UDK 378.4(497.5 Rijeka)(05)

ISSN 1848-1299 (tisak)
ISSN 1848-1723 (online)

ZBORNIK
VELEUČILIŠTA U RIJECI

Journal of the Polytechnic of Rijeka

Vol. 2, No. 1

Rijeka, 2014.

ZBORNIK VELEUČILIŠTA U RIJECI – JOURNAL OF THE POLYTECHNIC OF RIJEKA

Izdavač – *Published by*

VELEUČILIŠTE U RIJECI - *POLYTECHNIC OF RIJEKA*
Trpimirova 2/V, 51000 Rijeka
Hrvatska - Croatia

Za izdavača – *For the Publisher*
Prof. dr. sc. DUŠAN RUDIĆ
Dekan - *Dean*

Urednički odbor – *Editorial Board*
Prof. dr. sc. DUŠAN RUDIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska; mr. sc. EDA RIBARIĆ AIDONE, Veleučilište u Rijeci, Rijeka, Hrvatska; mr. sc. MAJA GLIGORA MARKOVIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska; dr. sc. SANJA RASPOR JANKOVIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska; DAVOR ŠIROLA, mag. oec. spec., Veleučilište u Rijeci, Rijeka, Hrvatska; mr. sc. LJERKA TOMLJENOVIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska; mr. sc. ANITA STILIN, Veleučilište u Rijeci, Rijeka, Hrvatska; prof. dr. sc. NATAŠA ZRILIĆ, Grad Rijeka, Veleučilište u Rijeci, Rijeka, Hrvatska; prof. dr. sc. IVAN POGARČIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska; prof. dr. sc. ALEN JAKUPOVIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska; prof. dr. sc. RATKO ZELENIKA (ret.), Ekonomski fakultet Rijeka, Sveučilište u Rijeci, Hrvatska; SAŠA HIRNIG, Veleučilište u Rijeci, Rijeka, Hrvatska; dr. sc. IVICA BARIŠIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska; prof. dr. sc. BOJAN HLAČA, Veleučilište u Rijeci, Rijeka, Hrvatska; mr. sc. ZDENKO NOVAK (ret.), Veleučilište u Rijeci, Rijeka, Hrvatska; IVAN GRAKALIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska; prof. dr. sc. MARIO STAVER, Veleučilište u Rijeci, Rijeka, Hrvatska; prof. dr. sc. DAMIR ŠEKULJA, Veleučilište u Rijeci, Rijeka, Hrvatska; prof. dr. sc. SINIŠA PETROVIĆ, Veleučilište u Rijeci, Rijeka, Hrvatska;

PhD NATAŠA BOŠKIĆ, Faculty of Education, Learning & Technology Services, The University of British Columbia, Vancouver, Canada; Prof. Dr.-Ing. HERBERT SONNTAG, Technische Hochschule Wildau, Wildau, Germany; prof. dr. sc. RAMIZ KIKANOVIĆ, Univerzitet „Vitez" u Travniku, Travnik, Bosna i Hercegovina; Prof. Dr. HERMANN PECHHACKER, Institut für Bienenkunde, Austrian Carnica Association, Lunz am See, Austria;

Glavni i odgovorni urednik – *Editor-in-Chief*
Prof. dr. sc. DUŠAN RUDIĆ

Izvršni urednici – *Executive Editors*
Mr. sc. EDA RIBARIĆ AIDONE, pred.
Mr. sc. MAJA GLIGORA MARKOVIĆ, v. pred.

Tajnica Uredništva – *Secretary*
Mr. sc. EDA RIBARIĆ AIDONE, pred.

Lektori – *Language Editors*
Dr. sc. SANJA GRAKALIĆ PLENKOVIĆ (hrvatski jezik – *Croatian Language Editor*)
TAMARA POLIĆ, v. pred. (engleski jezik – *English Language Editor*)

Oblikovanje naslovnice – *Cover Design*
SLAVIŠA SRDIĆ

Zbornik izlazi jedanput godišnje – *Proceedings is issued once a year*
Pretplata: cijena primjerka iznosi 40,00 kn

Radovi objavljeni u Zborniku dostupni su na Portalu znanstvenih časopisa Republike Hrvatske - HRČAK
Papers published in the Journal are available through Portal of scientific journals of Croatia - HRČAK
http://hrcak.srce.hr/zbornik-veleri

Tisak – *Printed by*
Chamango, obrt za dizajn
Naklada - *Edition*
300 primjeraka – *copies*

Adresa Uredništva – *Editorial Board Address*
Veleučilište u Rijeci – Zbornik Veleučilišta u Rijeci,Vukovarska 58, 51000 Rijeka, Hrvatska, tel.: ++385 51 321 300;
faks.: ++385 51 211 270; *e-mail*: zbornik@veleri.hr; http://www.veleri.hr
ISSN 1848-1299 (tisak) 1848-1723 (online)

Copyright© Dijelovi objavljenih radova smiju se koristiti za osobnu ili edukacijsku svrhu uz poštovanje autorskih prava autora i izdavača.

UDK 378.4(497.5 Rijeka)(05)

ISSN 1848-1299 (tisak)
ISSN 1848-1723 (online)

ZBORNIK

VELEUČILIŠTA U RIJECI

Vol. 2 (2014), No. 1

RIJEKA, 2014.

PREDGOVOR

Veleučilište u Rijeci započelo je s radom 1998. godine. Osnovano je na temelju Uredbe Vlade Republike Hrvatske 21. svibnja 1998. godine. Veleučilište ima sjedište u Rijeci te dislocirane studije u Poreču, Pazinu, Puli i Ogulinu.

Od svojeg osnutka do danas Veleučilište u Rijeci izraslo je u moderno visoko učilište s prepoznatljivim stručnim i specijalističkim studijima i programima koji pokrivaju potrebe Rijeke, Primorsko-goranske i susjednih županija.

Danas se na Veleučilištu u Rijeci izvodi devet stručnih studija i pet specijalističkih diplomskih stručnih studija. Visoku razinu kvalitete Veleučilišta potvrđuju sva dosadašnja vanjska vrednovanja 2004., 2009. i 2014. godine (u tijeku), koja provode međunarodna stručna povjerenstva za ocjenu Veleučilišta u Rijeci, te dobivene dopusnice.

Osim reakreditacija, posebno treba istaći Certifikat koji je uručen Veleučilištu u Rijeci 2013. godine nakon vanjskog neovisnog vrednovanja sustava kvalitete u organizaciji Agencije za znanost i visoko obrazovanje Republike Hrvatske. Certifikatom se potvrđuje da je sustav osiguravanja kvalitete u skladu sa standardima i smjernicama za osiguranje kvalitete u Europskom prostoru visokog obrazovanja. Certifikatom se potvrđuje da je sustav osiguravanja kvalitete Veleučilišta u Rijeci učinkovit i u razvijenoj fazi na temelju kriterija Agencije za znanost i visoko obrazovanje za vanjske neovisne periodične prosudbe sustava osiguravanja kvalitete visokih učilišta u Republici Hrvatskoj.

Suvremeni i međunarodno usporedivi programi, osigurani prostori i suvremena oprema, kompetentno i motivirano nastavno osoblje, djelotvoran organizacijski ustroj i isto takav sustav upravljanja, motivirani studenti i uspostavljen sustav praćenja kvalitete nastave, kao i suradnja s gospodarstvom te domaćim i inozemnim visokoškolskim ustanovama, temelj su uspješnom daljnjem razvoju Veleučilišta.

U sklopu uspješnog djelovanja Veleučilište je pripremilo i drugi broj Zbornika Veleučilišta u Rijeci. Zato mi je posebno zadovoljstvo što drugi broj Zbornika mogu predstaviti svim poštovanim kolegicama i kolegama, nastavnicima i studentima Veleučilišta te drugim čitateljima. Zbornik sadrži brojne radove iz područja koja pokrivaju studiji Veleučilišta u Rijeci.

Zbornik sadrži znanstvene i stručne radove koji pobuđuju interes znanstvene i stručne javnosti. Sve su radove recenzirala po dva anonimna i neovisna recenzenta, svi su kategorizirani prema propisanoj klasifikaciji znanstvenih i stručnih radova te zastupljeni na Portalu znanstvenih časopisa Republike Hrvatske.

Zahvaljujem Uređivačkom odboru i autorima znanstvenih i stručnih radova, kao i recenzentima, koji su značajno pridonijeli kvaliteti ovog Zbornika.

Srpanj 2014.

Prof. dr. sc. Dušan Rudić
Glavni i odgovorni urednik

SADRŽAJ

PREDGOVOR

DRUŠTVENE ZNANOSTI

Sanja Raspor Janković, Maja Gligora Marković, Alma Brnad
RELATIONSHIP BETWEEN ATTRIBUTE AND OVERALL CUSTOMER SATISFACTION: A CASE STUDY OF ONLINE BANKING SERVICES
(Izvorni znanstveni rad). *1-12*

Elena Krelja Kurelović, Jasminka Tomljanović, Krešimir Bronić
UPORABA APLIKACIJA U OBLAKU KOD STUDENATA
(Izvorni znanstveni rad). *13-26*

Marino Golob, Tina Sirotić, Martin Golob
ISTRAŽIVANJE KVALITETE I RAZINE ZADOVOLJSTVA TURISTA TURISTIČKOM PONUDOM
(Prethodno priopćenje) *27-40*

Sabrina Šuman, Maja Gligora Marković, Berta Jadro
DECISION SUPPORT AND BUSINESS INTELLIGENCE – WHAT NEEDS TO BE LEARNT?
(Prethodno priopćenje) *41-58*

Nataša Zrilić, Davor Širola
SOCIJALNO PODUZETNIŠTVO – NOVA MOGUĆNOST ZAPOŠLJAVANJA MLADIH U HRVATSKOJ
(Pregledni rad) *59-76*

Denis Buterin, Julijan Plenča, Eda Ribarić Aidone
MOGUĆNOSTI I RIZICI INVESTIRANJA NA *FOREX* TRŽIŠTU
(Pregledni rad) *77-90*

Denis Buterin, Nikolina Blašković, Eda Ribarić Aidone
SUZBIJANJE KRUŽNIH PRIJEVARA U CILJU ZAŠTITE JAVNIH FINANCIJA HRVATSKE
(Pregledni rad) *91-106*

Silvano Čulinović, Marin Kaluža, Dijana Liverić
USPOREDBA PROTOKOLA ZA PRIJENOS DATOTEKA
(Pregledni rad) *107-126*

Ivana Bujan, Marija Vugrinec
SPECIFIČNOSTI FINANCIRANJA SME SEKTORA U HRVATSKOJ U ODNOSU NA ZEMLJE EUROPSKE UNIJE
(Stručni rad).....*127-138*

Davor Širola, Valentina Iskra
ANALIZA SUSTAVA POTICANJA PODUZETNIŠTVA NA EUROPSKOJ, HRVATSKOJ I LOKALNOJ RAZINI
(Stručni rad).....*139-162*

Aleksandar Skendžić
SIGURNOST INFRASTRUKTURNOG NAČINA RADA BEŽIČNE MREŽE STANDARDA IEEE 802.11
(Stručni rad).....*163-176*

Jasminka Tomljanović, Marina Krsnik, Mile Pavlić
SUSTAVI PITANJA I ODGOVORA
(Stručni rad).....*177-196*

Vedran Harmadi, Marin Kaluža, Dijana Liverić
USPOREDBA TEHNOLOGIJA PRIKAZA ANIMACIJA U RAZLIČITIM *WEB*-PREGLEDNICIMA
(Stručni rad).....*197-214*

Adrian Smijulj, Ana Meštrović
IZGRADNJA MVC MODULARNOG RADNOG OKVIRA
(Stručni rad).....*215-232*

TEHNIČKE ZNANOSTI

Bojan Hlača, Dušan Rudić, Erika Gržin
PROMET KONTEJNERA NA PRAVCU DALEKI ISTOK – SJEVER ILI JUG EUROPE
(Prethodno priopćenje).....*235-254*

Marko Kršulja, Dario Bognolo
ODREĐIVANJE ALATNE GEOMETRIJE U OVISNOSTI O PONAŠANJU MATERIJALA TIJEKOM PROCESA OBRADE DEFORMIRANJEM
(Prethodno priopćenje).....*255-274*

Ivo Brozović, Aleksandar Regent, Matea Grgurević
EMISIJE STAKLENIČKIH PLINOVA, OSOBITO IZ PROMETA
(Prilog analizi emisija stakleničkih plinova, osobito iz prometa)
(Pregledni rad).....*275-294*

Milorad Milojica, Kristina Dundović
PRIMJENA POISSONOVE RAZDIOBE U STATISTIČKOJ OBRADI OZLJEDA NA RADU U TRGOVAČKOM DRUŠTVU „LUKA RIJEKA“
(Stručni rad).....*295-312*

Tatjana Gregorović , Dario Bognolo, Marko Kršulja
PRORAČUN I ODABIR PARAMETARA TRANSPORTNE TRAKE
(Stručni rad).....*313-328*

BIOTEHNIČKE ZNANOSTI

Slavica Dudaš, Irena Šestan
UTJECAJ TEHNOLOGIJE UZGOJA PRESADNICA I PRIMJENE BIO-ALGEENA S-90 NA KVALITETU KADIFICE *TAGETES PATULA* L. 'ORANGE BOY'
(Izvorni znanstveni rad).....*329-342*

Damir Šekulja, Hermann Pechhacker, Elisabeth Licek
DRIFTING BEHAVIOR OF HONEY BEES (*APIS MELLIFERA CARNICA* POLLMAN, 1879) IN THE EPIDEMIOLOGY OF AMERICAN FOULBROOD
(Izvorni znanstveni rad).....*343-358*

UPUTE AUTORIMA.....359-368

GUIDELINES FOR AUTHORS.....369-378

DRUŠTVENE ZNANOSTI

Sanja Raspor Janković[1]
Maja Gligora Marković[2]
Alma Brnad[3]

Izvorni znanstveni rad
UDK 33671:004.78](497.5)
33671:658.89](497.5)

RELATIONSHIP BETWEEN ATTRIBUTE AND OVERALL CUSTOMER SATISFACTION: A CASE STUDY OF ONLINE BANKING SERVICES[4]

ABSTRACT

The purpose of this paper is to examine the relationship between attribute and overall customer satisfaction with online banking services. The main objective was to discuss the impact of four online banking service attributes on overall customer satisfaction. The questionnaire designed for collecting data consisted of three parts. Firstly, customer satisfaction with online banking services was measured. Secondly, questions about online banking services usage were comprised. Thirdly, demographic variables were included. Questionnaires were distributed online, of which 171 valid responses were gathered. Descriptive analysis, correlation analysis, and multiple regression analysis were performed to analyze data. The findings showed that accessibility, security and price had a significant and positive effect on overall customer satisfaction, while user-friendly approach positively influenced overall customer satisfaction, but this impact was not statistically significant when other variables were involved. These findings indicate that improving online banking services' accessibility, security, price and user-friendly approach lead to higher overall satisfaction levels of online banking customers.

Key words: *customer satisfaction, online banking services, statistical analysis, Croatia.*

1. INTRODUCTION

Online services have become an important part of company business scope, regardless of their nature of conducting business as online companies or traditional companies that are yet to develop online services. As much as it is important to achieve customer satisfaction with "traditional" services, companies are also eager to have satisfied customers by offering their online services.

One of the service sectors that recognized the advantages of online services was banking industry. According to the Croatian National Bank, at the end of 2013 the number of online banking users in Croatia exceeded 1.3 million (http://www.hnb.hr). The number of online banking users indicates a need for better understanding of online banking from customer perspective.

In practice, banks conduct surveys about their customers and provide customers with a possibility to express their opinions, as well as positive and negative experiences regarding bank's products and services. This information is useful for improving and meeting customer needs. However, according to the search results on the Croatian Scientific Bibliography portal and the Portal of

[1] PhD, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: sraspor@veleri.hr
[2] MSc, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. *E-mail:* mgligoram@veleri.hr
[3] Student, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: abrnad@veleri.hr
[4] Received: 19. 2. 2014.; aaccepted: 5. 5. 2014.

Scientific Journals of Croatia, there is insufficient academic research referring to the online banking sector in Croatia. In addition to the authors' best knowledge, there is no academic research quoting findings on customer satisfaction with online banking services in Croatia. Therefore, it is justified to conduct this study.

The paper is organized as follows. Firstly, brief theoretical background is provided. Then, research methodology is explained. Next, results of empirical research are presented, followed by discussion and conclusion.

2. THEORETICAL BACKGROUND

Customer satisfaction has usually been defined as a post consumption evaluative judgment (Fornell, 1992; Oliver, 1997). According to Oliver (1997), customer satisfaction is a judgment that product or service provides a pleasurable level of consumption related fulfillment.

In addition, Churchill and Surprenant (1982) stated that satisfaction is similar to attitude as it can be assessed as the sum of satisfaction judgments regarding various attributes of relevant product or service. Similarly, Oliver (1997) pointed out that customer satisfaction can be measured with single or multiple indicators. Since services, including banking services, are complex, it is important to identify and measure customer satisfaction with each service component. This approach focuses on attribute satisfaction and provides more accurate and reliable information, since satisfaction (or dissatisfaction) with one service attribute leads to overall satisfaction (or dissatisfaction) with this service (Grigoroudis, Siskos, 2010; Kozak, Rimmington, 2000). However, there is a large body of research that used one, overall measure for assessing customer satisfaction (Yüksel, Rimmington, 1998; Choi, Chu, 2001; Akama, Kieti, 2003; Alén Gonzalez et al., 2007; Namkung, Jang, 2008). Although this approach is less complex, it is usually not the best predictor of overall service performance, because it provides general customer satisfaction measure. However, customer satisfaction operationalization as attribute or overall measure depends on research purpose and objectives.

In this study, customer satisfaction with online banking services is operationalized with attribute satisfaction measures that result in overall customer satisfaction.

A review of literature shows that researchers investigated the relationship between attribute and overall customer satisfaction with online banking services using different number and nature of attributes. In addition, the results of these studies have empirically confirmed that proposed attributes significantly affected overall customer satisfaction with online banking services. In this regard, Rod et al. (2009) found that online customer service quality, online information system quality and banking service product quality, as overall banking service quality dimensions, influenced customer satisfaction. Yoon (2010) demonstrated that design, security, speed, information content, and customer support service significantly influenced customer satisfaction. Hu and Liao (2011) proposed efficiency, system availability, responsiveness, compensation, contact, tangibility, privacy, reliability, reputation, continuing improvement, personalization, and benefit as antecedents of customer satisfaction within online banking sector. Zavareh et al. (2012) proposed efficient and reliable services, fulfillment, security/trust, site aesthetics, responsiveness/contact and user-friendly

approach. Kordnaeij et al. (2013) determined accessibility, easiness, trust, security, website design, website content, speed, and commission as factors affecting online banking customer satisfaction.

In accordance with previous researches, price, accessibility, security, and user-friendly approach are proposed in this study as attributes that influence overall customer satisfaction with online banking services in Croatia.

3. METHODOLOGY

In the following section research objectives are presented, hypotheses proposed, questionnaire design explained, sampling procedure described and data analysis methods presented.

3.1 Research objectives and hypotheses

The idea behind this study was to examine the relationship between attribute and overall customer satisfaction in the context of online banking sector in Croatia. Specifically, the study aimed at (a) assessing attribute and overall customer satisfaction, and (b) discussing the impact of online banking service attributes on overall customer satisfaction with online banking services.

In order to meet the study's objectives, the following main hypothesis and sub-hypotheses were proposed:

H_1: Online banking service attributes have positive and significant effect on the overall customer satisfaction with online banking services.

H_{1a}: Price has a positive and significant impact on overall customer satisfaction.

H_{1b}: Accessibility has a positive and significant impact on overall customer satisfaction.

H_{1c}: User-friendly approach has a positive and significant impact on overall customer satisfaction.

$H1_d$: Security has a positive and significant impact on overall customer satisfaction.

3.2 The questionnaire

In order to address research objectives, a questionnaire was developed. The foundation of questionnaire design in this study was literature review elaborated in the theoretical part of the paper, and questionnaires used by banks when conducting similar surveys. The questionnaire included 17 items and was divided in three parts.

The first part was designed for measuring customer satisfaction with online banking services. This concept was operationalized with attribute and overall customer satisfaction measures. Attribute customer satisfaction measures represented four variables, namely price, accessibility, user-friendly approach and security. The overall customer satisfaction was measured with one item. All customer satisfaction variables were rated on a 6-point scale, ranging from "very dissatisfied" (1) to "very satisfied" (6).

The second part of the questionnaire included seven items regarding the use of online banking services: bank's name, user type, device for using the service, location, years of online banking

experience, frequency of online banking, and the most frequently used services. These variables were measured using nominal scale.

Respondents' demographic information was included in the questionnaire's third part and it referred to respondent's gender, age, level of education, county of residence, and economic status. These characteristics were measured using nominal scale.

3.3 Sampling procedure

The target population in this study were online banking customers in Croatia. Thus, a sample consisted of individuals who use online banking services and were willing to participate in the research.

Data were gathered from April to June 2013, using online questionnaire. The link to the questionnaire was distributed via e-mail, with the request to forward it to other addresses, if possible. Of 203 returned questionnaires, 32 were not included in the analysis because they were incomplete. Therefore, data collection resulted in a sample of 171 valid questionnaires.

3.4 Data analysis

The collected data were analyzed using the SPSS 19 statistical software. Data analysis included descriptive statistics, correlation analysis and multiple regression analysis.

Descriptive statistics was used to examine respondents' demographic profile and their online banking habits, as well as to assess attribute and overall customer satisfaction with online banking services. This method was used to meet the first research objective.

Correlation analysis and multiple regression analysis were used to explore how the attribute customer satisfaction variables were related to the overall customer satisfaction, addressing the second research objective. Specifically, correlation analysis was performed to assess relationships between each service attribute and overall customer satisfaction. At this stage, sub-hypotheses were tested (H_{1a} – H_{1d}) using Pearson correlation coefficients. In addition, multiple regression analysis was used to examine the relationship between the combination of service attributes and overall customer satisfaction. This is a useful technique that can be used to analyze the relationship between a single dependent variable and several independent variables (Hair et al., 2006). Hence, multiple regression analysis was conducted to test the main research hypothesis. The latter analysis was performed using confirmatory (simultaneous) approach.

4. RESULTS

The results are presented as follows. Firstly, demographic profile of the respondents and their habits regarding the use of online banking services are presented. Next, the relationship between attribute and overall customer satisfaction with online banking services is examined.

4.1 Demographic characteristics and the use of online banking services

Detailed descriptive statistics relating to the respondents' profile is presented in Table 1.

Table 1. Descriptive statistics of respondents' characteristics (N=171)

Characteristics	Percentage	Characteristics	Percentage
Gender		*Age*	
Male	35.1	15 - 24	18.7
Female	64.9	25 - 34	29.2
		35 - 44	35.7
Level of education		45 - 54	14.0
Secondary school	36.3	55 - 64	2.3
Higher education	30.4		
University and higher	33.3	*County of residence*	
		Istra	9.4
Economic status		Primorje-Gorski Kotar	72.5
Student	19.9	Sisak-Moslavina	3.5
Employed	69.6	Varaždin	5.3
Unemployed	8.2	Other	9.4
Retired	2.3		
		User classification	
Bank's name		Citizen	87.7
Splitska banka	2.9	Business	1.8
Zagrebačka banka	15.8	Both	10.5
Privredna banka Zagreb	28.1		
OTP banka	4.7	*Online tool*	
Raiffaisen	7.0	Personal computer	59.1
Erste banka	33.3	Laptop	33.3
HPB	4.1	Mobile phone	7.6
Other	4.1		
		Location	
Years of online banking experience		Home	84.2
1 - 3	29.2	Office	13.4
3 - 5	19.3	Other	2.4
5 - 7	20.5		
7 - 9	4.7	*Frequency of online banking*	
More than 9	11.1	Once per day	11.7

Characteristics	Percentage	Characteristics	Percentage
Without answer	15.2	More times per day	8.2
		Once per week	25.2
Most frequently used services		Twice per week	23.9
Account balance and turnover	48.5	Once per month	10.5
Transfers between accounts	5.3	Twice per month	20.5
Account payments	42.7		
Exchange rates	0.6		
Buying, selling and transfer of shares in investment funds	2.9		

Source: authors

As presented in Table 1, female respondents (64.9 per cent) outnumbered male respondents in the sample. Nearly two-thirds were in the age group between 25 and 44, and about 70 per cent were employed. The respondents were almost evenly distributed across different levels of education (approximately one-third in each level). The majority of respondents (72.5 per cent) was from Primorje-Gorski Kotar County, and used online banking service as citizens (87.7 per cent). About one-third were clients of Erste bank. Furthermore, the majority of respondents accessed online banking services from a personal computer (59.1 per cent), and from home (84.2 per cent). Almost half of the respondents had between 1 and 5 years of online banking experience, and about one-fourth used online banking services once per week. The most frequently used online banking services were insight into account balance and turnover (48.5 per cent) and account payments (42.7 per cent).

4.2 Antecedents of overall customer satisfaction

Table 2 indicates that the respondents were mostly satisfied with the accessibility of online banking services (mean = 5.05), followed by user-friendly approach (mean = 4.87), service security (mean = 4.84), and price (mean = 4.18). What is more, the overall customer satisfaction with online banking services was 4.96. These values indicate high levels of customer satisfaction with online banking services, since all of them are highly rated.

Correlation analysis was used to examine the nature of the relationship between each service attribute and the overall customer satisfaction. In order to identify relative impact of attribute customer satisfaction variables on overall customer satisfaction, multiple regression analysis was employed.

Table 2. Customer satisfaction descriptive statistics and correlation matrix (N=171)

Customer satisfaction variables	Mean	SD	1	2	3	4	5
1. Price	4.18	1.099	1.000				
2. Accessibility	5.05	0.932	0.279	1.000			
3. User-friendly approach	4.87	0.854	0.314	0.562	1.000		
4. Security	4.84	0.877	0.378	0.563	0.631	1.000	
5. Overall customer satisfaction	4.96	0.800	0.397	0.555	0.492	0.578	1.000

Note: mean ranges from 1 to 6; SD – standard deviation; all correlation coefficients are significant at 0.01 level.
Source: authors

The correlation matrix (Table 2) indicates that attribute customer satisfaction variables were moderately correlated with the overall customer satisfaction. All the relationships were positive and statistically significant. According to the results, the variable "security" had the strongest correlation with the "overall customer satisfaction" variable ($r = 0.578$, $p < 0.01$), followed by "accessibility", "ease of use", and "price" ($r = 0.555$, $r = 0.492$, and $r = 0.397$, $p < 0.01$, respectively).

Although all attribute customer satisfaction variables were intercorrelated with each other, the correlation coefficients did not exceed cut-off value of 0.80, which means that multicollinearity problem did not occur in this research (Bryman, Cramer, 2009). Thus, it was justified to conduct a multiple regression analysis.

Table 3. Multiple regression analysis (N=171)

Model fit				
Multiple R	0.666			
R^2	0.444			
Adjusted R^2	0.431			
Standard error	0.603			
F ratio	33.132			
Significance	0.000			
Independent variable	*b*	*Beta*	*t*	*Sig.*
Constant	1.469		4.697	0.000*
Price	0.129	0.178	2.823	0.005*
Accessibility	0.251	0.293	3.947	0.000*
User-friendly approach	0.082	0.088	1.108	0.270
Security	0.265	0.291	3.596	0.000*

Note: Dependent variable: overall customer satisfaction; * - significant at 0.01 level
Source: authors

The multiple regression analysis revealed the following. The relationship between the combination of independent variables in the model and dependent variable is strong (R = 0.666). According to the coefficient of determination (R^2 = 0.444) and the adjusted coefficient of determination (adjusted R^2 = 0.431), four attribute customer satisfaction variables explained approximately 44 per cent of variance in overall customer satisfaction. Since R^2 value and adjusted R^2 value are very similar (adjusted R^2 decreased by only 0.013 points), the regression model in this research has a very good explanatory power of dependent variable. In addition, the significant *F*-ratio (F = 33.132, $p < 0.01$) suggested that the results of the employed regression model could not have occurred by chance and that the combination of independent variables significantly predicted dependent variable.

To assess the relative importance of each independent variable in determining the value of dependent variable, beta coefficients are provided. According to Table 3, three out of four independent variables significantly influenced overall customer satisfaction. The variable "accessibility" ($\beta = 0.293$, $p < 0.01$) had the highest statistically significant standardized coefficient. Therefore, this was the most important independent variable and had the highest impact on overall customer satisfaction. It was followed by the variables "security" ($\beta = 0.291$, $p < 0.01$), and "price" ($\beta = 0.178$, $p < 0.01$). The least important independent variable in this regression model was "user-friendly approach" ($\beta = 0.088$, $p > 0.05$), meaning that this service attribute had the smallest impact on overall customer satisfaction. In addition, this impact was not statistically significant.

However, since all variables were considered together, deletion of one independent variable (although not significant) can affect the significance levels of other independent variables (Leech et al., 2005). Therefore, the multiple regression model in this study has produced adequate and significant results, meaning that accessibility, security, price and user-friendly approach can be used as significant predictors of overall customer satisfaction with online banking services.

5. DISCUSSION AND CONCLUSION

The study reported here was designed to empirically examine the nature of the relationship between attribute and overall customer satisfaction in the online banking sector in Croatia. Using several methods of statistical analysis, objectives were achieved and hypotheses tested.

According to the findings, the respondents showed high levels of attribute and overall customer satisfaction with online banking services. The respondents were most satisfied with the accessibility of online banking services, while they were least satisfied with their price.

The findings of the correlation analysis showed positive and significant relationships between each attribute satisfaction variable and overall customer satisfaction. This evidence supported the hypotheses H_{1a} to H_{1d}. All attributes, namely "security", "accessibility", "price" and "user-friendly approach" were moderately related to overall customer satisfaction. These results suggested that increase in each attribute satisfaction variable is likely to lead to increase in the overall customer satisfaction with online banking services.

The multiple regression analysis indicated that attribute satisfaction variables are an important antecedent of overall customer satisfaction. The results revealed a strong, positive and significant

relationship between the combination of attribute satisfaction variables and overall customer satisfaction, implying that highly perceived "accessibility", "security", "price" and "user-friendly approach" lead to higher overall customer satisfaction in the Croatian online banking sector. In addition, about 44 per cent of variance in the overall customer satisfaction can be explained by these attributes. Thus, the explanatory power of the tested model in the online banking sector is rather satisfactory. These results have confirmed the hypothesis H_1.

The most important predictor of overall customer satisfaction in this study was the attribute "accessibility". According to the results, a one-unit increase in satisfaction with online banking service accessibility would result in 29.3 per cent increase in customer overall satisfaction with their online banking experience, other variables being constant.

"Security" turned out to be the second most important attribute affecting overall customer satisfaction. A one-unit increase in satisfaction with online banking service security would lead to 29.1 per cent increase in the customer overall satisfaction with their online banking experience, other variables being constant.

Furthermore, "price" appeared to be the third significant attribute influencing the overall customer satisfaction in this study. The results showed that a one-unit increase in satisfaction with price of the online banking service would result in 17.8 per cent increase in the customer overall satisfaction with their online banking experience, other variables being constant.

Finally, although Pearson's correlation coefficient between the attribute "user-friendly approach" and overall customer satisfaction implied a significant positive correlation, when three other attributes were considered in the model, this service attribute did not have a statistically significant impact on the overall customer satisfaction.

However, the combination of four attribute satisfaction variables tested in this study demonstrated significant impact on overall customer satisfaction. The findings confirmed that higher accessibility, security, price, and user-friendly approach increase overall customer satisfaction in the online banking sector. Therefore, bank managers should set priorities and continue to improve these important aspects of online banking services.

Similar findings were reported by Yoon (2010) and Kordnaeij et al. (2013). Yoon (2010) found out that security had a significant influence, while user-friendly approach did not have significant influence on customer satisfaction with online banking services in China. As Yoon (2010) suggested, a possible explanation why user-friendly approach did not have a significant impact on customer satisfaction may be due to increased customer online experience thanks to which customers do not have much trouble using online banking. Furthermore, Kordnaeij et al. (2013) stated that, among others, accessibility and security had a positive and significant impact on customer satisfaction in the Iranian online banking sector.

In respect to study's limitations, although the sample included respondents from different Croatian counties, the majority of them came from the Primorje-Gorski Kotar County. The sampling procedure may have influenced the sample structure, hence not representing the population as a whole, although it included respondents from different age groups, online banking experience and

habits. In addition, this study examined only four online banking service attributes that are likely to influence customer satisfaction.

Therefore, future research could focus on diversifying respondents further across different demographic variables in order to ensure more comprehensive results. Furthermore, other attributes of online banking service should be taken into consideration. Business-to-business aspect of online banking customer satisfaction could also be investigated. Additionally, future research should address the issue of relationship between customer satisfaction and loyalty in the online banking sector in Croatia.

REFERENCES

Akama, J. S., Kieti, D. M. (2003) "Measuring tourist satisfaction with Kenya's wildlife safari: a case study of Tsavo West National Park", *Tourism Management*, 24, p. 73-81

Alén González, M. E. A., Comesana, L. R., Brea, J. A. F. (2007) "Assessing tourist behavioral intentions through perceived service quality and customer satisfaction", *Journal of Business Research*, 60, p. 153-160

Bryman, A., Cramer, D. (2009) *Quantitative Data Analysis with SPSS 14, 15 and 16: A Guide for Social Scientists*, London, New York: Routledge.

Choi, T. Y., Chu, R. (2001) "Determinants of hotel guests' satisfaction and repeat patronage in the Hong Kong hotel industry", *International Journal of Hospitality Management*, 20, p. 277-297

Churchill, G. A., Surprenant, C. (1982) "An Investigation into the Determinants of Customer Satisfaction", *Journal of Marketing Research*, 19, p. 491-504

Fornell, C. (1992) "A National Customer Satisfaction Barometer: The Swedish Experience", *Journal of Marketing*, 56, p. 6-21

Grigoroudis, E., Siskos, Y. (2010) *Customer Satisfaction Evaluation: Methods for Measuring and Implementing Service Quality*, New York: Springer Science and Business Media, LLC

Hair, J. F. et al. (2006), *Multivariate Data Analysis*, 6th Edition, New Jersey: Pearson Prentice Hall

Hu, Y.-C., Liao, P.-C. (2011) "Finding critical criteria of evaluating electronic service quality of Internet banking using fuzzy multiple-criteria decision making", *Applied Soft Computing*, 11, p. 3764-3770

Kordnaeij, A., Askaripoor, H, Imani, A. (2013) "The Impact of E-Banking Service Quality Dimensions on Customers' Satisfaction and Brand Equity (Case study: Refah Bank, Tehran)", *Business and Management Research*, 2(4), p. 25-37

Kozak, M., Remmington, M. (2000) "Tourist Satisfaction with Mallorca, Spain, as an Off-Season Holiday Destination", *Journal of Travel Research*, 38, p. 260-269

Leech, N. L., Barett, K. C., Morgan, G. A. (2005) *SPSS for Intermediate Statistics: Use and Interpretation*, 2nd Edition, New Jersey: Lawrence Erlbaum Associates Publishers

Namkung, Y., Jang, S. (2008) "Are highly satisfied restaurant customers really different? A quality perception perspective", *International Journal of Contemporary Hospitality Management*, 20(2), p. 142-155

Oliver, R. L. (1997) *Satisfaction: A Behavioral Perspective on the Customer*, New York: McGraw-Hill

Rod, M. et al. (2009) "An examination of the relationship between service quality dimensions, overall internet banking service quality and customer satisfaction: A New Zealand study", *Marketing Intelligence & Planning*, 27(1), p. 103-126

Yoon, C. (2010) "Antecedents of customer satisfaction with online banking in China: The effects of experience", *Computers in Human Behavior*, 26, p. 1296-1304

Yüksel, A., Rimmington, M. (1998) "Customer-Satisfaction Measurement", *The Cornell Hotel and Restaurant Administration Quarterly*, December, p. 60-70

Zavareh, F. B. et al. (2012) "E-Service Quality Dimensions and Their Effects on E-Customer Satisfaction in Internet Banking Services", *Procedia – Social and Behavioral Sciences*, 40, p. 441-445

http://www.hnb.hr/platni-promet/hplatni-promet.htm (11. 2. 2014.)

Sanja Raspor Janković[1]
Maja Gligora Marković[2]
Alma Brnad[3]

Original scientific paper
UDK 33671:658.89](497.5)
33671:658.89](497.5)

POVEZANOST ZADOVOLJSTVA POJEDINIM ELEMENTOM USLUGE I UKUPNOG ZADOVOLJSTVA KLIJENTA: PRIMJER USLUGA INTERNETSKOG BANKARSTVA[4]

SAŽETAK

Svrha ovog rada bila je istražiti povezanost zadovoljstva pojedinim elementom usluge i ukupnog zadovoljstva klijenta uslugama internetskog bankarstva. Osnovni cilj bio je utvrditi utjecaj zadovoljstva s četiri elementa usluge na ukupno zadovoljstvo klijenta. Upitnik za prikupljanje podataka sastoji se od triju dijelova. Prvo je mjereno zadovoljstvo klijenta uslugama internetskog bankarstva. Zatim su postavljena pitanja o korištenju usluga internetskog bankarstva. Treći dio sadrži pitanja o demografskim varijablama. Upitnici su ispitanicima poslani u obliku on-line ankete elektroničkom poštom. Prikupljen je 171 ispravno ispunjen upitnik. U analizi prikupljenih podataka korištene su metode deskriptivne statističke analize, korelacijska analiza i analiza multiple regresije. Rezultati pokazuju da dostupnost, sigurnost i cijena usluge značajno i pozitivno utječu na ukupno zadovoljstvo klijenta, dok je jednostavnost korištenja usluge pozitivno povezana s ukupnim zadovoljstvom, ali ta veza nije statistički značajna kada su uključene i druge varijable. Ovi rezultati ukazuju da poboljšanje dostupnosti, sigurnosti, cijene i jednostavnosti korištenja usluge internetskog bankarstva dovodi do više razine ukupnog zadovoljstva korisnika internetskog bankarstva.

Ključne riječi: *zadovoljstvo klijenta, usluge internetskog bankarstva, statistička analiza, Hrvatska.*

[1] Dr. sc., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* sraspor@veleri.hr
[2] Mr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* mgligoram@veleri.hr
[3] Student, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* abrnad@veleri.hr
[4] Datum primitka rada: 19. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

Elena Krelja Kurelović[1]
Jasminka Tomljanović[2]
Krešimir Bronić[3]

Izvorni znanstveni rad
UDK 004.78
378

UPORABA APLIKACIJA U OBLAKU KOD STUDENATA[4]

SAŽETAK

Posljednjih godina razvoj informacijske tehnologije ide u pravcu „računarstva u oblaku" koje se sve više prihvaća i ima široku primjenu u različitim područjima, pa tako i u obrazovanju, stoga se ovaj rad fokusira na mogućnosti primjene računarstva u oblaku u visokoškolskim ustanovama te razmatra spremnost studenata za primjenu ove inovativne tehnologije. Rad se bavi jednim od modela računarstva u oblaku, „softver kao usluga" (SaaS), jer se polazi od pretpostavke da su studenti često mobilni, te da imaju potrebu pristupati aplikacijama i podacima s raznih uređaja i lokacija. Motivacija i percepcija dva su važna faktora koji utječu na ponašanje, pa time pridonose uporabi nove tehnologije. Upravo su zbog toga ciljevi rada utvrditi motivaciju i percepciju studenata prema aplikacijama u oblaku te učestalost njihova korištenja, kao i korelaciju među navedenim varijablama. Rezultati istraživanja pokazali su da postoji statistički značajna razlika i u motivaciji i u percepciji aplikacija u oblaku između studenata sa studija informatike i ostalih studijskih programa Veleučilišta u Rijeci. S obzirom na broj računala i mobilnih uređaja s kojih pristupaju internetu, utvrđena je statistički značajna razlika u motivaciji za uporabu usluga u oblaku, dok na percepciju to nije imalo značajan utjecaj. Potvrđena je pozitivna korelacija između motivacije i uporabe aplikacija u oblaku, te percepcije i uporabe aplikacija u oblaku. Od najpoznatijih aplikacija u oblaku najviše se koriste one za komunikaciju i druženje, a najmanje uredske aplikacije.

Ključne riječi: *računarstvo u oblaku, SaaS, motivacija, percepcija, uporaba*

1. UVOD

Računarstvo u oblaku (engl. *cloud computing*) novi je smjer razvoja IT industrije, te nov način pristupanja i uporabe računalnih resursa. Stručnjaci su odabrali pojam „oblak" jer se koriste resursi virtualnih računala, točnije mrežnih poslužitelja čija točna lokacija nije poznata. Stoga je oblak ujedno i metafora za internet. U fokusu interesa ovog rada je model „softvera kao usluge" (SaaS), tj. aplikacija u oblaku. Radi se o uporabi resursa na udaljenim poslužiteljima na kojima se izvršavaju aplikacije i pohranjuju podaci, a pristupa im se preko *web*-sučelja. Primjena računarstva u oblaku je vrlo široka i raste iz dana u dan zbog mnogih prednosti koje donosi korisnicima, a potaknuta je sve većom uporabom bežičnih tehnologija za pristup internetu i mobilnih uređaja (prijenosnih računala, tableta, pametnih telefona). Aplikacije u oblaku pojednostavljuju razmjenu i dijeljenje

[1] Mr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* elena@veleri.hr
[2] Mr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* jasminka.tomljanovic@veleri.hr
[3] Prof. PTO, asistent, Srednja škola Mate Balote Poreč, Karla Huguesa 6, Poreč, Hrvatska.
E-mail: kresimir.bronic@pu.t-com.hr
[4] Datum primitka rada: 14. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

sadržaja, kolaboraciju i komunikaciju u realnom vremenu, povećana je dostupnost aplikacija te dohvatljivost i sinkronizacija vlastitih podataka. Da bi obrazovne ustanove imale što više koristi od računarstva u oblaku, potrebno je da takve aplikacije prihvate svi sudionici obrazovnog procesa, što predstavlja šire problemsko područje ovog rada.

2. RAČUNARSTVO U OBLAKU I NJEGOVE ZNAČAJKE

„Cloud computing je nastao kao želja IT stručnjaka za povećanjem kapaciteta i dodavanjem novih mogućnosti na vlastite sustave bez investiranja u novu infrastrukturu i potrebe za osposobljavanjem novog osoblja ili kupnje novih licenciranih programa" (CERT CARNet, 2010). Postoji nekoliko pristupa u definiranju računarstva u oblaku, što se može objasniti činjenicom da ono obuhvaća širok spektar hardverskih, programskih i podatkovnih usluga koje su dostupne na internetu. Nacionalni institut za standarde u Americi (NIST) definira računarstvo u oblaku kao „model (plati koliko koristiš) koji, na zahtjev, omogućuje praktičan pristup, putem računalne mreže, skupu konfigurabilnih računalnih resursa (mrežama, poslužiteljima, spremištima podataka, aplikacijama i ostalim uslugama) koji se mogu brzo pripremiti za uporabu i staviti na raspolaganje, uz minimalan napor ili interakciju davatelja usluge" (Bronzin, Adamec, 2011:25). Općeprihvaćena definicija opisuje računarstvo u oblaku kao klaster distribuiranih računala, odnosno ogromnih podatkovnih centara i farmi servera, koji pružaju resurse i usluge na zahtjev kroz računalnu mrežu, točnije internet (Sultan, 2010:110). Definicije računarstva u oblaku razlikuju se i u tome koriste li ga IT stručnjaci ili obični korisnici. „Obični korisnici će cloud computing definirati kao novi i jeftiniji način korištenja programskih rješenja koja će se unajmljivati prema potrebi. Informatički stručnjaci definirati će ga kao novi poslovni model ili novu tehnološku platformu za smještaj, pokretanje i korištenje informatičke programske podrške" (CERT CARNet, 2010). Računarstvo u oblaku omogućuje „osobne mreže raznih uređaja" koji funkcioniraju kao cjelina, a svima se može pristupati i upravljati putem *weba* jer podaci i aplikacije nisu pohranjeni na korisnikovim računalima i uređajima (Horrigan, 2008). Govoreći o računarstvu u oblaku treba naglasiti da se radi o trima različitim modelima pružanja usluga:

- infrastruktura kao usluga (engl. *Infrastructure as a Service*, IaaS),
- platforma kao usluga (engl. *Platform as a Service*, PaaS),
- aplikacija kao usluga (engl. *Software as a Service*, SaaS).

Svaki od ova tri modela usluga može biti realiziran na četiri različita načina, pa se s obzirom na izvedbu računarstva u oblaku razlikuju: javni oblak, privatni oblak, hibridni oblak i zajednički oblak (CERT CARNet, 2010).

Kod modela infrastrukture kao usluge korisnici unajmljuju virtualne poslužitelje i ostalu mrežnu opremu, prostor za pohranu podataka, te imaju mogućnost odabira operacijskog sustava i drugih programa. Korisnik ima mogućnost upravljanja tim resursima, obradom i pohranom podataka kao i razvojem aplikacija, ali nema nadzor nad infrastrukturom „oblaka". Najpoznatiju infrastrukturu kao uslugu predstavlja Amazon Elastic Compute Cloud (Amazon EC2). Kad se radi o potrebama programera, rješenje nudi platforma

kao usluga. Riječ je o uporabi uobičajenih razvojnih alata koji se nalaze na računalu u oblaku, a dohvatljivi su preko *web*-sučelja. Korisnik ima nadzor samo nad razvijenim aplikacijama. Najpoznatiji primjeri platforme kao usluge su Microsoft Azure (Visual Studio) i GoogleApps Engine (Python, Java). Model SaaS namijenjen je širokom krugu krajnjih korisnika. To ujedno predstavlja najstariji način unajmljivanja ili besplatnog korištenja informatičkih usluga koji je započeo s uporabom *web*-pošte (npr. Gmail, Hotmail, YahooMail) i evoluirao u aplikacije različitih namjena s izraženom društvenom komponentom (dijeljenje sadržaja, tagiranje, kolaboracija i sl.), sve do aplikacija s ujedinjenim funkcionalnostima (npr. Google Docs/Apps, MS Office 365, ZohoDocs). Značajno mjesto u modelu SaaS, uz već spomenuto, imaju aplikacije za pohranu i sinkronizaciju podataka u oblaku (npr. Dropbox, SkyDrive, GoogleDisk). Web 2.0 alati kod kojih se aplikacije pokreću na udaljenom serveru, gdje se pohranjuju i korisnički podaci, ujedno mogu biti aplikacije u oblaku, iako treba naglasiti da pojmovi Web 2.0 i SaaS nisu sinonimi (Barnatt, 2012; UNESCO IITE, 2010).

Računarstvo u oblaku karakterizira skalabilnost (opseg i količina uporabe resursa prema potrebama, tj. na zahtjev), neovisnost o platformi, mobilnost i dostupnost usluge (mogućnost pristupa bilo kada, s bilo koje lokacije i s raznih uređaja), a plaća se stvarno korištenje resursa (prema vremenu i obujmu u kojem se koriste). Prednost računarstva u oblaku je ekonomska isplativost zbog smanjenih troškova održavanja opreme, licenciranja i nadogradnje programa, a korisniku je uvijek dostupna najnovija verzija programa.

3. PRIMJENA „RAČUNARSTVA U OBLAKU“ U OBRAZOVANJU

Mnoge obrazovne ustanove u svijetu prepoznale su potencijal računarstva u oblaku jer on smanjuje troškove, a povećava efikasnosti i upotrebljivost računalnih resursa (Sultan, 2010:111). Svoj „put k oblaku“ obrazovne su ustanove najčešće započele unajmljivanjem usluge elektroničke pošte za potrebe studenata i osoblja, te resursa za pohranu podataka, ponajviše za otvorene obrazovne materijale gdje sigurnost podataka nije od vitalne važnosti (UNESCO IITE, 2010). Uz uporabu raznih aplikacija u oblaku, visokoškolske institucije povremeno iskazuju potrebu za velikom procesorskom snagom radi provođenja istraživanja i eksperimenata ili dodatni diskovni prostor za pohranu velike količine podataka, što može zatrebati i administrativnom osoblju, a rješenje je u unajmljivanju dodatne infrastrukture u oblaku. Određeni studijski programi i kolegiji bave se upravo razvojem *web*-aplikacija, pa su studentima potrebni razvojni alati i ostali resursi za hosting i upravljanje tim aplikacijama. U tom se slučaju koristiti platforma kao usluga. Migracija u oblak za IT odjel znači jednostavnije održavanje programskih i računalnih resursa na visokoškolskoj instituciji. Uporaba svih navedenih modela računarstva u oblaku po skupinama korisnika u sektoru visokoškolskog obrazovanja prikazana je slikom 1.

Slika 1. Korisnici računarstva u oblaku na visokoškolskim ustanovama

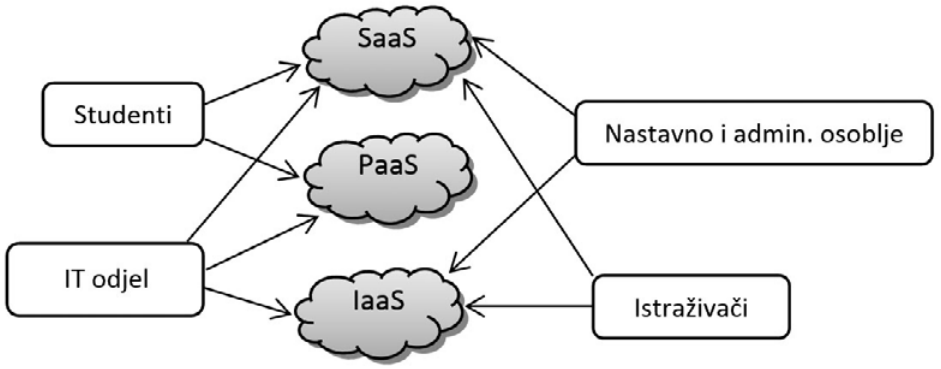

Izvor: izradili i prilagodili autori (prema Sultan, 2010:110)

U obrazovnom sektoru koriste se sustavi za upravljanje e-učenjem (LMS) smješteni na vanjskim poslužiteljima, što ima smisla za institucije koje ne mogu opravdati troškove kupnje, održavanja i nadogradnje potrebne programske podrške i sklopovlja. Jedna od najrašireniji aplikacija za upravljanje e-učenjem je Moodle, koji se može okarakterizirati kao aplikacija u oblaku (http://saasaddict.walkme.com). Značajan doprinos uporabe aplikacija u oblaku za potrebe obrazovanja u Hrvatskoj daje CARNet na portalu Edu.hr, gdje su dostupne posebno razvijene usluge u oblaku za učenike, studente i nastavnike, kao što su Webmail, Loomen (temeljen na Moodleu), Portal za učenje na daljinu Nikola Tesla, e-Knjižnica, eLektire, obrazovna multimedija na zahtjev. Također treba istaknuti Sveučilišni računski centar, „Srce", koji za znanstvene i obrazovne ustanove u Hrvatskoj nudi usluge u oblaku poput virtualnog poslužitelja (VPS), virtualnog računalnog laboratorija (VCL), uslugu pohranjivanja podataka (GSS) s 10 GB prostora, te daje platformu za razvoj i primjenu e-učenja (sustav Merlin, sustav za e-portfolio, uslugu *webinara*).

Računarstvo u oblaku ima puno potencijala za kreativnu uporabu u poučavanju i učenju, za povezivanje i suradnju studenata i nastavnika. Ono daje potpunu mobilnost, pa se nastava može održati i izvan zidova učionica (slika 2). Aplikacijama u oblaku studenti mogu na fleksibilan način pristupati elektroničkim knjigama i raznim obrazovnim resursima, s bilo kojeg mjesta i bilo kada, surađivati na projektima, zajedno kreirati sadržaje u realnom vremenu, učinkovito dijeliti ideje, diskutirati o određenim temama, brzo komunicirati i udruživati se u *online* zajednice. Njihovom uporabom stvaraju vlastito, personalizirano okruženje za „učenje u oblaku" ili „Cloud-Based Personalized Learning Environment" (Al-Zoube, 2009).

Slika 2. Mobilnost i personalizirano okruženje za učenje uporabom računarstva u oblaku

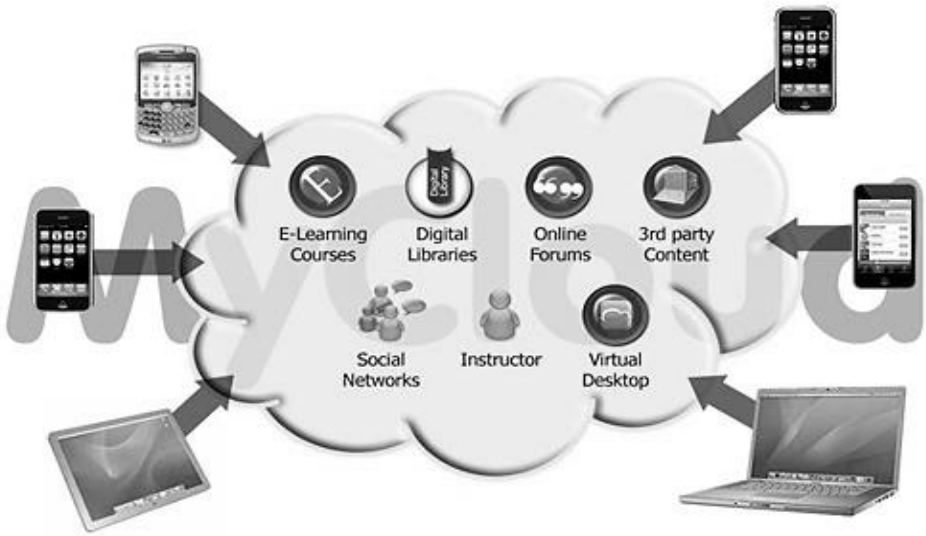

Izvor: http://www.edulabsglobal.com/the-edu-pad-difference/ (3. 1. 2014.)

Često se e-učenje i m-učenje povezuju s računarstvom u oblaku jer je korisnicima internetom omogućen pristup, korištenje, kreiranje i upravljanje udaljenim obrazovnim resursima i uslugama poput komunikacije, diskusije i kolaboracije (Kop, Carroll, 2011; Mallikharjuna, Sasidhar, Satyendra, 2010).

4. MOTIVACIJA, PERCEPCIJA I UPORABA APLIKACIJA U OBLAKU KOD STUDENATA VELEUČILIŠTA U RIJECI

Prihvaćanje određene inovacije dugotrajan je proces na koji utječu brojni individualni, organizacijski i društveni čimbenici. U nastavku će se analizirati utjecaj nekih individualnih čimbenika na prihvaćanje i uporabu aplikacija u oblaku kod studenata.

4.1 Teorijska osnova

Prema Rogersovom modelu širenja i prihvaćanja inovacija ljude možemo razvrstati u pet kategorija: inovatori, rani usvojitelji ili tehnološki lideri, rana većina, kasna većina i tradicionalisti koji se odupiru promjenama (slika 3), a udio svake navedene kategorije u populaciji prati Gaussovu krivulju (Zemsky, Massy, 2006). Sam proces prihvaćanja inovacije u društvu ima svoj tijek koji slijedi klasičnu S krivulju (slika 3), a to znači da je početak prihvaćanja inovacija vrlo spor, naglo raste kad inovacija postane dominantna, te se na kraju usporava jer dolazi do zasićenja (Zemsky, Massy, 2006). Isti autori su utvrdili da sve navedeno vrijedi za prihvaćanje tehnoloških inovacija u području obrazovanja, točnije e-učenja, pa je za očekivati da vrijedi i za prihvaćanje računarstva u oblaku.

Slika 3. Faze usvajanja tehnologije

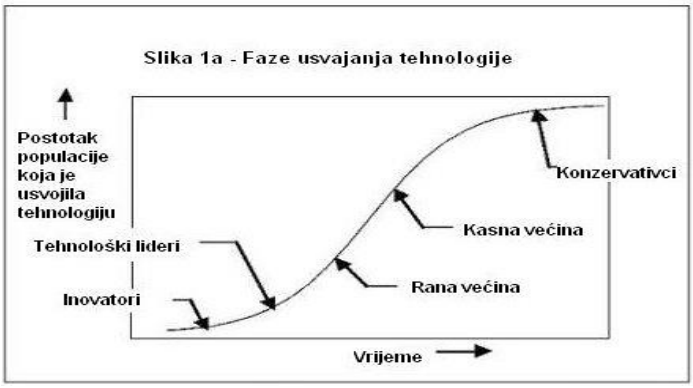

Izvor: http://edupoint.carnet.hr/casopis/47/clanci/3 (3. 1. 2014.)

Dok je računarstvo u oblaku, pogotovo SaaS, u poslovnom svijetu postao „mainstream" koji se širi na kasnu većinu (Board, 2011), postavlja se pitanje u kojoj je mjeri ono prihvaćeno u obrazovanju (Gartner, 2012). Istraživanja na temu računarstva u oblaku u području obrazovanja nema puno, a ovdje će biti navedeni zaključci nekih od njih. „Technology Acceptance Model" (TAM) zasniva se na pretpostavci da se prihvaćanje nove tehnologije može predvidjeti na temelju percepcije njene korisnosti i percepcije jednostavnosti uporabe, što značajno utječe na korisnikove stavove prema uporabi tehnologije, a sve to zajedno utječe na namjeru ponašanja i samo ponašanje, tj. korištenje tehnologije (Oye, 2011). Istraživanje Behrenda i suradnika na malom uzorku studenata, prema TAM modelu, pokazalo je da na prihvaćanje računarstva u oblaku najviše utječe jednostavnost korištenja i mala potreba instruiranja (Taylor, Hunsinger, 2011). Prema istom izvoru, istraživanje autora Ambrosea i Chiravurija utvrdilo je da na namjeru uporabe računarstva u oblaku značajno utječu dob i iskustvo. Taylor i Hunsinger (2011) koristili su teoriju planiranog ponašanja (engl. Theory of Planned Behavior) i utvrdili da na namjeru studenata za korištenje SaaS-a (GoogleDocs) značajno utječu stavovi, norme ponašanja i percipirana kontrola ponašanja (percepcija da studenti mogu i imaju potrebna znanja, sposobnosti i resurse za uporabu GoogleDocsa).

Glede uporabe usluga u oblaku u području visokog obrazovanja, istraživanje provedeno 2012. u Americi i Kanadi pokazuje da prednjače usluge pohrane podataka (31 %), aplikacije za komunikaciju i kolaboraciju (29 %) te unajmljivanje dodatne računalne snage (25 %) (www.cdwnewsroom.com).

4.2 Metodologija istraživanja

Metodologija istraživanja korištena u radu bit će objašnjena kroz ciljeve i hipoteze istraživanja, uzorak, opis mjernog instrumenta te metode statističke obrade podataka.

Problemsko područje ovog rada je uključivanje studenata u aktivnije prihvaćanje aplikacija u oblaku, kako za osobne potrebe, tako i za potrebe studiranja. Ciljevi istraživanja su utvrditi što motivira studente na uporabu aplikacija u oblaku (SaaS), kako percipiraju iste, te utječu li

studijski program i broj uređaja s pristupom internetu na motivaciju i percepciju aplikacija u oblaku. Također, cilj je utvrditi utječu li motivacija i percepcija prema aplikacijama u oblaku na učestalost njihove uporabe. U skladu s navedenim ciljevima postavljene su sljedeće hipoteze:

H1: Postoji značajna razlika u broju motivacijskih čimbenika za uporabu aplikacija u oblaku:
a) između studenata Informatike i studenata ostalih studijskih programa
b) s obzirom na korištenje više računala/uređaja s pristupom internetu.

H2: Postoji značajna razlika u percepciji aplikacija u oblaku:
a) između studenata Informatike i studenata ostalih studijskih programa
b) s obzirom na korištenje više računala/uređaja s pristupom internetu.

H3: Postoji pozitivna korelacija između učestalosti korištenja aplikacija u oblaku i
a) broja motivacijskih čimbenika za uporabu aplikacija u oblaku,
b) percepciji aplikacija u oblaku.

Populaciju u ovom istraživanju čine studenti Veleučilišta u Rijeci, dok uzorak predstavljaju oni studenti Veleučilišta u Rijeci koji su bili spremni ispuniti *online* anketni upitnik. Istraživanje je provedeno od siječnja do ožujka 2013. godine te se nastavlja na istraživanje o prepoznavanju potrebe studenata prema aplikacijama u oblaku (Krelja Kurelović, Rako, Tomljanović, 2013).

U svrhu istraživanja sastavljen je anketni upitnik u alatu GoogleDocs koji je distribuiran isključivo *online*, preko *web*-stranice Studentskog zbora Veleučilišta u Rijeci. U prvom dijelu prikupljali su se opći podaci o ispitaniku (spol, studijski program, godina studija) i uporabi računala (broj računala i drugih uređaja s kojima pristupaju internetu, učestalost *online*). Drugi dio uključuje pitanje o motivaciji za uporabu aplikacija u oblaku s 10 ponuđenih odgovora i mogućnošću višestrukog izbora. Zatim slijedi 8 izjava gdje ispitanici iskazuju svoj stupanj slaganja (5-stupanjska Likertova ljestvica) da bi se utvrdilo kako percipiraju aplikacije u oblaku. Treći dio sadrži 10 pitanja o učestalosti korištenja aplikacija u oblaku (5-stupanjska Likertova ljestvica).
Za opis uzorka i analizu rezultata korištene su metode deskriptivne statistike, dok su se za testiranje hipoteza koristili neparametrijski testovi: Mann-Whitneyjev U-test za nezavisne uzorke, Kruskal-Wallisov test s višestrukom komparacijom z vrijednosti, te Spearmanov koeficijent korelacije. Statistička obrada podataka rađena je u programu Statistica 8.0.

4.3 Analiza i interpretacija rezultata istraživanja

Anketni upitnik ispunilo je 158 ispitanika i to 58 % muškog i 42 % ženskog spola. Udio studenata studija Informatika u uzorku je 78 %, dok preostalih 22 % čine studenti ostalih studijskih programa Veleučilišta u Rijeci. U najvećoj mjeri ispitanici pohađaju stručne studije (prve 3 godine; 90 %), a mali je udio studenata specijalističkih studija (4. i 5. godina; 10 %).

Uređaji s kojih ispitanici najčešće pristupaju internetu su: prijenosna računala (74 %), pametni telefoni (67 %), zatim stolna računala (59 %), a najmanje koriste tablet PC (13 %) i ultraprijenosno računalo (5 %). Tu su mogli označiti više ponuđenih odgovora. Može se reći da velik udio ispitanika koristi više uređaja za pristup internetu, najčešće mobilnih,.

Na pitanje što bi ih potaklo na uporabu aplikacija u oblaku ispitanici su mogli odabrati više odgovora (od 10 ponuđenih). U prosjeku ispitanici su odabirali 5 motivacijskih čimbenika (M = 5,28; SD = 2,68). Za uporabu aplikacija u oblaku najveći broj studenata motivira jednostavnost uporabe (71 %) i mogućnost besplatnog korištenja usluge (70 %), zatim lakoća pristupa aplikaciji i procjena da će im takva aplikacija koristiti (62 %), mogućnost suradnje i dijeljenja sadržaja (52 %) te primjenjivost aplikacija na različitim platformama (51 %), što je prikazano na slici 4.

Slika 4. Motivacija za uporabu aplikacija u oblaku, frekvencije odgovora ispitanika

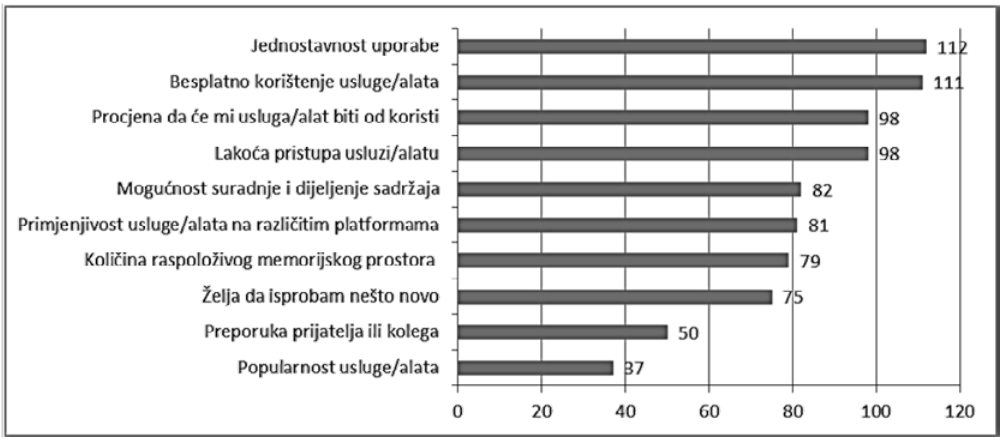

Izvor: obrada autora

Da bi iskazali percepciju prema aplikacijama u oblaku, ispitanici su označili stupanj slaganja s 8 izjava na ljestvici od *1 = uopće se ne slažem* do *5 = potpuno se slažem*. Rezultati su prikazani u tablici 1. Prema iskazanim aritmetičkim sredinama proizlazi da se ispitanici uglavnom slažu kako su aplikacije u oblaku korisne, te da bi im donijele određene pogodnosti (bolju komunikaciju i povezanost, te pristup dokumentima). Tu je i disperzija odgovora od aritmetičke sredine najmanja. U pogledu sigurnosti podataka u oblaku ispitanici nisu iskazali zabrinutost, ali niti veliko povjerenje (izjava „*e*" u tablici 1). U usporedbi s navedenim, istraživanje o uporabi i percepciji usluga u oblaku provedeno 2011. na uzorku od 1000 američkih *online* korisnika starijih od 18 godina pokazuje da se 40 % ispitanika slaže kako podacima pohranjenim u oblak nije osigurana sigurnost i privatnost (Board, 2011:9). Pitanje sigurnosti podataka u oblaku često se percipira kao barijera u prihvaćanju usluga u oblaku (Sultan, 2010; www.cdwnewsroom.com).

Tablica 1. Percepcija aplikacija u oblaku

Izjave	*Aritmetička sredina (M)*	*Standardna devijacija (SD)*
a. Aplikacije u oblaku mogle bi mi biti korisne.	4,14	0,76
b. Aplikacije u oblaku omogućile bi mi bolju povezanost s prijateljima i suradnicima te fleksibilan pristup dokumentima.	3,96	0,85
c. Aplikacije u oblaku mogu se koristiti bez puno podučavanja i uputa.	3,75	0,99
d. Prednost aplikacija u oblaku je što ne moram kupovati licence za uporabu programa, niti voditi računa o njihovoj nadogradnji.	3,65	0,98
e. Nesigurno je staviti osobne i druge važne podatke u oblak.	2,84	1,18
f. Prijelaz s poznatih „desktop" na manje poznate aplikacije u oblaku je frustrirajući.	2,63	1,24
g. Računarstvo u oblaku je trend koji se ne odnosi na mene.	2,36	1,09
h. Aplikacije u oblaku su nepouzdane za korištenje zbog utjecaja vremenske prognoze.	1,70	1,01

Izvor: obrada autora

U nastavku statističke obrade varijabla *„percepcija"* dobivena je kao linearni kompozit navedenih 8 čestica, vodeći računa o negativno postavljenim izjavama, tako da se njene vrijednosti kreću od 8 do 40. Ispitanici su iskazali učestalost korištenja 10 aplikacija u oblaku (uz koje je navedena njihova svrha i kategorija) na ljestvici od *1 = nikada* do *5 = vrlo često*. Kad se rezultati grupiraju po kategorijama i rangiraju prema aritmetičkoj sredini proizlazi da ispitanici koriste aplikacije u oblaku za (Krelja Kurelović, Rako, Tomljanović, 2013):

- komunikaciju i druženje (M = 3,62; SD = 0,75),
- konzumaciju i razmjenu multimedijskih sadržaja i slika (M = 2,79; SD = 1,15),
- e-učenje (M = 2,55; SD = 1,0),
- pohranu i sinkronizaciju podataka (M = 2,49; SD = 1,05),
- uredske (Doc/Office) aplikacije (M = 2,46; SD = 0,98) .

U prosjeku, aplikacije u oblaku ispitanici koriste ponekad (M = 2,75; SD = 1,09). U nastavku statističke obrade, varijabla *uporaba* predstavlja linearni kompozit navedenih 10 čestica, pa joj se vrijednosti kreću u intervalu od 10 do 50.

4.4 Testiranje hipoteza

Hipoteza H1a testirana je Mann-Whitneyjevim U-testom za nezavisne uzorke, te je utvrđena statistički značajna razlika u broju motivacijskih čimbenika za uporabu aplikacija u oblaku s obzirom na studijski program ($z = 2{,}358$; $p = 0{,}018$). Studenti sa studija Informatika iskazuju značajno veći broj motivacijskih čimbenika za uporabu aplikacija u oblaku ($M = 5{,}54$; $C = 6$; $Q_1 = 4$; $Q_3 = 7$) u odnosu na studente ostalih studijskih programa ($M = 4{,}37$; $C = 4$; $Q1 = 1$; $Q3 = 6$), pa možemo zaključiti da imaju veću motivaciju.

Hipotezom H1b želi se utvrditi postoji li statistički značajna razlika u motivaciji s obzirom na sljedeće tri nezavisne skupine ispitanika:

- 1 – student najčešće koristi jedno računalo/mobilni uređaj s pristupom internetu,
- 2 – student najčešće koristi dva računala/mobilna uređaja s pristupom internetu,
- 3 – student najčešće koristi tri i više računala/mobilna uređaja s pristupom internetu.

Stoga se koristio Kruskal-Wallisov test s višestrukom komparacijom z vrijednosti koji ukazuje da postoji statistički značajna razlika ($H(2, N = 158) = 8{,}456$; $p = 0{,}015$) u motivaciji za uporabu aplikacija u oblaku između skupina 1 i 3, tj. kod uporabe jednog računala/uređaja i uporabe 3 i više računala/mobilnih uređaja s pristupom internetu ($z_{1,3} = 2{,}489$; $p = 0{,}038$). Ta je razlika vidljiva i na slici 5 koja prikazuje Boxov i Whiskerov plot za varijable motivacija – broj računala/uređaja.

Slika 5. Boxov i Whiskerov plot za varijable motivacija
– broj računala/uređaja s pristupom internetu

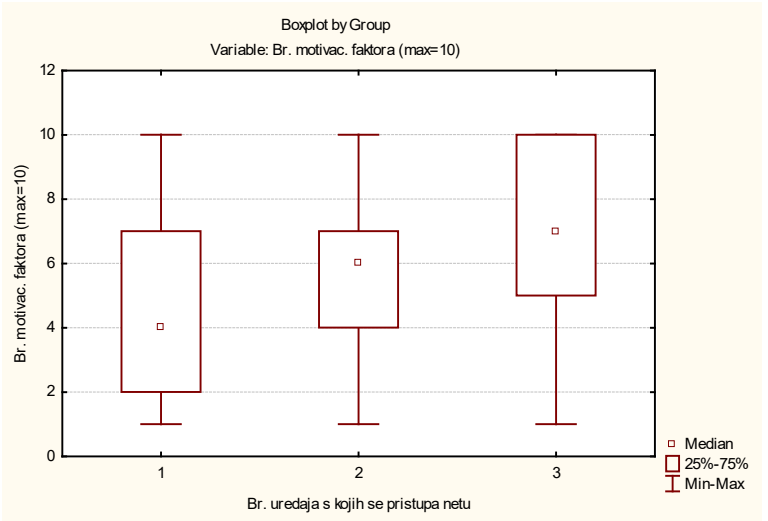

Izvor: obrada autora

Rezultati testiranja hipoteze H2a, koja je testirana Mann-Whintey U-testom, ukazuju da postoji statistički značajna razlika u percepciji aplikacija u oblaku s obzirom na studijski program ($z = 3{,}418$; $p = 0{,}001$). Očekivano, aplikacije u oblaku pozitivnije percipiraju studenti Informatike ($M = 30{,}60$; C

= 31; Q_1 = 27; Q_3 = 34) nego studenti ostalih studijskih programa (M = 27,68; C = 28; Q_1 = 24; Q_3 = 31). I druga istraživanja potvrđuju da ispitanici kojima IT nije struka često ne prepoznaju aplikacije u oblaku, iako neke od njih koriste (Board, 2011). Neočekivano je što se Kruskal-Wallisovim testom za H2b nije potvrdila razlika u percepciji aplikacija u oblaku s obzirom na korišteni broj računala/uređaja kojima se pristupa internetu (H(2, N = 158) = 4,961; p = 0,08).

Za testiranje treće hipoteze (H3a i H3b) korišten je Spearmanov koeficijent korelacije. Rezultati potvrđuju da postoji statistički značajna korelacija između motivacije i uporabe aplikacija u oblaku (r = 0,162: p < 0,05) te između percepcije i uporabe istih (r = 0,167; p < 0,05). Točnije, veći broj motivacijskih faktora kao i pozitivna percepcija aplikacija u oblaku povezani su s njihovom učestalijom uporabom.

Jedno od ograničenja ovog rada proizlazi iz činjenice da se istraživanje provelo među studentima na samo jednoj visokoškolskoj ustanovi, te da su u uzorku neravnomjerno zastupljeni studijski programi koji postoje na toj ustanovi. Zbog malog broja ispitanika u uzorku, on nije reprezentativan u smislu da možemo na temelju njega pouzdano zaključiti o cijeloj populaciji. Stoga bi bilo zanimljivo vidjeti da li se rezultati na reprezentativnom slučajnom uzorku studenata koji bi obuhvaćao veći broj visokoškolskih ustanova u Rijeci razlikuju od ovdje prikazanih rezultata. Uz navedeno, u nekom od budućih istraživanja trebalo bi se pozabaviti barijerama u prihvaćanju usluga u oblaku, na razini krajnjeg korisnika.

5. ZAKLJUČAK

Računarstvo u oblaku nova je paradigma u IT industriji usmjerena na potrebe i potražnju krajnjih korisnika. Oni sve češće koriste veći broj računala i mobilnih uređaja, pa je tim važnije bilo kada i s bilo koje lokacije biti u mogućnosti dohvatiti vlastite podatke, pokrenuti aplikacije i kreirati različite sadržaje, surađivati i komunicirati s kolegama i prijateljima, dijeliti dokumente i podatke, pregledavati i komentirati slike, videoisječke, glazbu itd. Sve to omogućuje „softver kao usluga" (SaaS), najjednostavniji model računarstva u oblaku koji uz „platformu kao uslugu" (PaaS) i „infrastrukturu kao uslugu" (IaaS) nalazi svoju primjenu i u obrazovnom sektoru. Brojne obrazovne ustanove prepoznale su prednosti računarstva u oblaku, od onih ekonomske prirode pa sve do njegovih kreativnih potencijala kada se primjeni u obrazovnom procesu za stvaranje, dijeljenje i širenje ideja, iskustava, promišljanja i znanja. Studenti primjenom aplikacija u oblaku mogu stvarati personalizirano virtualno okruženje za učenje, odnosno kroz oblak pristupati obrazovnim resursima i udruživati se s ostalim studentima i nastavnicima stvarajući virtualne zajednice učenja. No da bi se izvukle dobrobiti iz te inovativne tehnologije, potrebno je da je prihvate svi sudionici obrazovnog procesa.

Istraživanje provedeno na uzorku studenata Veleučilišta u Rijeci (N = 158) pokazalo je da za uporabu aplikacija u oblaku studente najviše motivira jednostavnost uporabe, mogućnost besplatnog korištenja aplikacija, lakoća pristupa aplikaciji i procjena da aplikacija može biti od koristi. Prosječna učestalost uporabe aplikacija u oblaku je „ponekad", najveću učestalost imaju aplikacije i servisi za komunikaciju i druženje, dok se najmanje koriste aplikacije Doc/Office u oblaku. Potvrđena je statistički značajna razlika između studenata sa studija Informatike i ostalih studijskih programa i u motivaciji i u iskazanoj percepciji prema aplikacijama u oblaku. Kada se uspoređuje skupina

korisnika jednog računala/mobilnog uređaja i skupina korisnika tri i više računalnih/mobilnih uređaja, studenti se statistički značajno razlikuju samo u motivaciji za uporabu aplikacija u oblaku. Pozitivna korelacija potvrđena je između motivacije i učestalosti uporabe te između percepcije i učestalosti uporabe aplikacija u oblaku.

Neki studenti su već krenuli put oblaka, pogotovo oni sa studija Informatika, pri čemu značajnu ulogu ima visoka motivacija i pozitivna percepcija. Kod drugih studijskih programa trebalo bi studente bolje upoznati s aplikacijama u oblaku, da dobiju priliku stvoriti potpuniju sliku njihovih mogućnosti i ograničenja, te ih motivirati da nađu svoj put k oblaku.

LITERATURA

Al-Zoube, M. (2009) E-learning on the Cloud, International Arab Journal of e-Technology, 1(2), p. 58-64, http://www.iajet.org/iajet/iajet_files/vol.1/no.2/E-Learning%20on%20the%20Cloud.pdf (28. 11. 2012)

Barnatt, C. (2012) A Guide to Computing by Christopher Barnatt, http://explainingcomputers.com/web2.html (31. 1. 2014)

Board, T. (2011) Head in the Clouds? Cloud computing & consumers, FYI: Technology Edition, http://www.ipsos.com/mediact/sites/ipsos.com.mediact/files/pdf/Head%20in%20the%20clouds.pdf (10. 4. 2014)

Bronzin, T., Adamec, D. (2011) Uzlet u oblake, Infotrend, 184, p. 25-27

CERT CARNet (2010) Cloud Computing, http://www.cert.hr/sites/default/files/NCERT-PUBDOC-2010-03-293.pdf (20. 1. 2014.)

Gartner (2012) Gartner Survy, http://www.gartner.com/newsroom/id/2253215 (29. 1. 2014.)

Horrigan, J. B. (2008) Use of Cloud Computing Applications and Services, Pew Internet, http://www.pewinternet.org/Reports/2008/Use-of-Cloud-Computing-Applications-and-Services.aspx (26. 11. 2013.)

Kop, R., Carroll, F. (2011) Cloud Computing and Creativity: Learning on a Massive Open Online Course, European Journal of Open, Distance and E-Learning, http://www.eurodl.org/index.php?article = 457 (28.11..2013.)

Krelja Kurelović, E., Rako, S., Tomljanović, J. (2013) Cloud Computing in Education and Student's Needs, MIPRO 36th International Convention Proceedings 2013, Computers in Education, Opatija, p. 856-861.

Mallikharjuna Rao, N., Sasidhar, C., Satyendra Kumar, V. (2010) Cloud Computing Through Mobile Larning, International Journal of Advanced Computer Science and Applications, 1(6), http://thesai.org/Downloads/Volume1No6/Paper_7_Cloud_Computing_Through_Mobile-Learning.pdf (03. 1. 2014.)

Oye, N. D. et al. (2011) A Model of ICT Acceptance and Use for Teachers in Higher Education Institutions, International Journals of Computer Science & Communication Networks, http://www.ijcscn.com/Documents/Volumes/vol1issue1/ijcscn2011010105.pdf (2. 1. 2014.)

Srce (2012) Novosti, No. 43, http://www.srce.unizg.hr/fileadmin/Srce/dokumenti/srce_novosti/Novosti_pdf/sn43.pdf (14. 1. 2014.)

Sultan, N. (2010) Cloud computing for education: A new dawn?, International Journal of Information Management, http://www.sciencedirect.com/science/article/pii/S0268401209001170 (26. 1. 2014.)

Taylor, C. W., Hunsinger, D. S. (2011) A Study of Students use of Cloud Computing Applications, Journal of Information Technology Management, http://jitm.ubalt.edu/XXII-3/article3.pdf (30. 1. 2014.)

UNESCO IITE (2010) Cloud Computing in Education, Policy Brief, http://iite.unesco.org/pics/publications/en/files/3214674.pdf (28. 1. 2014.)

Zemsky, R., Massy, W. (2006) Ometena inovacija, Što se desilo e-learningu i zašto?, Edupoint, http://edupoint.carnet.hr/casopis/47/clanci/3 (3. 1. 2014.)

5 Best SaaS Applications of 2013, http://saasaddict.walkme.com/5-best-saas-applications-of-2013/ (31. 1. 2014.)

CDW's 2013 State of the Cloud Report, http://www.cdwnewsroom.com/wp-content/uploads/2013/02/CDW_2013_State_of_The_Cloud_Report_021113_FINAL.pdf (15. 4. 2014.)

Elena Krelja Kurelović[1]
Jasminka Tomljanović[2]
Krešimir Bronić[3]

Original scientific paper
UDK 004.78
378

USAGE OF CLOUD APPLICATIONS BY STUDENTS[4]

ABSTRACT

Cloud computing is an increasingly accepted trend in the IT sector and it is widely used in various fields including education. This paper focuses on the possibilities of using cloud computing in higher education in general, and it considers students' readiness to use this innovative technology. The paper deals with one of the models of cloud computing, named "software as a service" (SaaS), because it is assumed that students are often mobile and that they need access to data and applications from various devices and locations. Motivation and perception are two important factors contributing to the acceptance of new technologies. For that reason, the objectives of this paper are to determine students' motivation to use and their perception of cloud applications and the level of use of those applications, so as to establish a correlation between these variables. A statistically significant difference in students' motivation to use and their perception of cloud applications between the students of Information Sciences and those of other study programmes of the Polytechnic of Rijeka has been determined. The number of computers and mobile devices with Internet access has indicated a statistically significant difference with regard to motivation to use cloud services. However, the number of computers/mobile devices used has had no impact on the perception. The statistically significant positive correlation between the variables motivation – use of cloud applications, and perception – use of cloud application has also been confirmed. Among the best known cloud applications, the most used are those for communication and socializing, and the least used are office applications.

***Key words**: cloud computing, SaaS, motivation, perception, usage*

[1] MSc, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: elena@veleri.hr
[2] MSc, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: jasminka.tomljanovic@veleri.hr
[3] Mag. educ. of polytechnic, Assistant, High school Mate Balote Poreč, Karla Huguesa 6, Poreč, Croatia. E-mail: kresimir.bronic@pu.t-com.hr
[4] Received: 14. 2. 2014.; accepted: 5. 5. 2014.

Marino Golob[1]
Tina Sirotić[2]
Martin Golob[3]

Prethodno priopćenje
UDK 338.484(457 Umag)

ISTRAŽIVANJE KVALITETE I RAZINE ZADOVOLJSTVA TURISTA TURISTIČKOM PONUDOM[4]

SAŽETAK

Turistička destinacija Umaga, gradića na sjeverozapadnoj obali Istre, ima svoje komparativne prednosti, široku ponudu hotelskih i ugostiteljskih objekata, raznovrsnu izvanpansionsku ponudu te velik broj sportskih, kulturnih i turističkih manifestacija. Ovim radom htjelo se dati uvid u razinu zadovoljstva turista turističkom destinacijom grada Umaga, kao i utvrditi kvalitetu turističke ponude u destinaciji. U tu svrhu provedeno je empirijsko istraživanje na području grada Umaga koje je obuhvatilo 200 ispitanika u razdoblju između 1. lipnja i 30. rujna 2012. godine. Korištena metoda ispitivanja bila je metoda samopopunjavanja ankete. Provedeno istraživanje imalo je za cilj istražiti i utvrditi razinu zadovoljstva turista turističkom ponudom ove destinacije, kako bi se na taj način došlo do temelja za stvaranje, nadopunjavanje i poboljšanje postojeće turističke ponude i marketinških aktivnosti ove istarske turističke destinacije, odnosno kako bi se na temelju pribavljenih podataka moglo doći do zaključaka o kvaliteti turističke ponude u turističkoj destinaciji grada Umaga. Analizom pribavljenih podataka i odgovorom na postavljeno istraživačko pitanje dobiven je zaključak o zadovoljstvu turista turističkom ponudom destinacije grada Umaga. Turisti su pojedine elemente turističke ponude ocijenili visokim ocjenama, te je njihovo zadovoljstvo na visokoj razini, no još uvijek postoji prostor za unaprjeđenje.

***Ključne riječi**: istraživanje, kvaliteta, zadovoljstvo, turistička ponuda*

1. UVOD

Turizam predstavlja jedan od najvažnijih ekonomskih sektora u zemljama diljem svijeta, a pogotovo u Republici Hrvatskoj. Turizam u Republici Hrvatskoj ima izrazito visok udio u nacionalnom proizvodu (Ministarstvo turizma RH, 2013) koji je isto tako praćen visokim udjelom zapošljavanja, stoga predstavlja izrazito važan gospodarski sektor. Kombinacija prirodnih ljepota i, posebice, prirodnih raznolikosti, kulturnih i drugih dobara te iznimno povoljnog geografskog položaja koju koristi turistička industrija ključ je brže integracije Republike Hrvatske u globalne ekonomske tokove i društvo. Utjecaj turizma, izravni i neizravni, na poslovanje poslovnih subjekata i razvoj gospodarstva u cjelini karakteriziraju turizam kao glavni pokretač investicija i generator gospodarskog rasta u prošlim, ali i budućim razdobljima (Madjar, Sladoljev, 2011). Velik dio

[1] Mr. sc., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* mgolob@veleri.hr
[2] Stručna specijalistica poduzetništva, studentica.
[3] Univ. spec. oec., student.
[4] Datum primitka rada: 17. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

proizvodne i prerađivačke industrije, zajedno s industrijama komunikacije, cestovnog, avionskog i brodskog prometa u Republici Hrvatskoj, izravno je određen turističkim tržištem.

Turističko tržište, s druge strane, iznimno je dinamično i pokazuje visok stupanj konkurentnosti (World Economic Forum, 2013). Potrebno je neprekidno praćenje i evaluacija postojeće turističke ponude, kao i konstantni napori u dostizanju standarda turističke ponude i postavljanju novih razvojnih ciljeva, poput proširenja turističke sezone, stvaranja turističkih proizvoda koji omogućuju zahvaćanje širih tržišnih segmenata, daljnji razvoj infrastrukture i dr. Takav razvoj potrebno je uskladiti na svim razinama, od lokalne, regionalne pa sve do državne razine. U tom pogledu sudionici koji čine turističku ponudu turističkih destinacija moraju marketinškim aktivnostima zadovoljiti turiste i njihova očekivanja, te je shodno tome potrebno stalno prilagođavati postojeću turističku ponudu turističke destinacije u odnosu na odabrani tržišni segment. Provođenjem istraživanja može se prikupiti dovoljno informacija za razvoj turističkih destinacija u pogledu unaprjeđenja kvalitete atributa turističke ponude turističke destinacije i stvaranje prepoznatljive marke turističke destinacije. Ishod takvih pozitivnih kretanja u završnici rezultira priljevom posjetitelja i stvaranjem zadovoljnog turista/klijenta. Ovim radom pokušat će se dati doprinos razvoju turističke ponude u Republici Hrvatskoj, što je i svrha rada i provedenog istraživanja. Istraživanje provedeno na području grada Umaga na sjeverozapadu Istre ima za cilj istražiti i utvrditi razinu zadovoljstva turista turističkom ponudom ove destinacije, kako bi se na taj način došlo do temelja za stvaranje, nadopunjavanje i poboljšanje postojeće turističke ponude i marketinških aktivnosti te istarske turističke destinacije, odnosno kako bi se na temelju pribavljenih podataka moglo doći do zaključaka o kvaliteti turističke ponude u turističkoj destinaciji grada Umaga. U sljedećim dijelovima rada dan je kratak prikaz teorijskih pretpostavki vezanih uz spomenutu temu i prikazani rezultati provedenog empirijskog istraživanja.

2. KVALITETA U TURIZMU I ZADOVOLJSTVO TURISTA

Prema definiciji Svjetske turističke organizacije (UNWTO, 2014) kvalitetom u turizmu smatra se rezultat procesa koji implicira zadovoljstvo svim legitimnim potrebama za proizvodima i uslugama u turističkim destinacijama, zadovoljstvo koje nastaje ispunjenjem zahtjeva i očekivanja korisnika/turista, te zadovoljstvo odnosom cijene i vrijednosti. Navedena organizacija definira i odrednice kvalitete u turizmu kao što je sigurnost, budući da finalni turistički proizvod ne smije predstavljati opasnost za živote ljudi ili opasnost za imovinu, a pritom se misli na poštovanje standarda sigurnosti i zaštite koji su propisani zakonom. Nadalje, higijena i poštovanje propisanih sanitarnih propisa jedna su od temeljnih odrednica kvalitete u turizmu. Standardi čistoće smještajnih, ugostiteljskih i drugih objekata trebaju se poštovati kako bi se dosegla potrebna razina kvalitete. Uklanjanje fizičkih, komunikacijskih i svih drugih prepreka, odnosno uspostavljanje pristupačnosti destinacije, iznimno je važno u postizanju potrebne razine kvalitete. Nedvosmislenost, transparentnost i autohtonost turističke ponude važne su odrednice kvalitete u kojima se u obzir uzima istinitost i točnost informacija o ponudi koja se nudi, kao i o izvornosti ponuđenog sadržaja uz poštovanje obilježja kulture i tradicije destinacije. Sve navedene odrednice kvalitete u turizmu upotpunjuje potreba za skladnošću

turističke djelatnosti s okolinom u kojoj obitava lokalno stanovništvo i s prirodnim okolišem. Kvaliteta u turizmu i održivost inherentno su povezani (UNWTO, 2014) te se u tom smislu može postaviti i širi koncept kvalitete u turizmu koji podrazumijeva konvencionalnu aplikaciju upravljanja kvalitetom u turizmu kao baze za postizanje kvalitete uz dodavanje prirodnog i kulturnog okruženja. Navedene stavke predstavljaju ukupnu kvalitetu turističkog doživljaja, odnosno iskustva turista. Drugim riječima, dok se kvaliteta izravno promatra kroz aktivnosti turista, održivost predstavlja okvir djelovanja i upravljačke procese koji se odvijaju u pozadini te omogućavaju postizanje visoke kvalitete turističke ponude i zadržavanje ili poticanje gosta na ponovni posjet.

Razina zadovoljstva i, posebice, iskustvo turista prilikom posjeta turističkoj destinaciji, čine završni proizvod turističke destinacije (Middleton, 1994; Smith, 1994). Zadovoljstvo je ponajprije razlog zbog kojeg turisti posjećuju turističke destinacije te je zadovoljstvo determinanta kvalitete turističke posjete, kao i sama kvaliteta turističke ponude određene turističke destinacije, odnosno sposobnost i performanse turističkih subjekata i djelatnika u okvirima pružanja zadovoljavajuće usluge korisnicima, tj. turistima. Zadovoljstvo korisnika mjera je koja se koristi pri određivanju zaključka o tome na koji način završni proizvod odgovara na zahtjeve i potrebe određene skupine korisnika (Hill, Alexander, 2003). Sukladno tome, zadovoljstvo korisnika može se definirati i na drugi način: zadovoljstvo je rezultat usporedbe očekivanja korisnika/potrošača i stvarne percepcije atributa završnog proizvoda. Shodno navedenome, zadovoljstvo nastupa kada očekivanja budu premašena ili kada budu zadovoljena (Crompton, Love, 1995). U literaturi vezanoj uz turizam i ugostiteljstvo zadovoljstvo se nastoji promatrati kao stav koji nastaje nakon proživljavanja određenog iskustva (Pearce, 2005) i kao emocionalno stanje koje nastaje kao rezultat doživljaja turističkog proizvoda (Crompton, Love, 1995). Turisti, kao i ostali korisnici usluga, imaju inicijalna očekivanja o kvaliteti usluge koja im se nudi u određenoj turističkoj destinaciji. Očekivanja se formiraju pretežito kroz informacije dostupne kroz komercijalne poruke, brošure, masovne medije te putem neformalnih informacija dobivenih od prijatelja, srodnika i bliskih osoba. Opseg do kojeg se tako formirana očekivanja ispune u završnici će determinirati razinu zadovoljstva turista. Ako cjelokupno iskustvo tijekom ili nakon posjeta određenoj turističkoj destinaciji ispuni ili premaši inicijalna očekivanja turista, smatrat će se da je razina zadovoljstva turista postignuta. No ako percipirano iskustvo ne uspije ispuniti ili premašiti inicijalna očekivanja turista, tada će se smatrati da zadovoljstvo turista nije postignuto. Može se reći da će zadovoljni turist prije preporučiti turističku destinaciju drugima, te je takva forma najjeftiniji i najučinkovitiji oblik marketinga i promocije. Nadalje, zadovoljstvo turista pridonosi povećanju stope zadržavanja turista kroz njihovu lojalnost i pokroviteljstvo, što zauzvrat pomaže u realizaciji ekonomskih ciljeva poput povećanja broja turista i ukupnih prihoda (Hapenciuc, Condratov, 2007). Posljedično se javlja pozitivna asocijacija između zadovoljstva turista i dugoročnog ekonomskog uspjeha turističke destinacije (Hapenciuc, Condratov, 2007). No cjelokupno zadovoljstvo turista ne temelji se samo na kvaliteti turističke ponude, nego i na cijeni i percipiranoj vrijednosti turističkog proizvoda i/ili usluge. Budući da zadovoljstvo turista turističkom destinacijom može u velikoj mjeri utjecati na izbor destinacije potencijalnih turista, zadovoljstvo turista

promatra se kao važan indikator performansi turističke destinacije i njezinog financijskog rezultata (Vetitnev et al., 2013). Zadovoljstvo turista smatra se jednom od primarnih varijabli održavanja kompetitivnosti u turističkom sektoru, budući da utječe na izbor destinacije te potrošnju proizvoda i usluga i odluku o ponovnom vraćanju u turističku destinaciju (Kozak, Rimmington, 2000). Iz svega navedenog može se naglasiti izuzetna važnost prilagođavanja turističke ponude u turističkim destinacijama potrebama i očekivanjima potencijalnih turista. Ako postoji evidentna nesposobnost ili nemogućnost prilagodbe tržišnim segmentima, dolazi do jaza između očekivane vrijednosti i naknadnog iskustva koje je doživio turist u turističkoj destinaciji, što rezultira nezadovoljstvom turista i smanjuje izglede za njegov ponovni povratak/ponovnu kupnju.

Zadovoljstvo turista može se dovesti u vezu sa samom kvalitetom turističke destinacije, odnosno kvalitetom cjelokupne turističke ponude u određenoj destinaciji. Turistička destinacija posjeduje kvalitetu, odnosno, turističku se destinaciju smatra kvalitetnom ako cjelokupna turistička usluga, odnosno ponuda, zadovoljava potrebe turista i naposljetku ispunjava njihova očekivanja (Pirija, 2003). Današnja očekivanja turista i potencijalnih posjetitelja turističkih destinacija veća su nego u prijašnjim razdobljima. U potrebama suvremenih turista prevladavaju različitost, kontrast, bogatstvo sadržaja i oblika, noviteti i inovativni proizvodi s naglaskom na kvaliteti (Pirija, 2003:35). Postizanje navedenih elemenata pretpostavlja i postizanje nove kvalitete u svim aspektima turističke ponude. Postojanje odnosa između kvalitete usluge, odnosno kvalitete turističkog proizvoda i zadovoljstva korisnika, turista, može se uočiti u odnosu kako povećanje kvalitete turističke ponude utječe na povećanje zadovoljstva turista turističkom destinacijom, tj. njezinom turističkom ponudom i naposljetku njezinim uspjehom (Suneeta, Koranne, 2014), posebice, povećanom broju posjetitelja/noćenja i financijskim rezultatom. Takav razvoj kvalitete pridonosi pojedinim komponentama destinacije, pogotovo imidžu turističke destinacije i samoj profitabilnosti koja se ostvaruje lojalnošću turista i usmenom predajom. Navedeno pridonosi i povećanom priljevu novih turista koji su privučeni stabilnom i visokom reputacijom kvalitetnog iskustva (Suneeta, Koranne, 2014). Nastavno, u svemu navedenom postavljeno je istraživačko pitanje: *Jesu li posjetitelji turističke destinacije grada Umaga zadovoljni turističkom ponudom*?

3. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA

Predmet ovog rada su rezultati empirijskog istraživanja razine zadovoljstva turista turističkom ponudom turističke destinacije grada Umaga i njegove bliže okolice. Turistička destinacija grada Umaga nalazi se na sjeverozapadnom dijelu Istarske županije. Rezultati provedenog empirijskog istraživanja prikazat će se tabelarno te će se u popratnom tekstu prikazati analiza, odnosno glavni rezultati provedenog istraživanja dobiveni anketiranjem turista u toj istarskoj destinaciji.

3.1 Definiranje problema i metodologija istraživanja

Zadovoljstvo turista u nekoj turističkoj destinaciji važan je čimbenik za razvoj same destinacije, posebice zbog toga što se na temelju (ne)zadovoljstva gostiju, donose odluke za poboljšanje turističke ponude same destinacije. Kako bi se pribavili podaci o zadovoljstvu turista, provodi se

istraživanje tržišta. Istraživanje tržišta služi kao nužna podloga za modifikaciju osnovnih elemenata postojećeg turističkog proizvoda u sklopu napora da sudionici u turističkoj ponudi prilagode svoj proizvod potrebama potrošača, odnosno turista (Senečić, Vukonić, 1997). Svaka turistička destinacija, odnosno ''proizvod" koji se nudi turistima, mora se stalno prilagođavati njihovim potrebama i željama, kako bi ostala konkurentna, te se shodno tome provodi istraživanje razine zadovoljstva turista.

Korištena metoda ispitivanja bila je metoda samopopunjavanja ankete. Anketni upitnik podijeljen je turistima na području grada Umaga. Anketa je podijeljena u Turističkoj zajednici grada Umaga, na administrativnom mjestu za rad sa strankama Lučke kapetanije Pula (ispostava Umag), te u jednoj putničkoj agenciji u Umagu. Budući da se anketa provodila među nerezidentima Republike Hrvatske, prevedena je na engleski i talijanski jezik kako bi bila razumljiva ispitanicima. Talijanski jezik odabran je zbog učestalosti talijanskih turista na području Istre i grada Umaga, dok je engleski jezik odabran zbog rasprostranjenosti njegove uporabe.

Anketni upitnik sastoji se od 4 dijela. U prvom dijelu traže se podaci o tome kako su ispitanici dobili informacije o Umagu, te koji su razlozi da su ga odabrali kao svoje odredište. Drugi dio pitanja je o njihovom zadovoljstvu atributima turističke ponude tijekom boravka u Umagu. Ispitanici su na raspolaganju imali Likertovu ljestvicu s odgovorima od 1 do 5, gdje 1 znači „nevažno", a 5 „izrazito važno" u ispitivanju njihovih preferencija i želja, a ''vrlo nizak" i ''vrlo visok" pri njihovu određivanju stupnja zadovoljstva pojedinim atributima turističke ponude prilikom boravka u gradu Umagu. U trećem djelu se istražuje nudi li Umag dovoljno informacija, proizvoda i usluga turistima, odnosno razinu zadovoljstva turista tim atributima turističke ponude. Na kraju, četvrti dio pitanja vezan je uz sociodemografski status ispitanika, odnosno preispituje spol, dob i nacionalnost ispitanika. Istraživanje je provedeno u periodu od 1. lipnja do 30. rujna 2012. godine. Empirijsko istraživanje provelo se na uzorku od 200 ispitanika. Turisti, odnosno ispitanici dobrovoljno du sudjelovali u istraživanju koje je bilo anonimne prirode. Anketni upitnik sastavljen je po uzoru na srodna istraživanja u Republici Hrvatskoj, te se pri sastavljanju posebno vodilo računa o specifičnim karakteristikama turističke destinacije grada Umaga.

3.2 Sociodemografski profil turista

Sociodemografski profil turista u provedenom empirijskom istraživanju sagledao se kroz varijable spola ispitanika, odnosno turista, zemlje podrijetla i njihove starosne strukture. U razdoblju u kojem je istraživanje provedeno, u turističkoj destinaciji grada Umaga boravilo je više stranih (76,5 %) nego domaćih turista (23,5 %). Sukladno strukturi turista koji su obuhvaćeni istraživanjem, anketirano je 28,5 % turista iz Italije, 17,5 % turista iz Slovenije, 7 % i 6 % turista iz Njemačke i Austrije, dok je 17,5 % ispitanika bilo s ostalih emitivnih tržišta. Tržišta Italije, Slovenije, Njemačke i Austrije predstavljaju ciljna tržišta hrvatskog turističkog sektora (Strategija razvoja turizma RH do 2020., 2013) zbog svoje blizine i tradicije dolaska turista s tih tržišta te je sukladno tome i njihov broj veći od broja turista iz ostalih zemalja.

Gledajući ostala obilježja, provedenim empirijskim istraživanjem utvrđeno je da je najveći broj turista koji posjećuje turističku destinaciju grada Umaga u dobnoj skupini od 26 do 35 godina (30 %) a znatno manji

udio turista u dobnim skupinama od 36 do 45 godina te od 46 do 55 i više godina. Također, utvrđen je i postotak od 25 % turista u dobnoj skupini od 19 do 25 godina. Navedeno navodi na zaključak da su u vremenskom razdoblju u kojem je provedeno empirijsko istraživanje uglavnom boravili turisti mlade životne dobi i da njima treba prilagođavati turističku ponudu u turističkoj destinaciji grada Umaga. Udio turista u dobnoj skupini od 55 godina i više u promatranom razdoblju iznosio je 13,5 %, što je relativno manji postotak od ostalih relevantnih dobnih skupina te takav podatak navodi da bi bilo poželjno ovoj dobnoj skupini usmjeravati ponudu u vremenskim razdobljima izvan glavnih sezonskih mjeseci. U tablici 1. dan je prikaz broja ispitanika prema spolu, starosnoj skupini i zemlji podrijetla.

Tablica 1. Spol, starosna skupina i zemlja podrijetla turista obuhvaćenih uzorkom

OPIS	BROJ ISPITANIKA	
	Apsolutno	Relativno (%)
SPOL		
Muški	104	52
Ženski	96	48
STAROSNA SKUPINA (u god.)		
0 - 18	4	2
19 - 25	50	25
26 - 35	60	30
36 - 45	31	15,5
46 - 55	28	14
55 i više	27	13,5
ZEMLJA PODRIJETLA		
Hrvatska	47	23,5
Italija	57	28,5
Slovenija	35	17,5
Njemačka	14	7
Austrija	12	6
Ostale zemlje	35	17,5

Izvor: rezultati provedenog istraživanja

Struktura ispitanika prema spolu u provedenom empirijskom istraživanju bila je pretežito ujednačena, no ipak je obuhvaćen veći broj ispitanika muškog spola (52 %). Provedenim empirijskim istraživanjem također je utvrđeno da je najveći broj turista u turističku destinaciju grada Umaga došao s partnerom (32 %) ili prijateljima (32 %), što odgovara mladoj starosnoj skupini koja je najzastupljenija u ljetnim sezonskim mjesecima. Nadalje, 27,5 % turista obuhvaćenih provedenim empirijskim istraživanjem došlo je u turističku destinaciju u pratnji obitelji, a tek 8,5 % turista na odmor je došlo individualno.

3.3 Motiv i način dolaska u destinaciju

U ovom dijelu rada prikazani su pokazatelji o motivima i načinu dolaska turista u turističku destinaciju grada Umaga. Rezultati provedenog empirijskog istraživanja vezani uz cjelinu dani su u tablici 2, izraženi aritmetičkom sredinom i standardnom devijacijom, odnosno, prikazala se prosječna ocjena važnosti pojedinog motiva pri odabiru dolaska u turističku destinaciju.

Obradom podataka dobivenih provedenim empirijskim istraživanjem dobiveni su motivi kojima se vode turisti prilikom dolaska u turističku destinaciju grada Umaga. Iz tablice 2. vidljivo je da je glavni motiv dolaska turista u turističku destinaciju sunce, more i klima. Taj motiv slijede dobra hrana i udoban smještaj uz ljepote prirode i upoznavanje novih mjesta.

Tablica 2. Motivi dolaska turista u turističku destinaciju

MOTIV DOLASKA	M	SD
Sunce, more, klima	4,20	0,83
Dobra hrana	4,09	0,85
Udoban smještaj	3,91	0,26
Ljepota prirode	3,87	2,04
Upoznavanje novih mjesta	3,82	0,97
Dobra prometna povezanost	3,72	0,48
Šetnje i razgledavanje	3,65	2,06
Dobra usluga u trgovinama	3,55	0,93
Zabava, izlasci i ples	3,47	1,28
Mir, tišina, bez buke i gužve	3,40	0,84
Izbor kratkih izleta	3,28	1,05
Pasivno odmaranje	3,20	1,21
Bavljenje sportovima	3,20	1,76
Povijesne zanimljivosti	3,16	0,49

Izvor: rezultati provedenog istraživanja

Pasivno odmaranje, bavljenje sportovima i povijesne zanimljivosti nisu važan motiv dolaska turista prilikom odabira turističke destinacije grada Umaga. Zabava, noćni izlasci i ples nalaze se u sredini tablice te ne predstavljaju najvažniji motiv dolaska, usprkos tome što su mlađe starosne skupine najzastupljenije u turističkoj destinaciji grada Umaga. Navedeno navodi na zaključak u smislu poboljšavanja turističke ponude. U tablici 3 prikazan je odabir turističke destinacije grada Umaga. Na pitanje ''Zašto ste odabrali Umag kao svoje odredište?" ispitanici su imali ponuđena tri odgovora.

Tablica 3. Odabir turističke destinacije

OPIS	%
Zbog preporuke prijatelja	49
Već sam boravio u Umagu	26
Zbog povoljne ponude	25

Izvor: rezultati provedenog istraživanja

Iz tablice je vidljivo da je gotovo polovica ispitanika (49 %) odgovorila da je u turističku destinaciju grada Umaga došlo zbog preporuke prijatelja, pogotovo što je za najveći broj turista turistička destinacija grada Umaga vjerojatno nepoznata. Iskustvo prijatelja i ostalih bliskih osoba od neprocjenjive je važnosti. Ostala polovica ispitanika došla je jer su već boravili u Umagu i svidjelo im se te zbog povoljne ponude (blizina turističke destinacije, povoljne cijene). U tablici 4 dan je prikaz načina dolaska, odnosno organizacije dolaska turista u turističku destinaciju grada Umaga i predstavljeni rezultati istraživanja na pitanje ''Na koji način je organiziran vaš dolazak u Umag?"

Tablica 4. Organizacija dolaska u turističku destinaciju

OPIS	%
Vlastita organizacija	69
Turistička agencija	12
Ostalo	19

Izvor: rezultati provedenog istraživanja

Iz tablice 4 vidljivo je da je velika većina anketiranih turista pristigla u turističku destinaciju grada Umaga u vlastitoj organizaciji (69 %), što se može opravdati činjenicom da velika većina turista dolazi iz ciljnih tržišta koja u relativnoj blizini destinacije te nisu potrebni veliki napori ili organizacija putovanja na neki drugi način (poput dolaska u organizaciji turističke agencije, 12 %). U tablici 5 prikazan je smještaj anketiranih turista u turističkoj destinaciji grada Umaga.

Tablica 5. Smještaj u turističkoj destinaciji

OPIS	%
Privatni apartman	42
Hotel	12
Kamp	12
Apartman u hotelu	6
Ostalo	28

Izvor: rezultati provedenog istraživanja

Navedeni podaci iskazuju da većina ispitanika bira privatni apartman uz more. 28 % ispitanika za smještaj koristi „ostalo", pod čime se posebno mislilo na vlastite apartmane,

paušalna mjesta u kampovima ili jahte. Najmanje posjetitelja je za boravak u Umagu odabralo apartman u hotelu, dok su hoteli (sobe u hotelima) i kampovi podjednako zastupljeni s 12 %. S obzirom na to da Umag kao turistička destinacija svojim posjetiteljima nudi velik broj smještaja u privatnom vlasništvu, rezultati istraživanja odgovaraju trenutnoj situaciji. U tablici 6 prikazani su izvori informacija o turističkoj destinaciji grada Umaga.

Tablica 6. Izvori informacija o turističkoj destinaciji

OPIS	%
Boravio sam ovdje i prije	37
Bliske osobe	34
Turistička agencija	9
Mediji (TV, novine, internet...)	5
Prospekt, brošura	4
Ostalo	11

Izvor: rezultati provedenog istraživanja

Iz dobivenih rezultata provedenog istraživanja evidentno je da su informacije o turističkoj destinaciji grada Umaga prije samog dolaska turisti dobili ponajprije od bliskih osoba koje su već boravile u destinaciji ili su upoznate s njome. Iz tablice je također vidljivo i da se turisti rado vraćaju u turističku destinaciju grada Umaga.

3.4 Zadovoljstvo turista atributima turističke ponude

Provedeno empirijsko istraživanje omogućilo je anketiranim turistima u turističkoj destinaciji grada Umaga ocjenu vlastite razine zadovoljstva atributima turističke ponude u turističkoj destinaciji. Turistima je u anketi postavljena Likertova ljestvica prioriteta za sve atribute turističke ponude u turističkoj destinaciji grada Umaga. Ocjena 1 označavala je izrazito nezadovoljstvo pojedinim atributom, a ocjena 5 predstavljala je izrazito visoku razinu zadovoljstva pojedinim atributom turističke ponude.

Tablica 7 prezentira razinu zadovoljstva turista o atributima turističke ponude turističke destinacije grada Umaga. Razina zadovoljstva anketiranih turista u destinaciji Umag analizirana je temeljem rezultata dobivenih iz 200 ispunjenih anketnih upitnika. Turisti su u anketnom upitniku ispitivani o razini zadovoljstva odabranim atributima turističke ponude u turističkoj destinaciji grada Umaga. Rezultati dobiveni obradom podataka sakupljenih istraživanjem prikazani su u tablici 7.

Tablica 7. Zadovoljstvo turista atributima turističke ponude grada Umaga

OPIS	M	SD
PROSTOR, KLIMA, OKOLIŠ		
Klima i vremenske prilike	4,13	0,77
Ljepote prirode i okoliša	3,88	0,072
STANOVNIŠTVO I ZAPOSLENI		
Gostoljubivost stanovništva	4,22	0,72
Ljubaznost zaposlenika u turizmu	3,96	0,72
SIGURNOST		
Osobna sigurnost	3,95	1,02
ORGANIZIRANOST DESTINACIJE		
Ponuda smještaja	4,01	1,18
Turistička signalizacija	3,41	1,03
Prometna dostupnost i povezanost	3,29	1,91
Broj parkirnih mjesta	3,2	1,07
SADRŽAJI		
Kvaliteta hrane u restoranima	3,93	0,75
Bogatstvo gastronomske ponude	3,92	0,78
Mogućnost za sportske aktivnosti	3,89	0,93
Ponuda hrane i pića u trgovinama	3,73	0,91
Mogućnost izbora izleta	3,47	0,42
Raznolikost sadržaja za zabavu	3,47	1,01
Bogatstvo kulturnih manifestacija	3,38	0,89
Kulturno bogatstvo	3,28	0,8
CJELOKUPNA TURISTIČKA PONUDA	3,89	0,65

Izvor: rezultati provedenog istraživanja

Ispitani turisti pokazali su visoku razinu zadovoljstva klimom i vremenskim prilikama koje su u vrijeme njihovog boravka vladale u turističkoj destinaciji. Prosječnu ocjenu 4,13 dobila je klima i vremenske prilike, dok su ljepote prirode i okoliša dobile ocjenu 3,88, što je visoka ocjena u usporedbi s ostalim ocjenama atributa turističke ponude. Dobiveni rezultati čine važnu informaciju za moguće tržišno pozicioniranje turističke ponude grada Umaga u budućnosti. Daljnjim očuvanjem i korištenjem resursa kao što su prirodne ljepote i okoliš moguće je uspostaviti konkurentnost turističke destinacije grada Umaga u dugoročnom razdoblju. Važno je napomenuti da se inicijative glede navedenoga ne bi

smjele poduzimati samo od turističkih poduzeća, već i od ostalih sudionika turističke ponude destinacije grada Umaga, krenuvši od lokalnih snaga i ostalih poslovnih subjekata na tom području pa sve do regionalne i najviše državne razine.

Turisti su također iskazali svoju ocjenu zadovoljstva stanovništvom i zaposlenima u turističkim djelatnostima. Nakon klime i vremenskih prilika (4,13), te ponude smještaja (4,01) daleko najvišu ocjenu razine zadovoljstva turista u destinaciji grada Umaga dobila je gostoljubivost stanovništva (4,22). Ljubaznost zaposlenika u turističkim djelatnostima također je dobila visoku ocjenu (3,96), što potvrđuje istarsku turističku tradiciju i gostoljubiv odnos prema turistima uz postojanje dovoljnog broja obrazovanih turističkih djelatnika. Osobna sigurnost također je visoko ocijenjena u usporedbi s ostalim atributima turističke ponude u turističkoj destinaciji grada Umaga (3,95) što je vrlo važan atribut, odnosno preduvjet prilikom odabira turističke destinacije.

Skupina atributa koji se odnose na organiziranost destinacije ocijenjena je u rasponu ocjena od 3,2 do 4,01. Kod atributa organiziranosti destinacije najvišu ocjenu dobila je ponuda smještaja, što ukazuje na činjenicu da su smještajni kapaciteti dovoljno razvijeni na području turističke destinacije grada Umaga te da turističku ponudu u tom smjeru nije potrebno dodatno razvijati. Ostale ocjene organiziranosti turističke destinacije grada Umaga značajno zaostaju za atributom ponude smještaja, što navodi na zaključak da se turistička signalizacija (3,41), prometna dostupnost i povezanost (3,29) i broj parkirnih mjesta (3,20), kao i ukupna organiziranost turističke destinacije grada Umaga moraju dodatno i sustavno unaprijediti kako bi se u tom pogledu turistička slika destinacije poboljšala.

4. ZAKLJUČAK

Uzimajući u obzir rezultate provedenog empirijskog istraživanja općenito se može utvrditi razina zadovoljstva ispitanih turista na području turističke destinacije grada Umaga. Utvrđeno je da su ispitanici iskazali višu razinu zadovoljstva određenim atributima turističke ponude grada Umaga, te je ocjena cjelokupne turističke ponude destinacije grada Umaga 3,89 uz standardnu devijaciju 0,65. Shodno navedenome, može se odgovoriti na postavljeno istraživačko pitanje i tvrditi da su ispitani turisti vrlo zadovoljni ponudom, međutim još uvijek postoji prostora za unaprjeđenje. Ispitani turisti suglasni su u činjenici da je gostoljubivost domicilnog stanovništva najjači adut turističke destinacije grada Umaga (4,22), uz prirodne atribute (4,13) i ponudu smještajnih kapaciteta (4,01).

Ocjena turističkih i drugih sadržaja kretala se u rasponu od 3,28 do 3,93. Najviše je ocijenjena kvaliteta hrane u restoranima, a najmanju je ocjenu dobilo kulturno bogatstvo tog predjela Istarske županije. Bogatstvo gastronomske ponude dobilo je ocjenu 3,92, što dodatno potvrđuje kvalitetu hrane i visoku razine gastronomije u destinaciji. Ostali sadržaji ocijenjeni su u rasponu od 3,28 do 3,89, što pretjerano ne odstupa od prosječne ocjene cjelokupne turističke ponude u turističkoj destinaciji grada Umaga koja iznosi

3,89. Navedena ocjena navodi na zaključak da još uvijek ima prostora za razvoj turističke destinacije grada Umaga. Održivi razvoj i "sazrijevanje" turističke destinacije, uključujući i turističku destinaciju Umag, treba temeljiti na kvaliteti turističke ponude i raznovrsnosti sadržaja, i to na takav način prilagodbe turističke ponude suvremenim tokovima turističkog tržišta i zahtjevima i željama turista sa svih ciljnih tržišta. Cjelokupnom analizom atributa turističke ponude turističke destinacije grada Umaga prikazano je da su turisti u toj istarskoj destinaciji najviše zadovoljni gostoljubivošću stanovništva, klimom i vremenskim prilikama te ponudom smještaja. Osim razvijene ponude smještajnih kapaciteta iz dobivenih rezultata provedenog empirijskog istraživanja evidentno je da su turisti najmanje zadovoljni organiziranošću destinacije budući da su ocijene dodijeljene turističkoj signalizaciji, prometnoj povezanosti te posebice broju parkirnih mjesta najlošije uz razinu zadovoljstva povijesno-kulturnom ponudom grada Umaga i okolice na sjeverozapadu Istre. Dobivene rezultate moguće je iskoristiti kao podlogu za daljnje unaprjeđenje i podizanje standarda kvalitete turističkog proizvoda na nove, više razine.

U empirijskom istraživanju postoji nekoliko metodoloških ograničenja koja su mogla utjecati na dobivene rezultate, a time i na mogućnost donošenja zaključaka na temelju istih. U istraživanju je korišten anketni upitnik kao obrazac za prikupljanje podataka te je dijeljen posjetiteljima turističke destinacije grada Umaga. Obujam anketnog upitnika bio je otežavajući činitelj dobivanja podataka. Kvalitetna ispuna ankete objektivno je zahtijevala duže vrijeme. Kao nedostatak može se navesti da dio ispitanika koji je ispunjavao ankete, nije ispunio sva pitanja, naročito ona gdje se moralo odvojiti više vremena na pisanje odgovora. Od nedostataka metode provedenog empirijskog istraživanja može se navesti i tendencija ispitanika da ne odgovaraju ono što misle, već ono za što smatraju da je prihvatljivo. Kao još jedno ograničenje provedenog istraživanja može se navesti nereprezentativnost uzorka ispitanika za temu istraživanja. Osim malog broja ispitanika (200), većina ih je starosne dobi od 19 do 35 godina (55 % ispitanika), pa se može pretpostaviti da su to mlađi ljudi u godinama kada pokazuju najveći interes za zabavne aspekte ponude, te ne pokazuju visok interes za sportske aktivnosti ili kulturni aspekt putovanja ili godišnjeg odmora. Na stavove o turističkoj destinaciji utječe i životni stil, znanje i obrazovanje ispitanika, pa i godine, a prema rezultatima istraživanja može se zaključiti da ispitanici u većini dijele iste vrijednosti. S obzirom na vremensko ograničenje i ostale uvjete, anketa je prevedena na engleski i talijanski jezik. Zbog toga je bilo teško ispitati sve posjetitelje, jer ne služe se svi jednako dobro engleskim jezikom. Prilikom provođenja empirijskog ispitivanja, odnosno dijeljenja anketnih upitnika na ispunjavanje, podosta posjetitelja nije moglo, htjelo, bilo zainteresirano ili nije imalo vremena za ispunjavanje anketnog upitnika zato što su na godišnjem odmoru ili poslovnom putu.

Preporuke za daljnja istraživanja zadovoljstva posjetitelja turističke destinacije, nadovezuju se na ograničenja koja su se pojavila pri istraživanju. Za izradu kvalitetnog upitnika potrebno je imati znanje, informacije i iskustvo. Uz primjeren problem istraživanja, dobro konstruiran i provjeren upitnik, reprezentativan uzorak ispitanika i uz pravilno prikupljanje podataka te prikladnu analizu podataka, anketnim upitnik se može doći do korisnih podataka. Ako

su pitanja jasno i precizno postavljena, anketni upitnik se može, kao i u ovom slučaju, obavljati pismenim putem jer ispitanicima nije potrebna pomoć oko rješavanja ankete. Osim toga, ispitanici se osjećaju sigurnije kada se ispitivanje obavlja pismenim putem, zbog veće anonimnosti, pa tako mogu dati iskrenije odgovore, što vodi boljim rezultatima. Potrebno je obuhvatiti što veći broj ispitanika koji se razlikuju po svojim demografskim i socijalnim karakteristikama, te ispitati više različitih dobnih skupina i skupina različitog podrijetla, kako bi prikupljeni podaci bili relevantniji i vjerodostojniji.

LITERATURA

Crompton, J., Love, J. L. (1995) *The Predictive Validity of Alternative Approaches to Evaluating Quality of a Festival*, Journal of Travel Research, Vol. 34, str. 11–24, u: Nowacki, M. (2013) *The Determinants of Satisfaction of Tourist Atractions` Visitors*, Poznan, Active, str. 18-19

Hapenciuc, C. V., Condratov, I. (2007) *Theoretical Framework for Quality Evaluation of Tourism-Related Websites Services*, Economy Informatics, Vol. 1-4, str. 52-58

Hill, N., Alexander, J. (2003) *Pomiar satysfakcji i lojalności klientów*. Kraków: Oficyna Eko-nomiczna Grupa Wolters Kluwer. str. 355, u: Nowacki, M. (2013) *The Determinants of Satisfaction of Tourist Atractions` Visitors*, Poznan, Active, str. 18-19

Kozak, M., Rimmington, M. (2000) *Tourist Satisfaction with Mallorca, Spain as an Off-Season Holiday Destination*, Journal of Travel Research, Vol. 38(3), str. 260-269

Madjar, M.L., Sladoljev, J. (2011) *Strateški plan razvoja hrvatskog turizma*, str. 4-5, dostupno na: www.vijesti.hssd.hr/.../Strateski%20plan%20arzvoja%20hrvtskog%20turizma.doc (17. 4. 2014.)

Middleton, V. T. C. (1994) *Marketing in Travel and Tourism*, Oxford: Butterworth-Heinemann. str. 487

Ministarstvo turizma Republike Hrvatske (2013) *Turizam u brojkama 2012*, Zagreb, Ministarstvo turizma Republike Hrvatske, str. 46-47

Ministarstvo turizma Republike Hrvatske (2013) *Strategija turizma RH do 2020*, Zagreb, Ministarstvo turizma Republike Hrvatske

Pearce, P. L. (2005) *Tourist behaviour: Themes and conceptual schemes*. Clevedon, Channel View, str. 256, u: Nowacki, M. (2013) *The Determinants of Satisfaction of Tourist Atractions` Visitors*, Poznan, Active, str. 18-19

Pirija, D. (2003) *Standardi u turističkom ugostiteljstvu*, Šibenik: Visoka škola za turizam Šibenik, p. 35

Senečić, J., Vukonić, B. (1997) *Marketing u Turizmu*, Zagreb, Mikrorad d. o. o., str. 77

Smith, S. L. J. (1994) *The Tourism Product*, Annals of Tourism Research, Vol. 21(3). str. 582–595

Suneeta, B., Koranne, S. (2014) *Conceptual Study of Relationship between Service Quality and Customer Satisfaction*, International Research Journal of Social Sciences, Vol. 3(2), str. 9-14, dostupno na: www.isca.in, 18. 4. 2014.

UNWTO (2014) *Quality in Tourism*, web stranica, dostupno na: sdt.unwto.org/en/content/quality-tourism, 18. 4. 2014.

Vetitnev, A., Romanova, G., Matushenko, N., Kvetenadze, E. (2013) *Factors AffectIng DomestIc Tourists' DestInatIon SatisfactIon: The Case of RussIa Resorts*, World Applied Sciences Journal, Vol. 22 (8), str. 1162-1173

World Economic Forum (2013) *The Travel & Tourism Competitiveness Report 2013*, Geneva, World Economic Forum, str. 10, dostupno na: www.weforum.org/issues/travel-and-tourism-competitiveness, 17. 4. 2014.

Marino Golob[1]
Tina Sirotić[2]
Martin Golob[3]

Preliminary communication
UDK 338.484(457 Umag)

TOURIST SATISFACTION AND QUALITY RESEARCH OF TOURIST OFFER[4]

ABSTRACT

Umag, a town on the northwest coast of Istria, has a number of comparative advantages as a tourist destination, a wide range of hotels and restaurants, diverse accommodation options and a large number of sporting, cultural and other tourist events. The purpose of this paper is to provide insight into the level of satisfaction of tourists with Umag as a tourist destination, and to determine the level of quality of the tourism offer in the destination. For this purpose, empirical research was conducted in the area of Umag, which included 200 respondents in the period from 1 June to 30 September 2012. The method of self-completion questionnaires was used. The aim of the conducted research was to investigate and determine the level of tourists' satisfaction with the tourist offer of this destination in order to provide a foundation for creating, updating and improving the existing tourism and marketing activities of this Istrian tourist destination, so that conclusions can be made, based on the obtained data, about the quality of the tourism offer in the tourist destination of Umag. The analysis of the collected data provided an answer to the research question wherefrom the conclusion regarding the satisfaction of tourists with the tourist destination of Umag was derived. Tourists rated individual elements of the tourist offer very high, thus showing their satisfaction, but there still remains room for improvement.

***Keywords**: research, quality, satisfaction, tourist offer*

[1] MSc, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: mgolob@veleri.hr
[2] Professional Specialist of Entrepreneurship, Student.
[3] Univ. spec. oec., student.
[4] Received: 17. 2. 2014.; accepted: 5. 5. 2014.

Sabrina Šuman[1]
Maja Gligora Marković[2]
Berta Jadro[3]

Preliminary communication
UDK 65.012.123

DECISION SUPPORT AND BUSINESS INTELLIGENCE – WHAT NEEDS TO BE LEARNT?[4]

ABSTRACT

Decision makers should have comprehensive knowledge to be able to make quality decisions. The development of intelligent technologies and specific supporting decision tools has been accelerated during the last ten years, so managers of all strategic levels should keep track of this development and have timely access to adequate modalities and quantity of knowledge necessary for the optimal business management. The domain of the required knowledge is broader at higher managerial positions, while at lower positions it becomes narrow so more profound knowledge of certain area is required. Consequently, managers should know what basic knowledge employees should develop on different hierarchical levels. The purpose of this paper is to provide insight into the domain of Decision Support Systems, which are, according to the authors, essential for understanding the importance and purpose of their usage. The following concepts have been discussed, due to their proved importance in Decision Support Systems, according to the previously analyzed corresponding literature: strategic methods, methods oriented to performance, measurements, techniques and specific tools. The paper elaborates on reasons of their usage, as well their interconnections. The dynamics of these concepts' development during the last two decades has also been analyzed. The correlation analysis indicated which domains have been developed with similar dynamics. This review should serve as a guidebook for further analysis of the domain of concepts related to Decision Support System, but also to all individuals interested in gaining the complete insight into a wider area related to Decision Support Systems, including students, managers and others.

Key words: *Decision Support System, Business Intelligence, Business Excellence, Total Quality, Knowledge Management*

1. INTRODUCTION

Today's business is exceptionally dynamic: shorter product life cycles, distributed units of companies, complex supply chains, strong competition on a global level, enormous overflow of information, accelerated ICT development. Managers should continuously adjust to competitive challenges and seek new ways of exploiting technology to act faster and smarter, bearing in mind the satisfaction of clients and other participants (Power, 2013). Though the development of technology could become an obstacle for managers, knowledge of new technologies and the

[1] Mag. edu. math. et inf., Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: ssuman@veleri.hr
[2] MSc, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: mgligoram@veleri.hr
[3] Professional Bachelor of Informatics, student, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: bjadro@veleri.hr
[4] Received: 20. 2. 2014.; accepted: 5. 5. 2014.

context of their usage will become a basic solution to manager's problems. Given the above, in the technological environment of modern organizations, comprised of computers, mobile devices, Internet, wireless communications, managers should make decisions that will enable competitive position of their companies. Basic concepts that support decision making are different definitions, facts and principles of how to use information and communication technology in the decision-making process. Understanding of these basics helps managers to evaluate and implement necessary software, a crucial step in the future successful business. Manager possessing the required knowledge uses the potential of the Business Intelligence analytic tools, as well as the functionality of decision support software, adjusted to specific business situations with the help of a technological specialist. The aim of the paper is to give managers a list of key terms in the domain of decision support and Business Intelligence that will help them acquire adequate knowledge for performance of their business function. The paper will categorize concepts into technical and managerial ones, with technical concepts implying the domain of specific tools and methods which should be thoroughly understood by technical specialists and not managers, while concepts in the managerial category will include meaningful connecting of the essential areas, approaches and philosophies, whose understanding is required for implementation of the best Decision Support System that will enable business excellence. Managers should understand concepts of the technical category to the extent that they can successfully realize purchase of an adequate software solution and choose adequate profile and number of professional personnel. There are several areas that stand out for their wide domain and are analyzed in numerous publications, (Luftig, Quellete, 2012; Porter, Tanner, 2004), durable existence in business and academic environment and proven importance in understanding of all other related concepts (Turban, Sharda, Delen, 2011). The paper continues with the overview and the analysis of chosen concepts, their development and connection to other domains.

2. BUSINESS EXCELLENCE AND TOTAL QUALITY MANAGEMENT

In the conditions of modern business described above, many organizations have adopted a set of methods that improve different organization levels and business aspects. The involvement of all employees in continuous improvement and transformation of business processes, with a view to realizing different user demands is of paramount importance when it comes to striving to improve quality and excellence. Concepts improvement and excellence include detailed knowledge of present conditions of certain process, project and company as a whole, precise and regular measurements and analysis and development of actions needed for improvements. During the eighties of the last century, many organizations recognized quality as a strategic factor for differentiating market companies, and not just for fulfilling the functional prerequisites in quality control. At the same time, basic understanding of quality changed and quality control gradually turned to efforts in providing quality, with the emerging acceptance of the ideas referring to managing the complete quality within an organization (Total Quality Management, TQM). TQM as an approach and philosophy had the greatest impact on the development of the field of business excellence. Presently, there are numerous business excellence models (Porter, Tanner, 2004) that companies use as the nucleus of their

improvement and development in the fields of self-evaluation or external evaluation based upon TQM concepts, though supplemented with guidelines and requirements for better organizational integration. TQM is primarily considered as an approach focused on the improvement of effectiveness, efficiency, timely satisfaction of clients' and other stakeholders' needs by using employees' skills and competencies with a purpose of achieving tested improvements in organization performances (Porter, Tanner, 2004). One of the critical success factors in TQM is strong leadership that motivates and authorizes employees to participate and engage. Organizations that implemented the TQM approach have outperformed their counterparts.

During the 90s of the last century, Business Process Reengineering (BPR) and Balanced Scorecard (BSC) developed as solutions that influenced development of different business excellence models. The main goal of BPR is to remodel crucial business processes due to decreased costs, increased product quality and better clients' satisfaction. BSC is basically a measurement system, enabling an efficient translation of strategy into action. BSC tries to connect the dimensions of learning and developing employees with the efficient processes that provide quality products and services according to the dimensions of satisfying customer needs, and finally according to the financial dimensions. The influence of BSC on the excellence models can also be perceived, since they all include this conceptual frame. Six Sigma should also be mentioned as a group of methodologies whose application has rapidly increased during the last ten years. Six Sigma uses a set of techniques in collecting data and techniques for analyzing the same, trying to improve organizational processes. Approach is focused on modalities helping the organization to deliver its products and services faster, better and cheaper, influencing the improvement of process capability by fulfilling a higher number of user demands. Six Sigma enables identification of costs not influencing added value, neither for clients nor those processes influencing the key product characteristics from the user's standpoint.

Some companies combined these initiatives with BSC initiatives due to the increased possibilities of progress enabled by the Six Sigma initiative. This helped to directly connect companies' quality initiatives with their strategic goals. The same principle was used by Gupta (2007) when developing a hybrid methodology named Six Sigma Business Scorecards that underlines differences between these methodologies and the need for their integration. Shortly, BSC is focused on improving the strategy, while Six Sigma is focused on process improvement. Due to these differences, most companies treated BSC and Six Sigma as individual initiatives, though Leahey (2005) claimed that true advantages cannot be realized unless both concepts are integrated.

The key dimensions of areas related to Business Excellence, as described by Porter and Tanner (2004), are as follows: Leadership, Focus on Clients, Strategy Alignment, Learning, Development and Innovations, Focus on Employees, Development of Partner Relationships, Process Management Based on Facts, Focus on Results and Social Responsibility.

3. DECISION SUPPORT AND BUSINESS INTELLIGENCE

The purpose of this paper is not to describe development of the concept of decision support, but instead to connect crucial concepts elaborated in the paper. Holsapple (2008) describes, in a comprehensible way, Decision Support System as a computer based system that represents and analyses knowledge from the aspects that ensure decision support procedures to be more productive, agile and innovative. Apart from the fact that it can be treated as digital knowledge storage, DSS enables acquisition of additional knowledge from external sources, focus on choosing the internal knowledge, generating new knowledge that could influence decisions, representation of knowledge through desired formats, coordinating outflow of knowledge among decision makers, controlling and the integrity/safety of outflows, and evaluation of participants and decision processes as a basis for future improvements.

Among Decision Support Systems, special attention should be given to decision making. To be able to understand decision making, one should understand the importance of information and knowledge processed according to that information. Knowledge management is related to distribution and assemblage of knowledge, while acquiring new knowledge refers to techniques of collecting and analyzing data and information. The authors Bolloju, Khalifa and Turban (2002) perceive the importance of integrating the Knowledge Management (KM) processes within Decision Support System so that decision makers can combine different types of knowledge (explicit and tacit) and data (internal and external), available in different formats.

When defining and describing Business Intelligence System (BI or BIS), one should start with information, one of the most important business resources, though their value is only potential. If companies want to use information to be successful, they should exploit them within the business processes for more quality decision making, processes performing and satisfying customers' demands (Prajogo, McDermott, 2005).

There are numerous definitions and descriptions of the BI or BIS concepts, e.g. Negash (2004) who defines BI as a system that combines data gathering, data storage, and knowledge management with analytical tools to present complex internal and competitive information to planners and decision makers; (Azvine, Cui and Nauck, 2005) for Azvine et al. (2005) BI is all about how to capture, access, understand, analyze and turn one of the most valuable assets of an enterprise — raw data — into actionable information in order to improve business performance. Lönnqvist and Pirttimäki (2006) stated that the term, BI, can be used when referring to the following concepts: 1. Related information and knowledge of an organization, which describe the business environment, the organization itself, the conditions of the market, customers and competitors and economic issues; 2. Systemic and systematic processes by which organizations obtain, analyze and distribute the information for making decisions about business operations; Turban and associates (2008) shortly and generally describe Business Intelligence as an umbrella term that combines architectures, tools, databases, analytical tools, applications, and methodologies. For the purpose of encompassing the complete domain and meaning of BI, authors propose the following definition: Business Intelligence System includes collecting and storing of comprehensive, correct and timely data that

are converted through different tools and techniques to information and submitted to decision makers in the appropriate format, so they could subsequently, supported by this information, act according to the strategic goals.

This definition is supported by the claim that successful implementation of Business Intelligence System within a specific company is related to using the correct, updated and valid, integrated data as means that will transform data into information required for decision making (Zeng et al., 2006).

The interrelated functioning of huge integrated enterprise systems such as Enterprise Resource Planning (ERP), Customer Relationship Management (CRM), and Supply Chain Management (SCM) systems with DSS and BIS is presently an exceptionally important field, where the Business Intelligence analytics developed upon integrated databases of the whole company can directly influence better, updated and flexible decision support, while decisions will subsequently influence the efficiency of CRM and SCM.

4. CONCEPTS RELATED TO THE SYSTEMATIC UNDERSTANDING OF DECISION SUPPORT AND BUSINESS EXCELLENCE

One of the goals of this paper is understanding and implementation of system thinking in certain areas related to the Decision Support Systems, such as acquiring the knowledge of the complete relevant system before considering its parts. Kanji (2005) claims that this attitude is opposed to the majority of modern managers' philosophies and actions. Most companies are divided into sectors, departments, sections, with managers perceiving their segment of organization as an entity itself, so they try to improve and optimize only their segment of organization (sub-optimization), which leads to more damage than benefits. Optimization implies defining the best balance for the complete system or organization, while sub-optimization connotes optimizing a part of the system without guaranteeing the improvement of a whole. What is crucial in the center of system thinking of an organization are the relationships and connections within the organization and between the organization and the environment. Hence, main inputs, processes, outputs and feedbacks should be well perceived. Main inputs (e.g. humans, materials, equipment and money) should be processed into main outputs (e.g. products and services, fallouts), all of this coordinated and managed through the implementation of business policies, supported by adequate measurements, decision making and execution of actions. One of the major advantages of system thinking is the capability of understanding a large number of mutual relationships between system's parts that will improve goal setting, implementation of policy and organizational structure. According to this standpoint, several concepts have been chosen and used as the basis for this paper. Table 1 presents a list of chosen areas, description of the purpose of knowledge of a specific area and its relation to other areas, and a category (managerial or technical). Knowledge categorized as managerial is required for the consciously, optimally and purposely used analytic and technical tools and methods (areas categorized as technical). Both categories are intended for all individuals interested in understanding a wider area encompassed in the paper. On the other hand, managers need not necessarily understand the described tools in detail in order to be able to successfully decide and manage.

Table 1. List of chosen terms and areas

Key terms and areas	Description	Category
Decision Support	Decision making basics and a need for support	Managerial
Decision Support Systems Computer Based Decision Support	Possibilities and integral parts of computer supported Decision Support System. The present challenges are connecting and interacting with other large systems, e.g. ERP, CRM or SCM	Managerial
Decision Support tools Decision Support methods Decision Support techniques Decision Support technologies	A need for concretization and realization of the specific Decision Support System. Modalities of development, modeling, gathering and presenting information, different performances and possibilities of individual tools, techniques and methods.	Technical
Business Intelligence	Domain and importance of Business Intelligence and Business Intelligence Systems	Managerial
Decision Support + Business Intelligence	Connection between these two crucial areas	Managerial
Business Intelligence tools Data Warehouse or Data Warehousing Online Analytical Processing Data Mining Text Mining Web Mining	Concretization of data browsing and analysis, knowledge of the concepts and role of Data Warehouse (DW), a need for knowledge of basic categories, tools and understanding their application. Each tool has its own features and is designed to address specific needs and situations. Knowledge of techniques used in the analysis of structured and unstructured data (text and web mining)	Technical

Data Management Business Analytics Knowledge Management Knowledge Discovery	The necessity of managing data flows and paying attention to receiving valuable information through adequate analytics. Managing the creation, sharing, storing and exploitation of knowledge. The necessity of integrating KM within DSS.	Managerial
Business Performance Management Corporate Performance Management	Business processes, methodologies, metrics and technologies used by companies for measurements, monitoring of and handling business performance	Managerial
Customer Relationship Management Customer Satisfaction	Planning and implementing strategies for managing customer relationships with a view to satisfying their needs and organizational needs for feedback	Managerial
Quality Management Business Excellence Performance Excellence Total Quality Management	Understanding the connections between business and process excellence and Total Quality Management. Basics of the TQM model (management philosophy, culture of quality in organization, clients, satisfaction and constant improvement) as a guideline for excellence.	Managerial
Six Sigma, Six Sigma Tools Balanced Scorecard Business Process Reengineering Key Performance Indicators	Group of tools and methods for the efficient process management in compliance with strategy, aimed at satisfying clients' demands. A need for understanding the integrated implementation of process-oriented and strategically oriented methods. Measuring the goals' realization.	Technical and managerial
Enterprise Resource Planning	The importance of knowing the purpose of modern ERPs, their additional and basic functionality within Business Intelligence and Decision Support.	Managerial
Supply Chain Management	Prerequisites for implementing a flexible, agile, reliable supply chain as an important characteristic of business excellence.	Managerial

Source: authors

5. RESEARCH METHOD

The research was conducted in several stages. During the first stage, the frequency of quoting the described concept or a combination of several concepts was observed over decades, i.e. throughout the 1970-2013 timeline. Research was done through Google Scholar. Quotes and patents were excluded, and the advanced search option was not used because the idea was to examine the frequency of quoting the concepts in all sorts of publications. The concepts used in search tools were combined with the operator OR, which indicated browsing of publications containing at least one of the concepts in their title, while each concept in the expression had quotation marks, thus specifying publications closely related to the context. The second research method included expressions given by the combination of two and more concepts with the quotation marks and the operator +, thus aiming to encompass all publications containing all of the mentioned terms. Considering the current year 2014, the observation of the last decade was limited to the 2010-2013 period, while the escalations in frequency of the observed areas were compared to 2000-2003 (in Appendix 1 marked as (d2-d1)/d2, in the form of percentage). Other annual ranges were analyzed as well, as it can be seen in Appendix 1. Decision Support Systems, data management, and quality management date back to the 1970s. Hence, 1970 was taken as the starting year. The aim of the first part of the research was to show the dynamics of the observed areas through a longer period of time – a decade, for which analyses of their frequency in publications of unspecified category were conducted, and to show the velocity of development of given areas as a percentage of frequency differences during a decade (equation given in the table as $((x_{ij}-x_{(i-1)j})/x_{(i-1)})$, i=2,3,4 j=number of rows).

6. RESEARCH RESULTS AND DISCUSSION

In Appendix 1 three arrows were used to demonstrate the three categories of the velocity of concept development, while each column containing arrow was regarded as a whole when determining percentiles. Upward arrow demonstrates concepts developing at a speed higher than the 75th percentile; the right arrow demonstrates concepts of an average speed between the 25th and 75th percentile, while the down arrow refers to the concepts developing at the slowest rate in a given period of time, with the speed average below the 25th percentile. It should be underlined that the above mentioned categories, i.e. arrows, show the velocity of concept development in comparison to other concepts of the time, while the development of individual concepts should be analyzed through rows, e.g. the concept of "balanced scorecard" recorded the speed of quotations of 8% in the 1980-1989 publications compared to the 1970-1979 period when it was among the slowest developing concepts (down arrow). During the period of 1990-1999 it increased a total number of quotations by 68 times, in comparison to 1980-1989, or 6830%, with arrow upwards implying that, aside from other concepts analyzed in the same period, it recorded one of the highest increases of frequency. The term "balanced scorecard" was, during the 1990-1999 period, one of the most quoted concepts used within different publications. Appendix 1 also clearly indicates chronological growth of quotation frequency for all the considered concepts, showing the relevance of all observed concepts in terms of scientific and business perspective. Graph 1 displays the most quoted concepts in the 1970-2013 publications.

Graph 1. Frequency of the most quoted concepts for the period 1970-2013

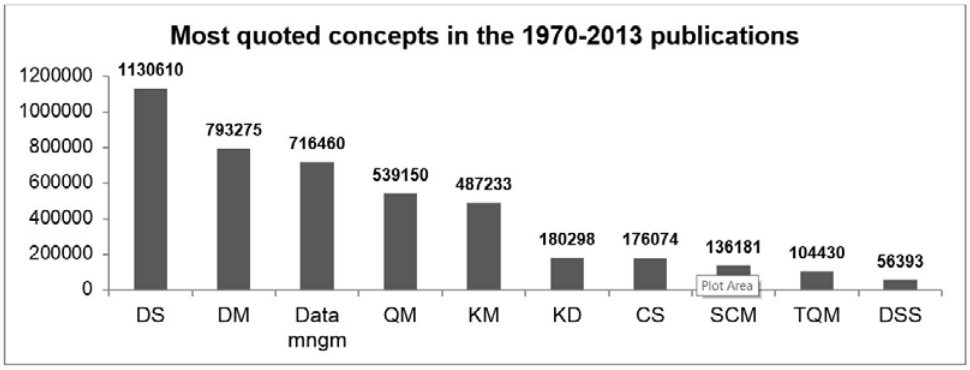

Source: authors

In the following illustration, Graph 2, the concepts with least frequency recorded in the same period were displayed.

Graph 2. Frequency of most quoted concepts for the period 1970-2013

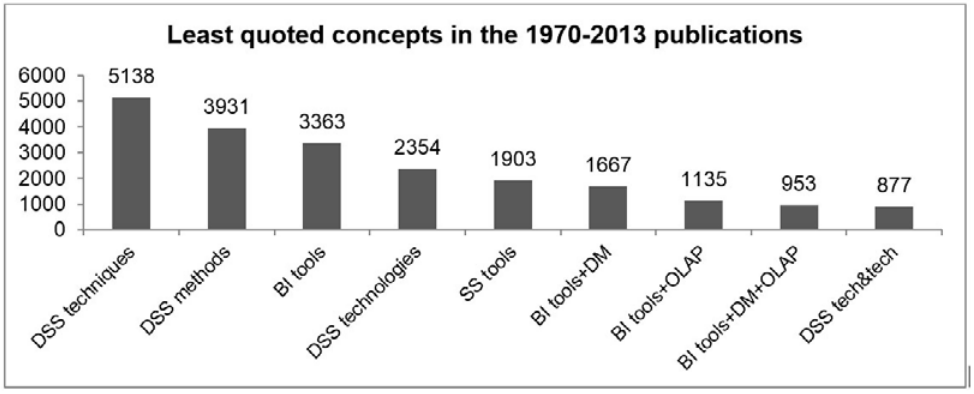

Source: authors

Graph 3 shows an overview of the crucial areas related to managerial category, or, in certain examples, to managerial and technical category. Two periods were considered since they were crucial for the development of the observed concepts. BPR recorded a significant increase of frequency in 1990-1999, in comparison to 1980-1989, alongside TQM, BE, ERP and SS, as the most quoted concepts in the same decade. The other concepts recorded a higher increase of frequency during the period 2000-2009 in comparison to 1990-1999, than during the period 1990-99 in comparison to 1980-1989.

Graph 3. An overview of the crucial areas related to managerial or managerial and technical category over two decades

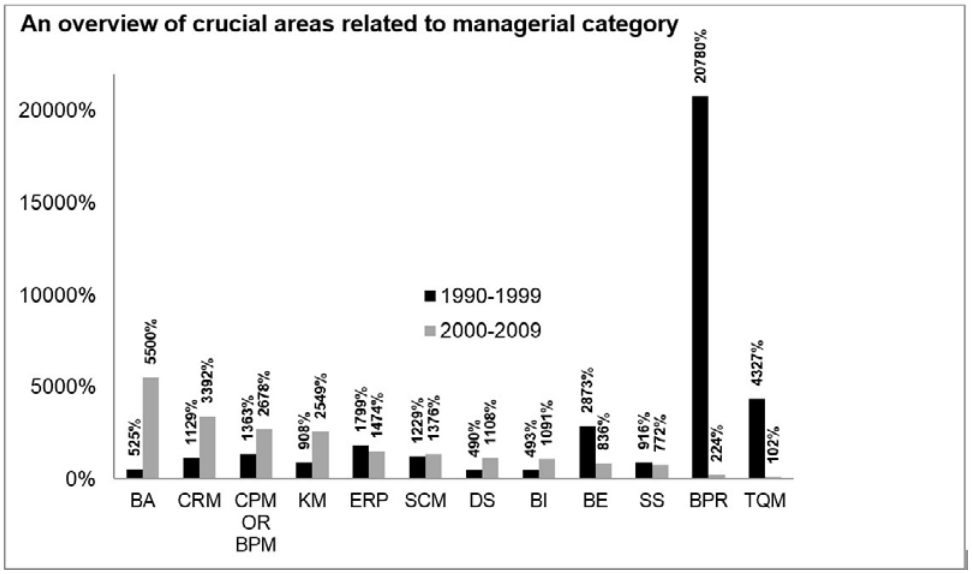

Source: authors

Graph 4 was designed on the same principle displaying the concepts categorized in technical category, due to the functionalities of processing, modeling, storing, measuring etc. It can be noticed that in the 2000-2009 period, in comparison to the previous decade, the most developed areas were WM+TM (+ denoting publication containing both concepts), SS tools, BA, following WM and TM as individual concepts, BI tools and DM, while other concepts recorded the highest growth in the 1990-1999 period.

Graph 4. An overview of the crucial areas related to technical category over two decades

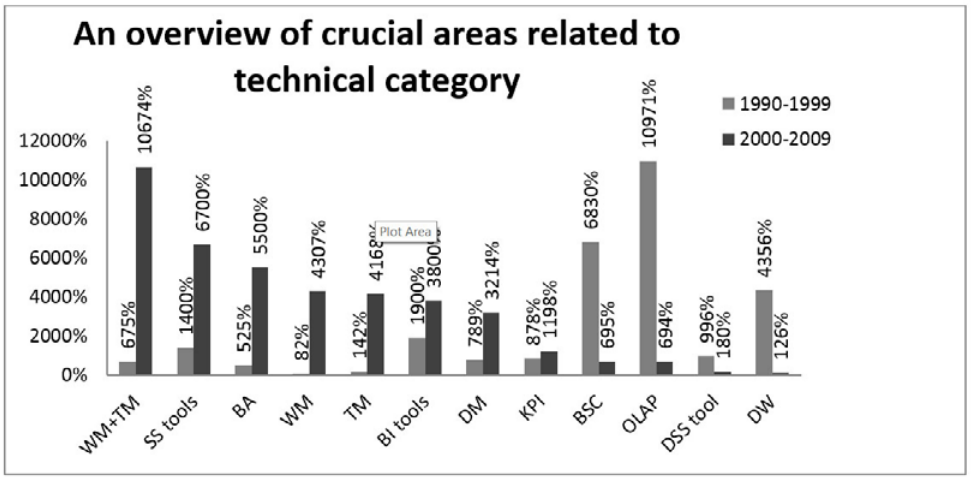

Source: authors

Graph 5 shows increase of concepts included in graphs 3 and 4, referring to the interrelation between triennial figures about frequency starting from 2010-2013, in comparison to 2000-2003. It can be concluded that BA recorded the highest increase, followed by CPM/BPM, SS tools, BI tools, WM+TM, Tm, BE, KPI, SS, BI.

Graph 5. Frequency increase in both managerial and technical categories for 2010-2013 in comparison to 2000-2003

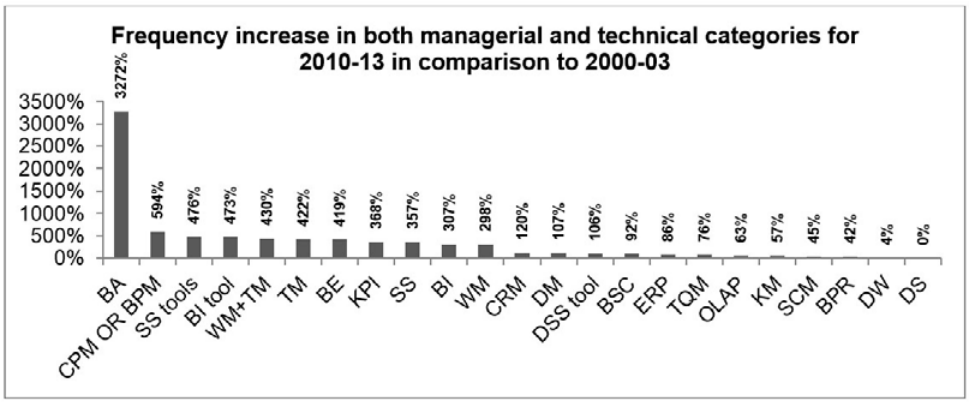

Source: authors

In order to specify the concepts most frequently quoted in publications edited in the recent period 2010-2013, Graph 6 was prepared to show their frequency. It can be concluded that the concepts DS, DM and KM are evidently more frequently quoted in the recent publications, followed by the concepts TQM, SCM, CRM, and BI.

Graph 6. Concepts most frequently quoted in publications edited in the recent period 2010-2013

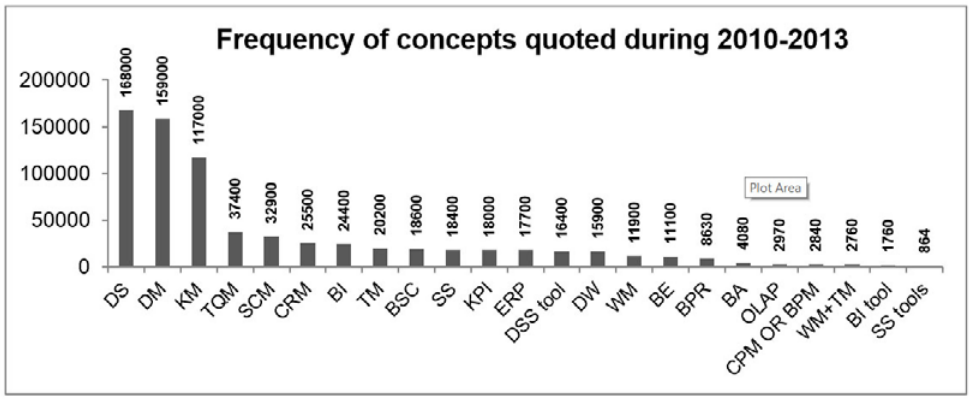

Source: authors

The second part of the research analyzed the frequency of quotations for concepts named in Appendix 1, separately for each year in the 1980-2013 period, summing up 34 years, with a purpose of specifying the most correlating concepts (the ones with the most similar frequency dynamics). For this purpose, the SPSS software was used, the version 19, combined with the correlation analysis and correlation matrix containing all concepts. The prepared matrix was used to extract correlations with r>0.98 and p<0.01, which were displayed in Appendix 2. The correlations with r>0.99 were underlined and written in bold fonts, which has helped to highlight the highest correlation between the concepts, as shown in Table 2.

Table 2. Concepts with highest correlation, (r>0.99, p<0.01)

Concepts with max correlation	**r**	**Concepts with max correlation**	**r**
BSC with SCM	**,995**	CRM with BSC	**,996**
BSC with DW	**,989**	CRM with SCM	**,994**
ERP with SCM	**,993**	CRM with PE	**,990**
ERP with BSC	**,991**	(DSS+KM) with ERP	**,996**
SS with SCM	**,992**	(BPM/CPM) with SCM	**,992**
SS with ERP	**,992**	(BPM/CPM) with SS	**,990**
PE with SCM	**,996**	DM with KM	**,996**
PE with BSC	**,991**	(BMI+DM+OLAP) with SCM	**,991**
BE with KPI	**,996**	(BI+DM) with KPI	**,995**
CS with PE	**,995**	BI+DM with BE	**,995**
CS with SCM	**,993**	BI with KPI	**,993**

Source: authors

7. CONCLUSION

This paper offers an insight into areas mutually connected by the fact that their domain is interrelated in order to achieve business excellence in all aspects of business: processes, products, clients and the environment. The motivation behind this standpoint comes from the fact that the research area is exposed to a multitude of concepts, philosophies, approaches, methods, tools, and techniques, so there is a need for a certain guidebook-overview offering the list of areas whose knowledge (detailed or general, depending on the function of employee or interested reader) is essential in understanding the complete business reality of modern times. As it was mentioned in the first chapters, several concepts address a wider domain (BE, TQM, DSS, BIS) than others, so these were used as basics when observing the interrelations to the other concepts. Browsing, storing, analyzing, interpreting and application of information for quality decision making and acting is a simplified course of the business cycles. The choice of software solutions, methods, material resources, and profiles of employees who will participate in the system is made by personnel holding the highest positions in a company, so their knowledge and competence is a required prerequisite for achieving the business excellence. This necessity was substantiated in the second and the third chapter of this paper.

The research results were used to describe the frequency of quotations for chosen concepts through several periods of time so as to determine which concepts developed most rapidly and to what degree they are more represented or "popular" in a certain time period than others. The authors noted that concepts related to the technical category (Table 1) mostly developed after 2000, their frequency being lower than that of theoretical concepts belonging to the managerial category, while technical concepts were leading in terms of percentage increase in the 2010-2013 period when compared to 2000-2003 (Graph 5). This conclusion implies that the frequency of certain concepts in publications is not the absolute measure of their relevance and importance, with the percentage increase between time periods being an equally important indicator, especially considering the last decade.

The second part of the research evaluates the correlation of chosen concepts, and the latter are extracted in Appendix 2 displaying the couples of concepts achieving the correlation $r>0.98$, $p<0.01$, and separately displayed couples correlating $r>0.99$ (Table 2). The correlations indicated that areas chosen in the paper are strongly interrelated, thus making one system that should be regarded as a whole, but separately as well.

Future research will be directed toward formalization of knowledge requirements for Business Intelligence department employees, which will facilitate personnel recruitment and targeted education of employees.

REFERENCES

Azvine, B., Cui, Z., Nauck, D. D., (July 2005), Towards real-time Business Intelligence, *BT Technology Journal*, Vol. 23, No. 3.

Bolloju, N., Khalifa, M., Turban, E. (2002) Integrating knowledge management into enterprise environments for the next generation decision support, Decision Support Systems, Vol. 33, pp.163–176.

Gupta, P., (2007) Six Sigma Business Scorecard, McGraw-Hill Education.

Holsapple, C., (2008) Supporting Decisional Episodes, in Adam, F. and Humphreys, P. (eds.), Encyclopedia of Decision Making and Decision Support Technologies, London: IGI Global.

http://businessfinancemag.com/technology/one-two-performance-punch, Leehy, 2005

Kanji Gopal, K.,(2005), Measuring Business Excellence, Routledge

Lönnqvist, A., Pirttimäki, V. (2006) The measurement of Business Intelligence, Information Systems Management, Vol. 23, No. 1, pp. 32–40.

Luftig, T. J., Ouellette , S. (2012) Business Performance Excellence, Bloomsbury Publishing.

Parikh, A.A., Haddad, J., (October 2008), Right-Time Information for the Real-Time Enterprise, Retrieved on February 2012 from DM Direct

Porter, L. J., Tanner, S. J. (2004) Assessing business excellence, Elsevier Butterworth-Heinemann

Power, D. J. (2013) Decision Support, Analytics, and Business Intelligence, Business Expert Press, 2013

Prajogo, D. I., McDermott, C. M. (2005) The relationship between total quality management practices and organizational culture, International Journal of Operations & Production Management, Vol. 25, No. 11, pp. 1101–1122.

Solomon, N. (2004) Business Intelligence, *Communications of the Association for Information Systems*, Vol. 13, Article 15

Turban, E., Sharda, R., Aronson, J. E., King, D. (2008) Business Intelligence: a managerial approach, Prentice Hall

Turban, E., Sharda, R., Delen, D., (2010), Decision Support and Business Intelligence Systems, Pearson

Appendix

Area	Abbreviation	x1	x2	x3	x4	d1	d2	(d2-d1)/d2	((xij-x(i-1))/x(i-1))), i=2,3,4			j=N of row	Total N of publ.
		1970-1979	1980-1989	1990-1999	2000-2009	2000-2013	2000-2003	2010-13 compared to 2000-03	1980-1989 compared to 1970-79	1990-99 compared to 1980-89	2000-09 compared to 1990-99	1970-2013	
"decision support"	DS	710	12200	72600	877000	168000	168000	0%	1632%	490%	1108%	1130610	
"decision support systems"	DSS	353	7840	16400	15900	15900	16300	-2%	2121%	109%	-3%	58393	
"computer based decision support"	CBDSS	8	311	1210	2650	1100	842	31%	3788%	289%	119%	5279	
"decision support tools"	DSS tool	25	532	5830	16300	16400	7980	106%	2028%	996%	180%	39087	
"decision support methods"	DSS method	2	37	392	2030	1470	523	181%	1750%	959%	418%	3931	
"decision support techniques"	DSS technique	2	104	972	2480	1580	685	131%	5100%	835%	155%	5138	
"decision support technologies"	DSS techno	0	29	333	1150	842	297	184%	2900%	1048%	245%	2354	
"decision support technologies + "technique"	DSS tech&tech	0	13	132	421	311	103	202%	1300%	915%	219%	877	
"business intelligence"	BI	81	273	1620	19300	24400	5990	307%	237%	493%	1091%	45674	
"decision support"+ "business intelligence"	DSS+BI	4	31	405	13700	14200	1460	873%	675%	1206%	3283%	28340	
"business intelligence tools"	BI tools	1	2	40	1560	1760	307	473%	100%	1900%	3800%	3363	
"business intelligence tools + "data mining"	BI tools+DM	0	0	20	793	854	161	430%	0%	2000%	3865%	1667	
"business intelligence tools + "olap"	BI tools+OLAP	0	0	17	572	546	137	299%	0%	1700%	3265%	1135	
"business intelligence tools + "data mining"+ "olap"	BI tools+DM +OLAP	0	0	16	509	428	114	275%	0%	1600%	3081%	953	
"on-line analytical processing"	OLAP	3	7	775	6150	2970	1820	63%	133%	10971%	694%	9905	
"data mining"	DM	695	2080	18500	613000	159000	76900	107%	199%	789%	3214%	793275	
"text mining"	TM	271	203	492	21000	20200	3870	422%	-25%	142%	4168%	42166	
"web mining"	WM	0	195	354	15600	11900	2990	298%	19500%	82%	4307%	28049	
"web mining + "text mining"	WM+TM	0	4	31	3340	2760	521	430%	400%	675%	10674%	6135	
"data management"	Data mngm	5660	16600	51200	515000	128000	71300	80%	193%	208%	906%	716460	
"business analytics"	BA	9	4	25	1400	4080	121	3272%	-58%	525%	5500%	5518	
"corporate performance management" OR "business performance management"	CPM OR BPM	1	8	117	3250	2840	409	594%	700%	1363%	2678%	6216	
"knowledge management"	KM	503	1330	13400	355000	117000	74400	57%	164%	908%	2549%	487233	
"decision support"+ "knowledge management"	DSS+KM	7	216	2340	18300	18200	5550	228%	2986%	983%	682%	39063	

Area	Abbreviation	x1	x2	x3	x4	d1	d2	(d2-d1)/d2	((xij-x(i-1))/x(i-1)) , i=2,3,4			j=N of row	Total N of pubbl.
		1970-1979	1980-1989	1990-1999	2000-2009	2000-2009	2010-13	2010-13 compared to 2000-03	1980-1989 compared to 1970-79	1990-99 compared to 1980-89	2000-09 compared to 1990-99		1970-2013
"customer relationship management"	CRM	27	58	713	24900	25500	11600	120%	115%	1129%	3392%	51198	
"customer satisfaction"	CS	924	3150	24800	84300	62900	38800	62%	241%	687%	240%	176074	
"business excellence"	BE	15	37	1100	10300	11100	2140	419%	147%	2873%	836%	22552	
"performance excellence"	PE	16	90	542	4470	3400	986	245%	463%	502%	725%	8518	
"six sigma"	SS	88	184	1870	16300	18400	4030	357%	109%	916%	772%	36842	
"six sigma tools"	SS tools	3	1	15	1020	864	150	476%	-67%	1400%	6700%	1903	
"total quality management"	TQM	33	497	22000	44500	37400	21300	76%	1406%	4327%	102%	104430	
"enterprise resource planning"	ERP	54	89	1690	26600	17700	9500	86%	65%	1799%	1474%	46133	
"balanced scorecard"	BSC	40	43	2960	23700	18600	9680	92%	8%	6830%	695%	45363	
"key performance indicators"	KPI	18	134	1310	17000	18000	3850	368%	644%	878%	1198%	36462	
"quality management"	QM	3200	6150	83800	345000	101000	97200	4%	92%	1263%	312%	539150	
"supply chain management"	SCM	181	490	6510	96100	32900	22700	45%	171%	1229%	1376%	136181	
"data warehouse"OR"data warehousing"	DW	115	149	6640	15000	15900	15300	4%	30%	4356%	126%	37804	
"business process reengineering	BPR	7	25	5220	16900	8630	6070	42%	257%	20780%	224%	30782	
"knowledge discovery"	KD	53	115	8130	129000	43000	23300	85%	117%	6970%	1487%	180298	

The concepts with the highest correlation (r>0,98, p<0,01,n=34)

	DM	data_mngm	KM
ds	,988	,982	,981

	CS	PE	BE	SCM	BPM/CPM	BI+OLAP
dss	,988	,988	,984	,984	,981	,981

	BSC	ERP	SS
dss tools	,986	,981	,980

	QM	dss technologies
dss techniques	,984	,981

	QM
dss technologies	,983

	KPI	DSS+KM	BI tool	BI+DM	BE	BI+OLAP	dss+bi
BI	**,993**	,989	,988	,986	,986	,985	,981

	DSS+KM
dss+bi	,988

	BI+DM	KPI	BE	BI+OLAP	BI+DM+ OLAP	PE	SCM
BI tool	**,994**	**,993**	,989	,987		,982	
BI+DM	**,995**	**,995**	**,994**	**,990**	,982	,981	

	KPI	BE	BI+OLAP	BI+DM+ OLAP	PE	SCM
BI+OLAP	**,999**	**,990**	,989	,989	,985	,985

	BI+DM+ OLAP	SCM	PE	BE	KPI	CS	CRM	DW	ERP	BSC
BI+DM+OLAP	**,999**	**,991**	,989	,985	,985	,984	,984	,983	,982	,981

	SCM	PE	CRM	CS	BE	BSC	DW	ERP	SS
BI+DM+OLAP	**,991**	,989	,985	,985	,984	,984	,984	,984	,981

	KM	KD
DM	,996	,988

	SCM	SS	PE	DSS+KM	ERP	BSC	CS
BPM OR CPM	,992	,990	,987	,986	,986	,983	,980

	KD
KM	,987

	ERP	SS	SCM	DW	BSC
DSS+KM	,996	,988	,986	,983	,980

	BSC	SCM	PE	ERP	DW	CS	SS
CRM	,996	,994	,990	,988	,986	,985	,985

	PE	SCM	DW	BSC	QM	ERP	BE	SS
CS	,995	,993	,988	,988	,985	,984	,982	,981

	KPI	PE	SCM
BE	,996	,986	,983

	SCM	BSC	SS	DW	ERP
PE	,996	,991	,983	,982	,981

	SCM	ERP	BSC
SS	,992	,992	,989

	SCM	BSC	DW
ERP	,993	,991	,989

	SCM	DW	QM
BSC	,995	,989	,980

	DW
SCM	,987

Appendix 2

Sabrina Šuman[1]
Maja Gligora Marković[2]
Berta Jadro[3]

Prethodno priopćenje
UDK 65.012.123

POTPORA ODLUČIVANJU I POSLOVNA INTELIGENCIJA – ŠTO JE POTREBNO ZNATI?[4]

SAŽETAK

Brojna su područja koja danas donositelji odluka moraju poznavati kako bi kontinuirano donosili kvalitetne odluke. Razvoj računalnih tehnologija i specifičnih alata za potporu odlučivanju u posljednjih deset godina sve je brži, a menadžeri na svim razinama moraju pratiti taj razvoj, raspolažući u svakom trenutku odgovarajućom vrstom i količinom znanja za optimalno upravljanje. Domena potrebnog znanja šira je na višim menadžerskim pozicijama, dok je na nižim pozicijama sužena, te se traži detaljnije i dublje znanje o nekom području. Dakle, potrebno je znati koja osnovna znanja trebaju posjedovati zaposlenici na različitim poslovnim razinama. Cilj ovog rada je dati pregled pojmova iz područja sustava za potporu u odlučivanju koje autorice drže nužnim za razumijevanje važnosti i svrhe korištenja takvih sustava. Promatrani su sljedeći pojmovi: strateške metode, metode orijentirane na izvedbu, mjerenja, skupovi tehnika i specifični alati. Pojmovi su izdvojeni zbog svoje dokazane važnosti u područjima vezanim uz potporu odlučivanju, a na temelju proučene literature iz tog područja. U radu je iznesena argumentacija odabira pojmova kao i njihova povezanost. Također je analizirana i dinamika pojavnosti tih pojmova kroz posljednja dva desetljeća. Analizom korelacije pokazano je koja su se područja razvijala sličnom dinamikom. Ovakav pregled trebao bi biti vodič za daljnje proučavanje predložene domene pojmova područja sustava za potporu odlučivanju, kao i svima onima koji žele dobiti cjelovit pogled na šire područje povezano s potporom odlučivanju, od studenata do menadžera.

***Ključne riječi**: potpora odlučivanju, poslovna inteligencija, poslovna izvrsnost, potpuna kvaliteta, upravljanje znanjem*

[1] Mag. edu. math. et inf., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* ssuman@veleri.hr
[2] Mr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* mgligoram@veleri.hr
[3] Bacc. informatike, student, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* bjadro@veleri.hr
[4] Datum primitka rada: 20. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

Nataša Zrilić[1]
Davor Širola[2]

Pregledni rad
UDK 364-053.81:65.01
331.56-053.81

SOCIJALNO PODUZETNIŠTVO – NOVA MOGUĆNOST ZAPOŠLJAVANJA MLADIH U HRVATSKOJ[3]

SAŽETAK

Socijalno poduzetništvo predstavlja specifičan oblik poduzetništva koji se temelji na načelima socijalne, ekološke i ekonomske održivosti, a dio ili cijelu stvorenu dobit izdvaja za dobrobit zajednice, no u praksi često nailazi na nerazumijevanje u pogledu svrhe i potencijala. U Europi i svijetu rastući je trend osnivanja različitih oblika socijalnog poduzetništva. Europska unija sve više pažnje usmjerava k stvaranju normativne i operativne podloge poticanja socijalnog poduzetništva u skladu sa zacrtanim novim modelom ekonomskog i društvenog rasta. Zakonski modeli u Republici Hrvatskoj omogućuju realizaciju različitih poduzetničkih projekata, a fondovi Europske unije podupiru takve inicijative. Problematika nezaposlenosti mladih u Republici Hrvatskoj, i u cijeloj Europskoj uniji, zahtijeva da se na svim razinama organizirano pristupi poticanju socijalnog poduzetništva u cilju novog zapošljavanja. Kroz odgovarajuće strateške dokumente i regulativu Hrvatska može unaprijediti obrazovne, savjetodavne i financijske pretpostavke za brže i potpunije iskorištavanje potpora Europske unije te tako znatno razviti socijalno poduzetništvo, a time i olakšati mladima ulazak u svijet rada.

Ključne riječi: *poduzetništvo, socijalno poduzetništvo, nezaposlenost mladih*

1. UVOD

Nezaposlenost mladih jedan je od najvećih problema u Hrvatskoj, ali i na području Europske unije (u daljnjem tekstu EU). Rješenja tog problema ne podrazumijevaju jedan model već više različitih pristupa za stalno, povremeno i privremeno zapošljavanje mladih. Jedan od modela koji daje značajne rezultate posljednjih godina je socijalno poduzetništvo. Iako su europska i svjetska iskustva iznimno zanimljiva, u Republici Hrvatskoj ne može se govoriti o sustavnom pristupu socijalnom poduzetništvu mladih. No fondovi EU-a svakako mogu pridonijeti financiranju različitih oblika socijalnog poduzetništva, posebno za mlađe skupine stanovništva.

Socijalno poduzetništvo nije nov fenomen, iako se čini kao da je tek počeo privlačiti sve više i više pažnje. U ovom radu koristit će se naziv *socijalno* poduzetništvo, koji se već dostatno udomaćio u hrvatskom jeziku.

[1] Dr. sc., prof. v. škole, savjetnica gradonačelnika za razvoj, Grad Rijeka, Korzo 16, Rijeka, Hrvatska. *E-mail:* natasa.zrilic@rijeka.hr

[2] Mr. oec. spec., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* davor.sirola@veleri.hr

[3] Datum primitka rada: 13. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

Osim ovog termina, u Hrvatskoj se pojavljuje i naziv *društveno* poduzetništvo. Termin društveno poduzetništvo u hrvatskom jeziku ima konotaciju proizašlu iz bivšega socijalističkog konteksta, u kojemu se 'društveno' razumije kao nastavak društvenog vlasništva i iz toga proizašlih oblika odnosa (Vidović, 2012:24). Uvažavajući problematičnost doslovnog prijevoda termina s engleskog jezika i konotacije koje oba termina imaju u hrvatskom jeziku, prvi termin je ipak nešto precizniji u doticanju sadržaja fenomena. Iako pojam 'socijalno' u hrvatskom jeziku može imati konotaciju socijalnog statusa, siromaštva, krajnje bijede ili 'socijalnog slučaja', 'socijalno' u terminu vrlo jasno upućuje na angažiranost u socijalnoj sferi, području koje označavaju različita djelovanja usmjerena prema postizanju blagostanja (engl. *welfare*).

Upravo razgraničenje vrsta poduzetništva i kontradikcija u poimanju socijalnog poduzetništva predmet su obuhvata sljedećih dvaju poglavlja ovog rada, dok se u nastavku elaborira EU i hrvatski pristup razvoju socijalnog poduzetništva, njegovi institucionalni oblici te posebno analizira potencijal socijalnog poduzetništva u ublažavanju problema nezaposlenosti mladih i u EU i u Hrvatskoj.

2. TEMELJNE ZNAČAJKE PODUZETNIKA I PODUZETNIŠTVA

Pojam poduzetnika i poduzetništva različito se definira ovisno o tome promatra li se iz poslovne, menadžerske ili osobne perspektive. U gotovo svim definicijama poduzetništva ipak se može utvrditi slaganja da je riječ o ponašanju koje uključuje (Hisrich et al., 2011:7):

1. preuzimanje inicijative
2. organiziranje i reorganiziranje društvenih i ekonomskih mehanizama i resursa u praktičnom smjeru
3. prihvaćanje rizika ili neuspjeha.

Zelena knjiga o poduzetništvu u Europi (European Commission, 2003:6) definira poduzetništvo kao „način razmišljanja i proces kreiranja i razvijanja ekonomskih aktivnosti stapanjem spremnosti na preuzimanje rizika, kreativnosti i/ili inovativnosti s razumnim upravljanjem, unutar nove ii postojeće organizacije."

Iz različitih teorija može se izdvojiti zajednička crta svih pristupa poduzetništvu, a to je inovativnost. Tu zajedničku crtu slijedi i definicija poduzetnika kao (Jelavić, Ravlić, 1995:60): „osobe nadarene poslovnim duhom i rukovodnim sposobnostima, bogate znanjem o poslovima i ljudima, odlučne i spremne da preuzme rizik upravljanja poduzećem na temelju inovacija i stalnog razvoja."

U općoj podjeli može se reći da poduzetništvo podrazumijeva prvu fazu procesa koja nastaje idejom, a rezultira poduzetničkim projektom (shema 1). Shema 1. Realizacija i cilj poduzetničkog projekta (shema 1).

Shema 1. Realizacija i cilj poduzetničkog projekta

Izvor: autori

Treća faza procesa nije uvijek jednoznačno određena već ovisi o vrsti poduzetništva u kojoj se proces zbiva. Oko definiranja vrsta poduzetništva također ne postoji potpuno suglasje autora, no široko je prihvaćena podjela na (Škrtić, 2006:5-18): tradicionalno, korporativno („intrapreneurship") i socijalno poduzetništvo, iako neki autori razlikuju individualno, korporacijsko i skupno poduzetništvo (Deželjin et al., 2002:54), odnosno u užem obuhvatu nezavisno i korporacijsko poduzetništvo (Hisrich et al., 2011:14-16).

Upravljanje poduzetničkim projektom podrazumijeva niz aktivnosti koje se povezuju s menadžmentom, a to ne mora biti uloga poduzetnika koji je osmislio i razradio projekt. Naime, temeljni cilj menadžera je ostvariti dobit, te poduzimati sve aktivnosti u tom cilju. Stoga proizlazi da faza poduzetništva i menadžmenta mogu biti odvojene, ali i ujedinjene u istoj osobi - poduzetnom menadžeru.

Naime, u suvremeno doba sve se više isprepliću elementi poduzetništva i menadžmenta, što se upravo iskazuje u obliku složenijeg pojma – poduzetnički menadžer. Ta se isprepletenost ne ogleda samo u sjedinjenju obiju funkcija u istoj osobi u malim poduzećima, nego i u tome što se u svakoj od tih funkcija sjedinjuju neki sadržaji i svojstva obiju funkcija. To ne znači da među njima ne postoji razlika. Menadžer nastoji osigurati što racionalniju uporabu raspoloživih resursa kako bi ostvario što veće poslovno-financijske rezultate sa što manje ulaganja, odnosno što veći *output* uz što manji *input*. Poduzetnik se time ne zadovoljava; on teži novome, neprestanim promjenama, rastu i razvitku, kako bi osigurao trajnu konkurentnost na tržištu, zadovoljio potrošača - kupca i osigurao dinamičku (a ne statičku) stabilnost i prosperitet poduzeća (Deželjin et al., 2002:64-65).

Prema P. Druckeru, teoretičaru menadžmenta, tri su ključna poduzetnička zadatka menadžmenta (Škrtić, 2006:82):

- postizanje uspješnosti postojećeg poslovanja
- nalaženje novih poslovnih potencijala i
- osiguravanje budućnosti poslovanja.

N. C. Siropolis u cilju povećanja uspješnosti predlaže da bi poduzetnici trebali raditi tako da budu i menadžeri i poduzetnici (Siropolis, 1995:359):

- okružujući se ljudima koji o mnogim aspektima posla znaju više od njih
- usmjeravajući znanje takvih ljudi u djelotvorniju proizvodnju
- držeći korak s najnovijim menadžerskim metodama.

No postajući menadžerima ne bismo se smjeli odreći svoje poduzetničke sklonosti. Naprotiv, menadžeri trebaju nastaviti tražiti nove prilike, održavajući istodobno ravnotežu između korištenja takvih prilika i rješavanja problema, jer će inače njihovi poslovi imati male izglede za budući rast.

Howard Stevenson sa Sveučilišta Harvard vjeruje da se poduzetnički model upravljanja poduzećem razlikuje od tradicionalnog (menadžerskog) u osam dimenzija (Hisrich et al., 2011:41-46):

1. strateška orijentacija vođena prisutnošću ili rađanjem prilika (a ne iskorištavanjem postojećih resursa poduzeća)
2. predanost prilici uz naglasak na brzinu ulaska na tržište (a ne trajnost iskorištavanja prilike)
3. angažiranje (što manje) resursa
4. kontrola (pristup, a ne vlasništvo) resursa
5. organska (fluidna, a ne formalna) struktura menadžmenta
6. filozofija nagrađivanja na temelju doprinosa otkrivanju prilika, a ne na temelju razine odgovornosti
7. orijentacija prema ubrzanom rastu (bez čuvanja pozicija i moći) i
8. poduzetnička kultura (poticanje generiranja ideja na tržištu, a ne samo u okviru postojećih resursa).

Iz svega navedenog može se zaključiti da je realizacija poduzetničkog projekta, a posebno preklapanje funkcije poduzetnika i menadžera, izuzetno složen proces.

3. SOCIJALNO PODUZETNIŠTVO – KONTRADIKCIJA U POJMU

Za razliku od klasičnog pojma poduzetništva, socijalno poduzetništvo složeniji je pojam. No niti socijalno poduzetništvo ne se razumijeva jednoznačno. Kako je posljednjih desetljeća eksponencijalno rasla popularnost koncepta socijalnog poduzetništva, rastao je i broj definicija. Iako ne postoji univerzalna definicija socijalnog poduzetništva, uočljivo je da misija rješavanja socijalnih problema i kreiranja društvene vrijednosti predstavlja osnovu svake definicije (Singer et al., 2011:9).

Socijalno je poduzetništvo nov fenomen u trećem sektoru modernih ekonomija i razlikuje se od tradicionalnog neprofitnog sektora (Bežovan, 2008:395).

Pojam socijalno poduzetništvo (engl. *Social entrepreneurship*) po mnogima je prvi skovao prije nekoliko desetljeća Bill Drayton. On je ujedno i osnivač Ashoke (www.ashoka.org), jedne od prvih zaklada koja promovira i podupire socijalno-poduzetničke pothvate. Za Draytona je socijalno poduzetništvo poduzetništvo s etičkim integritetom, kojemu nije cilj osobna korist ili maksimiziranje profita, nego usmjerenost na društvene vrijednosti. Drayton je isticao važnost inovativnog pristupa rješavanju socijalnih pitanja te smatrao da je za korjenite promjene potrebno uključiti što više ljudi širom svijeta (Vidović, 2012:23).

Fenomen socijalnog poduzetništva star je tek nekoliko desetljeća, no socijalno-poduzetnička praksa može se prepoznati u različitim oblicima kroz povijest. Smatra se da korijeni socijalnog poduzetništva sežu unazad do 18. stoljeća, kada je industrijalac Robert Owen počeo štititi svoje zaposlenike tražeći načine da poboljša njihove radne uvjete, osiguravajući odgovarajuće obrazovanje njima i njihovim obiteljima i uključujući ih u različite kulturne aktivnosti (Singer et al., 2011:5).

Treba razlikovati pojam socijalnog poduzetništva u užem i širem smislu. Stevenson i Wei-Skillern (2006) razlikuju širi i uži pristup razumijevanju socijalnog poduzetništva. U širem smislu socijalno poduzetništvo shvaća se kao inovativna aktivnost sa socijalnim ciljem, koja se pojavljuje bilo u profitnom sektoru, bilo u neprofitnom sektoru ili u međusektorskom prostoru. U užem značenju socijalno poduzetništvo razumije se kao fenomen primjene poslovnih znanja i vještina u neprofitnom sektoru, kada neprofitne organizacije počnu primjenjivati tržišne načine stjecanja financijskih sredstava (Vidović, 2012:30). U užem smislu, socijalno poduzetništvo podrazumijeva i poduzetništvo koje se orijentira na ciljeve vezane uz sektor socijalne skrbi. Najrašireniji primjer socijalnog poduzetništva su socijalni inkubatori koji podrazumijevaju poduzetničku infrastrukturu za ljude koji se iz raznih razloga ne mogu baviti poduzetništvom u klasičnom smislu te riječi. Sljedeća shema prikazuje faze socijalnog poduzetništva.

Shema 2. Realizacija i cilj projekta socijalnog poduzetništva

PAMETAN RAST	**ODRŽIV RAST**	**UKLJUČIV RAST**
INOVACIJE	KLIMA, ENERGETIKA I MOBILNOST	ZAPOŠLJAVANJE I VJEŠTINE
OBRAZOVANJE	KONKURENTNOST	BORBA PROTIV SIROMAŠTVA
DIGITALNO DRUŠTVO		

Izvor: autori

U 1. fazi i u socijalnom poduzetništvu potrebno je osmisliti ideju i provjeriti mogućnosti njezine realizacije. U suvremenom svijetu prednost donosi korištenje interneta jer se tako mogu lakše i brže provjeriti ideje koje su već realizirane na tržištu.

U 2. fazi potrebno je da poduzetnik razradi projekt sa svim njegovim elementima, a posebno s naglaskom na financijsku i tržišnu održivost.

Kod 3. faze realizacija socijalnog poduzetništva podrazumijeva menadžment koji nije usmjeren ostvarenju dobiti. Naime, temeljni cilj socijalnog poduzetništva je ostvarenje određenih društvenih vrijednosti. Upravo u izboru tih društvenih ciljeva i njihovoj realizaciji pružaju se široke mogućnosti za uspješno socijalno poduzetništvo.

Iz navedenog je jasno da postoji određena kontradikcija u pojmu socijalnog poduzetništva koja se svodi na nespojivost poduzetništva i društvenih koristi (http://www.nesst.org). Pojam socijalnog poduzetništva je problematičan iz dvaju razloga (Martin, Osberg, 2009):

1. socijalna komponenta – može se nazvati i društveno korisnom komponentom i
2. poduzetništvo klasičnog tipa podrazumijeva tržišni pristup i orijentaciju na poslovne ciljeve.

Kontradiktornost pojma socijalnog poduzetništva proizlazi iz činjenice da naizgled spaja nespojivo – socijalnu svrhu s tržišnim djelovanjem, tj. socijalnu i poduzetničku komponentu. Socijalna komponenta socijalnog poduzetništva odnosi se na njegovu usmjerenost na socijalna pitanja, odnosno adresiranju prepoznatih socijalnih potreba u društvu koje su ostale neodgovorene. U usporedbi s tradicionalnim poduzetništvom, kojeg pokreće ostvarivanje ekonomske vrijednosti, prvenstveno dobiti, socijalno poduzetništvo je okrenuto generiranju društvenih vrijednosti u socijalnim učincima u društvu i doprinosu općem dobru. Mnogi autori ističu hibridnost pojma (hibridni karakter) socijalnog poduzetništva kao ključno obilježje za razumijevanje ovog fenomena, budući da kombinira komercijalne i neprofitne oblike djelovanja (donacije, volonterski rad), ima 'multidionički' karakter (volonteri, zaposlenici, korisnici, zajednica...), različite pravne i organizacijske oblike te rastapa granice tradicionalnih sektora – države, privatnog tržišnog sektora i civilnog društva (Vidović, 2012:32-33 i 38-39).

Naime, temeljni cilj svakog poduzetnika je ostvarenje dobiti te na taj način poduzetnik sudjeluje u društvenom sustavu kroz realizaciju svih ekonomskih ciljeva (plaćanje dobavljača, zaposlenika, poreza i drugo).

Sve se više širi kultura društveno odgovornog poduzetništva, odnosno društveno odgovornog poslovanja (engl. *Corporate social responsibility*), koja podrazumijeva da poduzetnici izdvajaju dio dobiti za određene društvene ciljeve. Društveno odgovorno poduzetništvo posebno se može stimulirati poreznom politikom, ali i promicanjem opće kulture sudjelovanja u humanitarnim i drugim aktivnostima. No kad se spomene socijalno poduzetništvo, ne misli se na povremeno sudjelovanje u društveno korisnim akcijama. Pod socijalnim poduzetništvom podrazumijeva se posebna vrsta poduzetništva koja je u potpunosti orijentirana isključivo na ostvarenje društvenih ciljeva (Bubić, 2011), dok se socijalna komponenta društveno odgovornog poduzetništva ogleda u dodatnom poštovanju određenih društvenih i etičkih vrijednosti kroz poslovanje, čime se artikulira doprinos zajednici (Vidović, 2012:25).

Iz navedenih razloga neki autori govore o pojmu društvenog poduzetništva, ali taj pojam također može stvoriti zabunu kako se radi o ciljevima koji su vezani za neku društvenu sferu ili način ponašanja javnog sektora u rješavanju određenih društvenih problema. Primjerice, u literaturi se govori o javnom menadžmentu, poduzetništvu u javnom sektoru, društvenom marketingu i drugo, a sve navedene kategorije mogu se djelomično poistovjetiti s pojmom društvenog poduzetništva. Stoga će se u ovom radu koristiti pojam socijalnog poduzetništva u širem smislu, a u nastavku će se izložiti vrste društvenih ciljeva, a time i vrste socijalnog poduzetništva.

Postavlja se pitanje koji su to društveni ciljevi koji se mogu realizirati putem socijalnog poduzetništva. Ne mogu se navesti svi ciljevi prihvatljivi za socijalno poduzetništvo jer oni ovise o specifičnoj društvenoj problematici u određenoj sredini (Martin, Osberg, 2009), stoga je najbolje podijeliti ciljeve sukladno socijalnom poduzetništvu i to na:

- socijalnu skrb
- zdravstvenu skrb
- ekološke ciljeve
- edukaciju
- uključivanje raznih skupina stanovništva (inkluzija).

U sferi socijalne skrbi podrazumijevaju se posebne aktivnosti koje socijalno poduzetništvo može pružiti različitim skupinama ljudi s obzirom na njihove probleme socijalne isključenosti iz društva. U suvremenim uvjetima najzastupljenija je problematika razvoja posebnih znanja i vještina radi aktivnog uključivanja na tržište rada, posebne aktivnosti s kategorijom beskućnika i dodatne edukacije za sve one koji nemaju dovoljnu razinu obrazovanja. Već iz navedenog vidljivo je da se radi o vrlo širokom spektru djelatnosti, a svaka lokalna sredina ima i svoje dodatne specifičnosti kao što je, primjerice, problem nezaposlenosti uslijed propasti velikih gospodarskih sustava, velik broj ljudi treće životne dobi bez dostatnih sredstava za egzistenciju i drugo.

U sferi zdravstvene skrbi postoje velike mogućnosti socijalnog poduzetništva u cilju poboljšanja kvalitete života oboljelima od kroničnih bolesti, njihove edukacije, kao i posebni vidovi kućne pomoći oboljelima. Ova vrsta socijalnog poduzetništva mora se realizirati uz stručnu pomoć zdravstvenih djelatnika koji su specijalizirani za pojedina područja. No, u te se aktivnosti mogu uključiti i svi građani koji imaju iskustva sa zdravstvenim problemima i mogu pridonijeti oboljelima i njihovim obiteljima.

Ekološki ciljevi mogu biti vrlo različiti, a bitno ovise o vrsti i stupnju zagađenja okoliša u određenoj sredini. Socijalno poduzetništvo može se usmjeriti na određena specifična područja u suradnji sa stručnjacima, ali i svim građanima zainteresiranim za bolju kvalitetu okoliša.

Edukacija građana pruža velike mogućnosti za razvoj socijalnog poduzetništva. S obzirom na to da posebne kategorije građana imaju specifične potrebe, s tim u vezi edukacija može bitno pridonijeti stupnju njihove informiranosti i pripreme za rješavanje određenih problema.

Pojedine skupine stanovništva imaju problem isključenosti iz društva zbog različitih ekonomskih ili društvenih razloga. Svaka od kategorija ima specifične probleme koji se ne mogu riješiti bez suradnje sa stručnjacima i uz primjere dobre prakse u Europi i svijetu. Stoga je zadatak socijalnog poduzetništva razviti programe posredstvom kojih će se zainteresirane skupine građana postepeno prilagođavati općim okolnostima.

Svi navedeni ciljevi mogu se ostvariti i povremenim aktivnostima društva, odnosno određenih subjekata. No socijalno poduzetništvo pruža kontinuitet ostvarenja pojedinih programa, a time i dugoročno ostvarivanje ciljeva. Naime, socijalnim poduzetništvom osigurat će se konstantnost realizacije pojedinih društvenih ciljeva (Martin, Osberg, 2009). U nastavku će biti objašnjeni oblici socijalnog poduzetništva.

4. INSTITUCIONALNI OBLICI SOCIJALNOG PODUZETNIŠTVA

Pod oblicima socijalnog poduzetništva podrazumijevaju se zakonski i institucionalni oblici unutar kojih se može razvijati određena vrsta socijalnog poduzetništva (Martin, Osberg, 2009). Treba naglasiti da se socijalno poduzetništvo realizira posredstvom postojećih zakonskih akata koji uređuju pojedine oblike poduzetništva. Tako se u Republici Hrvatskoj socijalno poduzetništvo može realizirati vrlo različitim zakonskim mogućnostima – od udruga do trgovačkih društava. Ovo zaslužuje posebnu pozornost jer je pred socijalnim poduzetnicima širok spektar mogućnosti u okviru kojih mogu realizirati svoje poduzetničke projekte i inicijative. Drugim riječima, koristeći postojeće zakonodavstvo u Republici Hrvatskoj, socijalno poduzetništvo može se organizirati kao (Bubić, 2011):

- udruga
- zaklada
- obrt
- zadruga
- trgovačko društvo
- ustanova.

Sukladno zakonskoj regulativi, svaki od ovih oblika predstavlja određene prednosti i rizike za ostvarenje ciljeva. Također, u početnim fazama realizacije socijalnog poduzetništva pogodnija je organizacija posredstvom *udruga*, dok su za razvijene oblike socijalnog poduzetništva primjerenija trgovačka društva. Izbor oblika prvenstveno ovisi o vrsti socijalnih ciljeva i o rokovima u kojima će se pojedini projekti i/ili programi socijalnog poduzetništva realizirati.

Također, treba naglasiti da pojedini natječaji za fondove EU-a i programe Unije već u uvjetima određuju financiranje prema određenom obliku realizacije socijalnog poduzetništva. Odnosno, na neke od spomenutih natječaja mogu se prijaviti isključivo udruge, na druge natječaje isključivo trgovačka društva, a postoji i mogućnost njihovog partnerstva.

U Republici Hrvatskoj iznimno je razvijen sektor udruga u kojima ljudi mogu povremeno, privremeno ili stalno zasnivati radni odnos, a što predstavlja veliku pogodnost za nezaposlene, posebno mlade ljude. Sustav udruga subvencionira se i putem programa javnih potreba na svim razinama, a dostupni podaci pokazuju da prevladavaju udruge s područja sporta, kulture, slobodnog vremena djece i mladih i drugo. Uočeni nedostatak udruga koje se bave poduzetničkom edukacijom i jedan od osnovnih problema vidimo i u tome što tematika razvoja poduzetničkih projekata i promocija poduzetništva kod mladih nije prepoznata kroz programe javnih potreba.

Istodobno, Zakon o udrugama izjednačava formalne i neformalne oblike udruživanja građana te ne radi razliku između vrsta udruga po pojedinim sektorima, tako da egzistira situacija da su udruge u sportu izuzetno jake zbog izvora financiranja putem tržišta (primjerice prodaja igrača na svjetskom tržištu), a određene udruge ne bi uopće mogle funkcionirati bez javnog financiranja (razne udruge u kulturi i one orijentirane na potrebe mladih). Pritom je kod udruga u sportu zapravo riječ o devijaciji, budući da se one pretvaraju u 'zamaskirani' oblik udruge koji

skriva profitni interes pojedinaca (Meler, 2003:130). Pritom se svakako postavlja pitanje kriterija kojima javne vlasti definiraju financiranje udruga javnim novcem, kao i kontrole provedbe javno financiranih programa i njihovog poreznog nadzora. Jedan od dodatnih problema je i taj što ne postoji kontrola u tome koliko je udruga osnovao određeni pojedinac i koliko su se puta udruge s istim članovima uprave javljale na javne natječaje. Sve navedeno govori o tome da je Zakon o udrugama potrebno doraditi primjereno sadašnjem stupnju razvoja, kako bi mogao biti u funkciji razvoja civilnog društva i društva u cjelini, ali uz jasna pravila i kontrolu njihova poslovanja.

Iskustvo je pokazalo da su udruge najprikladniji oblik organizacije socijalnog poduzetništva u sferi zdravstva i socijalne skrbi, provedbi kulturnih programa, a pogotovo svih programa orijentiranih na kvalitetu slobodnog vremena djece i mladih. Pretpostavka ostvarenju navedenih programa je suradnja sa stručnjacima iz različitih područja, koji su obično već angažirani na drugim institucijama te im sektor usluga pruža dodatnu profesionalnu slobodu.

Za razliku od navedenog realizacija socijalnog poduzetništva posredstvom *obrta, zadruga i trgovačkih društava* podrazumijeva profesionalni menadžment i jasno određene tržišne ciljeve. Iako ima izvrsnih primjera socijalnog poduzetništva s područja zaštite okoliša, obrazovanja i drugo, u hrvatskoj postoji nedostatak menadžerskih kadrova za ta specifična područja. Već samo vođenje obrta, zadruge i trgovačkog društva u uvjetima ekonomske krize predstavlja poseban rizik, a dodatno je otežavajuća okolnost ako menadžment nema iskustva s provođenjem odabranih socijalnih ciljeva.

U Hrvatskoj je posebno izražen nedostatak zadruga, pogotovo u dijelu edukacije i pripreme poljoprivrednih proizvođača za prijavu projekata za fondove EU-a. Navedeno će biti sve veći problem s obzirom na izrazito rigoroznu poljoprivrednu politiku Europske komisije i definirane standarde za proizvodnju i preradu poljoprivrednih sirovina i autohtonih proizvoda, kao i njihove zaštite. Također, unutar EU-a upravo zadruge pokazuju velike prednosti u ostvarenju zajedničkih ciljeva poljoprivrednika na određenog regionalnoj razini, a njihov se rad posebno podupire kao dio državne politike.

Najsloženiji oblik provođenja socijalnog poduzetništva su *zaklade* jer podrazumijevaju specifičan menadžment koji je sposoban prikupiti potrebna financijska sredstva od javnog i privatnog sektora te ga usmjeriti prema ostvarenju određenih društvenih ciljeva.

Naime, neprofitne se organizacije danas, kao izvoru svoje egzistencije, okreću prema tržištu. Filantropija se supstituira tržišnim načinima financiranja. Umjesto međunarodnih i državnih izvora kao novi izvori financiranja pojavljuju se raznoliki načini samofinanciranja koji se uglavnom temelje na tržišnim načelima (primjerice: članarine, pristojbe, ulaznine, kotizacije, naknade i sl. za usluge, prodaja različitih proizvoda, iznajmljivanje prostora/opreme i drugo). Drugim riječima, cilj neprofitnih organizacija postaje i ostvarenje određene dobiti kroz financijski održive projekte, odnosno programe, kako bi mogle uspješno ostvarivati svoju misiju. Tako neprofitna organizacija danas mora stjecati novac po načelu „kako prikupiti potrebna jaja iz različitih gnijezda" (Meler, 2003:106). Zbog toga i stvaranje marke i prepoznatljivog imidža udruga i zaklada postaje nužno za održanje kontinuiteta njihova djelovanja. Takav pristup neprofitnih organizacija posljedica je vrlo

brzog ritma prihvaćanja koncepcije stvaranja marke. Naime aktivnost koja je tri četvrtine prošlog stoljeća bila pretežno ograničena na robe i usluge široke potrošnje, sada karakterizira industrijski, javni i dobrovoljni sektor te nevladine udruge (Economist, 2004:6).

Pritom je najveći izazov utvrditi jasne kriterije financiranja pojedinih projekata i programa te osigurati transparentnost postupaka natječaja za sve korisnike sredstava zaklade. U Hrvatskoj je nedovoljno razvijen sektor zaklada iako postoje značajne mogućnosti posebnih poreznih poticaja za sve fizičke i pravne osobe koje su spremne donirati zakladu (financijskim sredstvima, nekretninama, stvarima i pravima). No zbog čestih promjena u poreznom zakonodavstvu i ekonomske krize poduzetnici još ne mogu prepoznati korisnost donacija za poduzetnički sektor, iako su u EU-u i svijetu zaklade značajan oblik socijalnog poduzetništva.

Posebna tema su *ustanove*, koje mogu biti javne i privatne, ali je njihovo funkcioniranje do sada uvijek bilo vezano uz javni sektor. Iz svega navedenog jasno je da postoji još puno mogućnosti za doradu i povezivanje postojećih zakonskih rješenja u pravcu razvoja socijalnog poduzetništva. Na razini EU-a nema jedinstvenog sustavnog rješenja već je svakoj državi članici i državama kandidatima prepušteno da u sklopu svog nacionalnog zakonodavstva specifično rješavaju pitanje oblika pod kojima se može razvijati socijalno poduzetništvo.

U Hrvatskoj je određenje socijalnog poduzetništva u državnim politikama još uvijek primarno vezano uz sektor civilnog društva. Samo u dokumentima koji su usmjereni na razvoj ovog sektora socijalno se poduzetništvo eksplicitno tematizira i identificira kao poseban oblik djelovanja. Primjerice, u sklopu Nacionalne strategije stvaranja poticajnog okruženja za razvoj civilnog društva 2012. – 2016. razmatra se razvoj socijalnog poduzetništva kao novog, prilagodljivog modela za održivi razvoj, prožetog vrijednostima civilnoga društva, koji razvojnim projektima pristupa na poduzetnički način i pridonosi općem društvenom razvoju. Kroz planiranu buduću Strategiju za razvoj socijalnog poduzetništva 2014. – 2020. treba se jasno opredijeliti za definiciju, ali i pojam: socijalno-društveno-neprofitno poduzetništvo te dodatna normativna rješenja poput Fonda za razvoj socijalnog poduzetništva, u sklopu mjera osiguranja sustava financijskih poticaja, kako bi se potaknuo veći zamah u razvoju socijalnog-poduzetničkih inicijativa (Vlada Republike Hrvatske, 2012:43-44,50.). U drugim dokumentima, koji se tiču socioekonomskog razvoja, razvoja poduzetništva te suzbijanja socijalne isključenosti, socijalno poduzetništvo ne koristi se kao termin niti se posebno spominje, iako se ovi dokumenti posredno dotiču i područja socijalnopoduzetničkih djelatnosti. Sve navedeno ukazuje na nedovoljno poznavanje niti razumijevanje fenomena socijalnog poduzetništva na institucionalnoj razini. Po nekima, razlog slabe institucionalne razvijenosti jest u percepciji o ovom fenomenu kao nečemu naslijeđenom iz socijalističkog razdoblja (Vidović, 2012:186).

Socijalno poduzetništvo u Hrvatskoj više se pojavljuje u sferi pružanja socijalnih usluga, nego radne integracije slabije zapošljivih skupina, što je dijelom povezano i sa slabijim razvojem zadruga u Hrvatskoj. Inicijativa za socijalno-poduzetnički pothvat najčešće dolazi od organizacije ili skupine, no uglavnom nedostaje inicijalni kapital potreban za pokretanje

poslovnog pothvata, za što je potreban vanjski izvor. Za pravo socijalno poduzetništvo potrebno je osigurati samoodrživost i neovisnost o vanjskim izvorima financiranja, koju još uvijek svi promatrani slučajevi ne uspijevaju postići. To se posebno odnosi na pružatelje socijalnih usluga, koji pokazuju tendenciju stvaranja partnerstva s državom (Vidović, 2012:296).

Iz istraživanja se može zaključiti da obrazovne institucije – prvenstveno sveučilišta, moraju inicirati edukaciju i pokazati da socijalno poduzetništvo promovira zajedničke interese društva te da se može razumjeti samo kroz odgovoran stav prema zajednici. Kroz prepoznavanje socijalnog poduzetništva kao mogućeg karijernog puta mladi ljudi mogu razviti ključne vještine i kompetencije koje će im pomoći da postanu važni čimbenici u procesu donošenja odluka i aktivni zastupnici pozitivnih društvenih promjena (Singer et al., 2011:21).

5. EUROPA 2020. – IZAZOVI RAZVOJA SOCIJALNOG PODUZETNIŠTVA

Početkom ozbiljnijeg promoviranja socijalne ekonomije na razini EU-a može se smatrati 2000. godina, kada je osnovana Stalna europska konferencija zadruga, društava uzajamne pomoći, udruga i zaklada (engl. *European Standing Conference of Co-operatives, Mutual societies, Associations and Foundations*; CEP-CMAF). Ova institucija 2008. godine promijenila je ime u Socijalna ekonomija Europe (engl. *Social Economy Europe*) te od tada počinje nešto ozbiljnije promovirati ulogu socijalnog poduzetništva u ekonomskom i društvenom razvoju (Vidović, 2012:111). Nadalje, europski program za poduzetništvo (engl. *European Agenda for Entrepreneurship*) donesen 2004. godine ocrtava program poticanja poduzetništva i stvaranja povoljnije poduzetničke klime, a spominje i socijalno poduzetništvo kao poseban oblik poduzetničkog djelovanja, koji adresira otvorena socijalna pitanja. Tu se socijalno poduzetništvo prepoznaje kao akter u pružanju usluga u socijalnom sektoru, kao alternativa ili nadopuna javnom sektoru (European Commission, 2004:9). U 2009. godini, Europski parlament objavio je izvješće o socijalnoj ekonomiji u kojoj iznosi pregled stanja socijalne ekonomije u EU-u. Kvantitativni podaci ukazuju na opće povećanje aktera u socijalnoj ekonomiji. Prema službenim podacima, u cijeloj Europskoj uniji postoji više od 11 milijuna radnih mjesta unutar područja socijalne ekonomije, dok se broj dionika procjenjuje na čak 160 milijuna. Akteri u socijalnoj ekonomiji čine 10 % ukupnog korpusa poduzeća u EU-u i zapošljavaju 6 % od ukupne radne populacije EU-a. Od tog postotka zaposlenih, njih 70 % zaposleno je u neprofitnim organizacijama, 26 % u zadrugama i 3 % u društvima uzajamne pomoći. Pritom se organizacije ili poduzeća socijalne ekonomije pojavljuju u gotovo svim sektorima gospodarstva – od bankarstva i osiguranja, preko poljoprivrede, obrtništva, do zdravstvenih i socijalnih usluga (Vidović, 2012:114-115).

Upravo povećanje ukupne zaposlenosti predstavlja jedan od ključnih ciljeva svih članica EU-a, čiji je zajednički cilj povećanje konkurentnosti (Zrilić, 2013) na globalnoj razini i to prvenstveno primjenom novih znanja i novih tehnologija. Nizom programa i tzv. predvodničkih inicijativa Europska komisija podupirat će ciljeve pametnog, održivog i uključivog rasta (http://www.azoo.hr), stoga je *Strategija Europa 2020.* (*Europe 2020: A European strategy for smart, sustainable and inclusive growth*) strateški dokument koji istodobno želi postići dva dugoročna cilja:

1. izlaz iz ekonomske krize i
2. razvoj posredstvom novih tehnologija.

Spomenuti ciljevi međusobno su povezani jer se smatra da će se upravo posredstvom novih tehnologija izaći iz višegodišnje ekonomske krize.

Shema 3. Razrada ciljeva i inicijativa u strategiji *Europa 2020.*

PAMETAN RAST	**ODRŽIV RAST**	**UKLJUČIV RAST**
INOVACIJE	KLIMA, ENERGETIKA I MOBILNOST	ZAPOŠLJAVANJE I VJEŠTINE
OBRAZOVANJE	KONKURENTNOST	BORBA PROTIV SIROMAŠTVA
DIGITALNO DRUŠTVO		

Izvor: http://www.azoo.hr/images/razno/eu_hr.pdf (14. 1. 2014.)

U *Strategiji Europa 2020.* socijalno poduzetništvo ili socijalna ekonomija tek se neznatno tematizira direktno, premda je značajan fokus stavljen na koncept socijalnih inovacija, za najosjetljivije, posebno kroz osiguranje obrazovanja, treninga i mogućnosti zapošljavanja za hendikepirane skupine kako bi im se osigurala mogućnost potpunog iskorištavanja njihovih potencijala. U kontekstu traženja izlaza iz financijske krize i pozicioniranja EU-a kao snažnog socijalno tržišnog gospodarstva, pozivaju se zajedničke inicijative svih aktera, privatnih i javnih, s posebnim naglaskom na malo poduzetništvo, u povećanju socijalne uključenosti i zapošljavanja (European Commission, 2010:18).

Ovo je posebno značajno stoga što strategija *Europa 2020.*, planirana za razdoblje od 2014. do 2020. godine, postavlja visoke ekonomske i društvene ciljeve kao što su smanjenje nezaposlenosti, povećanje stupnja obrazovanosti mladih, povećanje energetske učinkovitosti posredstvom korištenja obnovljivih izvora energije, zaštitu okoliša i borbu protiv siromaštva. Stoga je upravo socijalno poduzetništvo jedna od velikih mogućnosti da se zaposli značajan broj mladih ljudi, a da se istodobno realizira i čitav niz društvenih ciljeva.

Potreba da se europski ekonomski i socijalni model inovira prepoznata je i u sklopu deklaracije usvojene na konferencije socijalnih poduzetnika i podupiratelja u Strasbourgu, koja ističe da Europska unija treba model rasta koji je pravičniji, zeleniji i više utemeljen u lokalnim zajednicama, tj. model koji valorizira socijalnu koheziju kao istinski izvor kolektivnog bogatstva. Pritom su socijalni poduzetnici prepoznati kao pokretači za socijalnu i ekonomsku koheziju širom Europe, budući da mogu pomoći u izgradnju pluralističke i otporne socijalno-tržišne ekonomije (Strasbourg Declaration, 2014:1). Sve navedeno su ciljevi kojima se Republika Hrvatska treba prilagoditi putem svojih strateških dokumenata.

Za sve ciljeve koje određuje dokument *Europa 2020.* treba dodatno informirati i educirati zainteresirane skupine građana, a posebno mladih ljudi. S obzirom na to da će realizaciju tih ciljeva dodatno financirati EU, mladi ljudi moraju imati znanja o tome kako pripremiti projekte

prilagođene ciljevima koje određuje *Europa 2020*. I u toj prilagodbi, informiranju i educiranju mladih vidljive su mogućnosti za razvoj socijalnog poduzetništva (Zrilić, Širola, 2013).

6. SOCIJALNO PODUZETNIŠTVO I MLADI U EUROPSKOJ UNIJI I HRVATSKOJ

Na razini EU-a s velikom se pozornošću prati nezaposlenost mladih i podaci za pojedine države članice.

Tablica 1. Stopa nezaposlenosti mladih u razdoblju od 2009. do 2011. godine (%)

Članice / godine	2009.	2010.	2011.
EU-27	20,1	21,1	21,4
EA-17	20,3	20,9	20,8
HR	25,1	32,6	36,1

Izvor: Key figures on Europe, 2013, Edition, Eurostat, www.eurostat.eu (3. 2. 2014.)

Podaci pokazuju stope nezaposlenosti u pojedinim starosnim kategorijama stanovništva.

Tablica 2. Stope nezaposlenosti prema starosti stanovništva u razdoblju od 2010. do 2012. godine (%)

Ukupno	**2010.**	**2011.**	**2012.**
	11,8	**13,5**	**15,8**
15 - 24	32,7	36,1	43,1
25 - 49	11,1	13,2	15,5
50 - 64	7,1	8,4	10,2
65 i više	–	–	–
15 - 64	12,1	13,9	16,3

Izvor: Hrvatska u brojkama, 2013., Državni zavod za statistiku, www.dzs.hr (3. 2. 2014.)

Prema podacima iz tablice najveća stopa nezaposlenosti je u najmlađoj kategoriji radno sposobnog stanovništva od 15 do 24 godine. U svim ostalim starosnim kategorijama stope nezaposlenosti su znatno niže, što ukazuje na alarmantnu situaciju u problematici nezaposlenosti mladih.

Nažalost, nezaposlenost mladih u Hrvatskoj u razdoblju od 2009. do 2011. godine porasla je s 25,1 % na 36,1 %. Ako se, prema istom izvoru, detaljnije analiziraju podaci nezaposlenosti mladih kod pojedinih država članica, može se uočiti da Hrvatska drži visoko mjesto u toj kategoriji. Naime, podaci za 2011. godinu govore o tome da su veću stopu nezaposlenosti mladih od Hrvatske imale Španjolska (46,4 %) i Grčka (44,4 %). Nešto niže stope nezaposlenosti mladih u 2011., usporedivo s Hrvatskom, imale su Slovačka (33,5 %), Litva (32,9 %), Latvija (31,0 %) i Portugal (30,1 %). Treba napomenuti da su tijekom 2011. godine najnižu stopu nezaposlenosti mladih imale Nizozemska (7,6 %), Austrija (8,3 %) i Njemačka (8,6 %).

Socijalno poduzetništvo predstavlja dodatnu mogućnost privremenog, povremenog ili stalnog oblika zapošljavanja mladih ljudi. U situaciji kada javni sektor poduzima čitav niz reformi, a dio toga su i viškovi zaposlenih, ne može se očekivati porast broja zaposlenih u javnom sektoru. Također, postojeća struktura gospodarstva nije u stanju apsorbirati velik broj nezaposlenih mladih ljudi, a niti u perspektivi s obzirom na tehnološki razvoj koji generalno smanjuje broj zaposlenih u gospodarstvu.

U istraživanju razvijenosti socijalnog poduzetništva koje je provela agencija PULS na uzorku od 2.000 ispitanika, za GEM Hrvatska 2009. godine, utvrđena je angažiranost 2,6 % radnog stanovništva u Hrvatskoj u socijalno-poduzetničkim pothvatima u početnoj fazi, što je znatno više od prosjeka skupine zemalja srednjeg ekonomskog razvoja u koji spada Hrvatska, koji iznosi 1,8 %, pa i od prosjeka udjela socijalno-poduzetničkih aktivnosti u najrazvijenijim ekonomijama, koji iznosi 1,9 %. U socijalno je poduzetništvo, prema ovim podatcima, uključeno više muškaraca (1,7 %) nego žena (0,9 %), a prevladavaju neprofitne organizacije i tradicionalne udruge s više od jedne trećine. Ostatak čine ostale kategorije socijalnog poduzetništva, hibridni oblici i profitno orijentirana poduzeća. No podatke ove GEM studije treba ipak iščitavati oprezno, s obzirom na to da tipologija koju koristi GEM ne odgovora europskom shvaćanju socijalnog poduzetništva, jer pored neprofitnih organizacija i tradicionalnih udruga kao aktera socijalno-poduzetničkih aktivnosti, u socijalno poduzetništvo ubrajaju i profitna poduzeća koja imaju socijalne i ekološke ciljeve u određenom omjeru, te su bliži onom što se razumije kao socijalno odgovorno poslovanje. Uzmemo li u obzir navedeno, rezultati mjerenja socijalnog poduzetništva u Hrvatskoj puno su veći od očekivanog (Vidović, 2012:195).

S ciljem utvrđivanja percepcije socijalnog poduzetništva kao potencijalne komponente osobne karijere i metode rješavanja problema radi razvitka zajednice kod mladih ljudi u Hrvatskoj, u 2010. godini provedeno je istraživanje na prigodnom uzorku od 120 studenata s ukupno četiri fakulteta (ekonomije, elektronike i umjetnosti) u Zagrebu i Osijeku. Čak 60 % studenata nikad nije čulo za koncept socijalnog poduzetništva, dok je 27 (od ukupno 48) studenata izjavilo da su upoznati s konceptom jer se navedeni pojam spominje u okviru nastavnog programa (ekonomski studiji). Nadalje, gotovo 61 % ispitanika izjasnilo se da se vide kao samostalni poduzetnici u budućnosti, no čak 59 % svih studenata ne želi biti socijalni poduzetnik, navodeći sljedeće razloge (Singer et al., 2011:13-17):

1. ne razumiju što je socijalno poduzetništvo i kako funkcionira
2. nije spojivo s njihovim usmjerenjem (inženjeri elektronike)
3. nije profitabilno i
4. nemaju potrebne vještine poput kreativnosti, motivacije ili volje.

Upravo zbog velikog broja nezaposlenih, a pogotovo mladih ljudi, sigurno je da će Europska komisija morati dati jasnije preporuke o tome koji su oblici organizacije socijalnog poduzetništva pokazali najbolja iskustva te primjere dobre prakse na razini EU-a učiniti dostupnima svima koji su zainteresirani za takav oblik poduzetništva.

7. ZAKLJUČAK

Socijalno poduzetništvo izuzetno je složen pojam koji na globalnoj razini ima višestruko značenje. Na razini EU-a državama članicama i kandidatima prepušteno je da unutar svog zakonskog okvira definiraju oblike razvoja socijalnog poduzetništva. U Republici Hrvatskoj ne postoji jednoznačan pristup socijalnom poduzetništvu niti na teorijskoj razini, a niti u zakonskim rješenjima. Naime, u hrvatskom jeziku govori se o socijalnom ili društvenom poduzetništvu, a upravo korištenje tih pojmova može izazvati određene zabune. U ovom radu polazi se od pojma socijalnog poduzetništva kao primjerenijeg suštini cijelog procesa. To prvenstveno znači da se socijalno poduzetništvo sagledava kao vrsta poduzetništva orijentirana na realizaciju određenih društvenih ciljeva. Iako taj oblik poduzetništva ima sve temeljne značajke poduzetništva, ipak postoji razlika u tome što se uspješnost ne mjeri ostvarenjem dobiti.

Socijalno poduzetništvo u Hrvatskoj može se realizirati različitim oblicima sukladno zakonskim rješenjima. Najjednostavniji oblik realizacije projekata socijalnog poduzetništva su udruge, ali socijalno poduzetništvo se može provoditi i obrtima, zadrugama, trgovačkim društvima te zakladama. Svaki od ovih oblika ima svoje rizike, ali bi svakako bilo potrebno da se na razini EU-a i Hrvatske daju određene preporuke za provedbu projekata socijalnog poduzetništva. Također, oblik organizacije socijalnog poduzetništva bitno ovisi i o vrsti projekta i sektoru unutar kojeg se ostvaruju socijalni ciljevi.

Na razini EU-a Hrvatska zauzima visoko mjesto po podacima o nezaposlenosti mladih ljudi, a to je problem koji će se dugoročno rješavati. Jedna od mjera u rješavanju tog problema može biti poticanje socijalnog poduzetništva mladih. Istraživanja pokazuju da mladi ljudi nisu dovoljno informirani o mogućnostima povremenog i privremenog zapošljavanja koje pruža koncept socijalnog poduzetništva. Stoga su dodatna edukacija i informiranje zadaci koji se moraju provesti u nadležnim institucijama, a posebice visokoškolskim ustanovama.

Strateški dokument *Europa 2020.* pruža velike mogućnosti za poticanje socijalnog poduzetništva u cilju novog zapošljavanja, a pogotovo u kategoriji mladih ljudi, koji kroz brojne učeničke zadruge i druge oblike u Hrvatskoj mogu steći prve spoznaje o socijalnom poduzetništvu, a zatim se uz podršku odgovarajućih obrazovnih, konzultantskih i financijskih programa i potpora razviti u socijalnog poduzetnika i tako ostvariti samozapošljavanje, socijalnu koheziju i socijalno-tržišnu ekonomiju koju potiču i socijalni poduzetnici EU-a. Stoga je zadatak Republike Hrvatske da na svim razinama vlasti provede navedene ciljeve pametnog, održivog i uključivog rasta kao provedbu strateških ciljeva *Europa 2020*.

LITERATURA

Bubić, J. (2011) *Socijalno poduzetništvo – mogućnosti financiranja društveno – poduzetničkih aktivnosti iz fondova EU*, www.mzss.hr (15. 1. 2014.)

Bežovan, G. (2008) *Civilno društvo i kombinirana socijalna politika,* Socijalna politika Hrvatske, Puljiz, V. (ur.), Zagreb: Pravni fakultet Sveučilišta u Zagrebu, http://www. http://books.google.hr (20.1.2014.)

Deželjin J. et al. (2002) Poduzetnički *menadžment*, Zagreb: M.E.P. Consult

Economist (2004): What *is a brand, Chapter from book Brands and Branding*, http://www.brandchannel.com/images/papers/what_is_a_brand.pdf, (12. 7. 2005.)

Europa 2020. (2010) http://www.azoo.hr/images/razno/eu_hr.pdf (14. 1. 2014.)

European Commission (2010) *Europe 2020, A European strategy for smart, sustainable and inclusive growth*, Brussels, http://europa.eu/pdf/complet_en_barroso_007_-_europe_2020_-en_version.pdf (18. 7.2011.)

European Commission (2004) *Action Plan: The European Agenda for Entrepreneurship*, ftp://ftp.cordis.europa.eu/pub/incubators/docs/action_plan_on_entrepreneurship.pdf (14. 1. 2014.)

European Commission (2003) *Green Paper Entrepreneurship in Europe*, http://eur-lex.europa.eu/LexUriServ/site/en/com/2003/com2003_0027en01.pdf (4. 1. 2008.)

European Economic and Social Committee (2014) Strasbourg Declaration, http://www.eesc.europa.eu (20. 1. 2014.)

Hisrich, R. D., Peters, M. P., Shepherd, D. A. (2011) *Poduzetništvo*, Zagreb: Mate

Jelavić, A., Ravlić, P. (1995) *Ekonomika poduzeća*, Split: Ekonomski fakultet

Martin, R. L., Osberg, S. (2009) Socijalno poduzetništvo, Čakovec: Autonomni centar – ACT

Meler, M. (2003) *Neprofitni marketing*, Osijek: Ekonomski fakultet

NESsT Publications, http://www.nesst.org/social-enterprise/ (10. 1. 2014.)

Singer, S., Perić, J., Delić, A. (2011) *Social Entrepreneurship in Croatia: do regional disparities influence young people's perception of social entrepreneurship as a potential career path?*, NYU Stern Conference of Social Entrepreneurship

Siropolis, N. C. (1995) *Menadžment malog poduzeća: vodič u poduzetništvo*, Zagreb: Mate, Hrvatska obrtnička komora

Vidović, D. (2012) *Socijalno poduzetništvo u Hrvatskoj*, doktorska disertacija, Zagreb: Filozofski fakultet

Vlada Republike Hrvatske (2012) Nacionalna strategija stvaranja poticajnog okruženja za razvoj civilnog društva 2012. – 2016., Zagreb, www.uzuvrh.hr/userfiles/file/Nacionalna_strategija_FINAL.pdf, 20. 10. 2013.

Zrilić, N. (2013) *Izazovi razvoja hrvatskog gospodarstva* - dugo dopunjeno izdanje, Rijeka: vlastita naklada, dostupno http://www.veleri.hr/?q=node/109.

Zrilić, N., Širola, D. (2013) Razvoj poduzetništva mladih – neiskorišteni potencijal Hrvatske, *Zbornik Veleučilišta u Rijeci*, Vol. 1., No. 1., p. 95-111

Nataša Zrilić[1]
Davor Širola[2]

Review article
UDK 364-053.81:65.01
331.56-053.81

SOCIAL ENTREPRENEURSHIP – NEW EMPLOYMENT OPPORTUNITIES FOR YOUNG PEOPLE IN CROATIA[3]

ABSTRACT

Social entrepreneurship is a specific form of entrepreneurship based on the principles of social, ecological and economic sustainability, which mainly implies reinvesting the profits for community benefits, but it is commonly misunderstood regarding its purpose and potentials. In Europe and in the world there is a growing trend towards the establishment of various forms of social entrepreneurship. The European Union emphasizes further engagement in creating normative and operational grounds for social entrepreneurship support system in accordance with the adopted new economic and social growth model. Legal models in Croatia enable the realization of various entrepreneurial projects and the funds of the European Union support such initiatives. The issue of youth unemployment in the Republic of Croatia, as well as throughout the European Union, requires that social entrepreneurship be stimulated in an organized manner, at all levels, with the aim of creating new employment. By implementing corresponding strategic documents and legal acts, Croatia can improve its educational, consulting and financial preconditions for obtaining more financial support from the European Union, and in this way be able to significantly develop social entrepreneurship, thereby making it easier for young people to enter the world of work.

Key words: *entrepreneurship, social entrepreneurship, youth unemployment*

[1] PhD, College Professor, Adviser to the Mayor for development, City of Rijeka, Korzo 16, Rijeka, Croatia. E-mail: natasa.zrilic@rijeka.hr

[2] Master of marketing management, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: davor.sirola@veleri.hr

[3] Received: 13. 2. 2014.; accepted: 5. 5. 2014.

Denis Buterin[1]
Julijan Plenča[2]
Eda Ribarić Aidone[3]

Pregledni rad
UDK 336.76:65.011.3

MOGUĆNOSTI I RIZICI INVESTIRANJA NA *FOREX* TRŽIŠTU[4]

SAŽETAK

Foreign exchange market, odnosno forex je međunarodno tržište najznačajnijih svjetskih valuta i najlikvidnije je tržište na svijetu. Razvojem interneta i komunikacijske tehnologije sve se više malih ulagača uključuje na to tržište nastojeći ostvariti zaradu špekulativnim ulaganjima. Premda se u Hrvatskoj javnosti forex često spominje u negativnom kontekstu, zbog velikih mogućnosti koje to tržište pruža može se očekivati i uključivanje hrvatskih ulagača. Mogućnosti trgovanja koje su karakteristične samo za forex tržište pružaju prilike koje poticajno djeluju na privlačenje brojnih ulagača, osobito malih. U radu se na temelju podataka analizira način funkcioniranja međunarodnog tržišta valuta i predviđa se njegov mogući značaj za hrvatske ulagače. Cilj rada je ukazati na mogućnosti i rizike prisutne na forex tržištu, kao i na specifičnosti tog tržišta u odnosu na druga financijska tržišta. Zbog svojih posebnosti, forex tržište pruža velike mogućnosti zarađivanja, ali isto tako, otvorena je i velika mogućnost brzih i trajnih gubitaka. U radu je istaknuta važnost dobre pripreme, prikupljanja informacija i stjecanja znanja prije ulaska na forex tržište i odluke o investiranju, što je osobito važno jer veličina tržišta i njegov špekulativni karakter mogu izazvati gubitke koji posljedično mogu smanjiti investicijski potencijal i imati prorecesijsko djelovanje

***Ključne riječi**: novac, forex, analize, financijski rizici*

1. UVOD

Trgovanje valutama na međunarodnom tržištu hrvatskoj je javnosti relativno nepoznato. Do početka devedesetih godina dvadesetog stoljeća pristup međunarodnom valutnom tržištu imali su samo veliki ulagači. Razvojem interneta otvorile su se mogućnosti pristupa tom tržištu gotovo svakom zainteresiranom ulagaču. Budući da se radi o najvećem tržištu na svijetu, otvorene su i brojne mogućnosti zarađivanja, ali i financijskih gubitaka. Trgovanje valutama na međunarodnom tržištu hrvatskoj je javnosti relativno nepoznato. Međutim, može se očekivati kako će zbog protoka informacija i ulagači iz Hrvatske biti privučeni mogućnostima koje trgovanje valutama nudi. Za ulagače je vrlo bitno steći osnovna znanja o pravilima trgovanja i o mogućim rizicima prije samog ulaska na tržište. Za razliku od tržišta vrijednosnih papira gdje se eventualni dobici i gubici s vremenom ipak mogu mijenjati i nivelirati, specifičnosti funkcioniranja međunarodnog valutnog tržišta mogu dovesti do nepovratnih gubitaka u vrlo kratkom roku.

[1] Mr. sc., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* denis.buterin@veleri.hr
[2] Student, bacc. oec. *E-mail:* plencajulijan@yahoo.com
[3] Mr. sc., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* eribaric@veleri.hr
[4] Datum primitka rada: 17. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

Premda u svojoj osnovi *forex* nije zamišljeno kao tržište namijenjeno špekulaciji, upravo se takvim poslovima na *forex* tržištu mogu ostvariti značajni dobici. Ipak, špekulacije na tom tržištu u bitnome se razlikuju od špekulacija na drugim financijskim tržištima ili tržištima vrijednosnih papira na kojima dio hrvatskih ulagača ima stečena znanja i iskustva. U tom smislu, cilj ovoga rada je ukazati na važnost uočavanja tih razlika i stjecanja osnovnih znanja prije uključivanja na međunarodno tržite valuta.

U članku se obrazlažu najvažnije značajke međunarodnog trgovanja valutama, povijest *forexa*, načini funkcioniranja i pregled brojčanih pokazatelja o valutama i valutnim parovima kojima se najviše trguje. Posebno su objašnjene specifičnosti, strategije i dio terminologije karakteristične za *forex* tržište da bi se njihovim razumijevanjem ukazalo na mogućnosti, ali i na prisutne potencijalne rizike.

2. RELEVANTNE ZNAČAJKE MEĐUNARODNOG TRGOVANJA VALUTAMA

Foreign exchange market ili skraćeno *forex* ili FX tržište je međunarodno tržište na kojem se trguje najznačajnijim svjetskim valutama. To tržište deviza u današnjem obliku postoji od 70-tih godina dvadesetog stoljeća kada se prešlo, s fiksnih, na sustav plutajućih, mjenjačkih tečajeva valuta. U nastavku su predočene temeljne karakteristike *forexa*, kao i razvoj ovoga tržišta.

2.1 Bitne karakteristike *forexa*

Forex predstavlja najlikvidnije tržište na svijetu s dnevnim prometom koji trenutno premašuje 5,3 trilijuna[5] američkih dolara (Bank for International Settlements, 2013: 9). Do cjenovne praznine koja se dogodi kada u datom trenutku nema sudionika koji žele zaključiti posao gotovo da nikad ne dolazi, pa stoga takva pojava može biti svrstana u izuzetke. U normalnim okolnostima, na tržištu uvijek postoji dovoljno trgovaca koji žele zaključiti posao.

Međunarodno tržište deviza ostvaruje se putem djelovanja financijskih institucija, a na nekoliko razina funkcionira pristup ovisan o financijskoj snazi i veličini trgovca. Uobičajene transakcije na FX tržištu odnose se na kupovinu određenog iznosa jedne valute plaćanjem određenog iznosa druge valute, ovisno o tečaju koji se neprekidno mijenja. Omogućavanjem konverzije valuta, FX tržište olakšava međunarodnu trgovinu i investicije. Zbog neprestanog mijenjanja tečaja, FX tržište vrlo je pogodno za špekulativne i arbitražne poslove. Međunarodno tržište deviza funkcionira 24 sata dnevno, od ponedjeljka do petka, a ovisno je o vremenskim zonama te prelazi preko glavnih financijskih centara: Londona, New Yorka, Tokia, Zuricha, Frankfurta, Hong Konga, Singapura, Pariza i Sydneya. *OTC* (eng. *over the counter*) transakcije predstavljaju transakcije izvršene izvan uređenog tržišta. FX OTC tržište postoji isključivo na ekranima računala i na telefonskim linijama i nema fizički parket za trgovanje.

[5] Trilijun = 1.000 milijardi

Svakih šest mjeseci, vodeće središnje banke svijeta dostavljaju statističke podatke o FX trgovini, a objavljuje ih Banka za međunarodna poravnanja – *Bank for International Settlements*[6] (Finberg, 2013). Podaci na grafikonu 1 redovito pokazuju rast i nove rekordne razine prometa.

Grafikon 1. Dnevni promet na FX tržištu u milijardama USD, stalne cijene iz 2013. g.

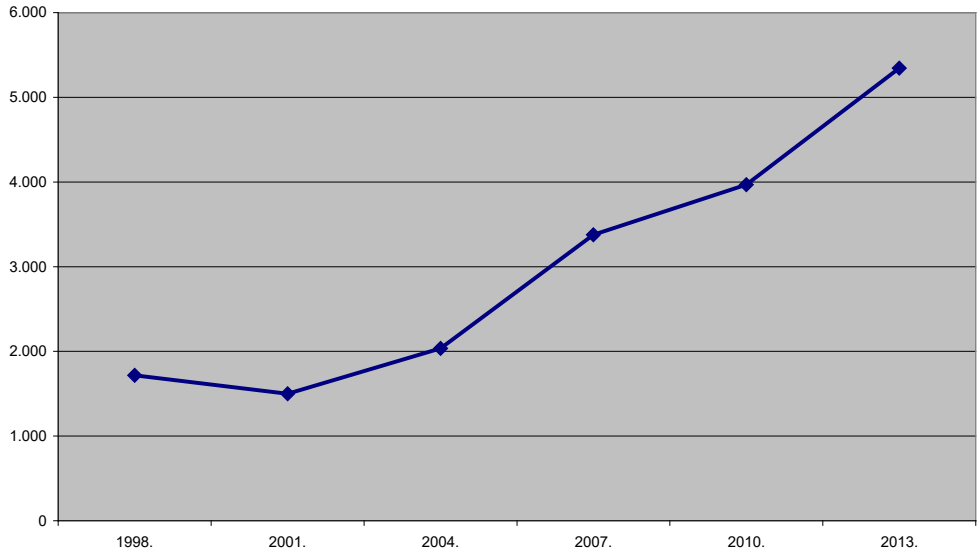

Izvor: Bank for International Settlements (2013: 9)

Spot tržište, *forward* tržište i *futures* tržište predstavljaju načine trgovanja pojedinaca i kompanija. Spot tržište je tržište gdje se valute kupuju i prodaju po trenutnoj cijeni. Ono je najpopularnije tržište za špekulante i investitore. Kada se govori o *forexu,* najčešće se to odnosi na *spot* tržište. Za razliku od *spot* tržišta, na *forward* i *futures* tržištima se trguje ugovorima koji reprezentiraju pravo na određenu valutu, po točno određenoj cijeni i datumu izvršavanja transakcije. Tako se na *forward* tržištu ugovori kupuju i prodaju preko OTC, između dvije strane koje same dogovaraju uvjete ugovora. Na *futures* tržištima ugovori se kupuju i prodaju u standardiziranim iznosima i datumima izvršenja na burzama roba. *Futuresi* su standardizirani terminski ugovori s definiranim svim osnovnim značajkama, osim cijene. Oba tipa ugovora su obvezujuća i izvršavaju se obično po dospijeću. *Forward i futures* tržišta se često koriste za zaštitu od rizika. Kao osnovnu valutu, *forex* tržište koristi američki dolar, koji je ujedno i osnovna valuta za trgovanje. Pregled valuta kojima se najviše trguje prikazan je u tablici 1.[7]

[6] Godine 2013. podatke su dostavile centralne banke ili institucije monetarne vlasti iz 53 zemlje.

[7] Budući da valutne parove čine dvije valute te da se zbog toga svaka valuta pojavljuje dvaput, ukupni zbroj svih valutnih parova iznosi 200.

Tablica 1. Valute kojima se najviše trguje na FX tržištu

Valuta	2001.		2004.		2007.		2010.		2013.	
	udio %	rang	udio %	rang	udio %	rang	udio %	rang	udio %	rang
USD	89,9	1	88,0	1	85,6	1	84,9	1	87,0	1
EUR	37,9	2	37,4	2	37,0	2	39,1	2	33,4	2
JPY	23,5	3	20,8	3	17,2	3	19,0	3	23,0	3
GBP	13,0	4	16,5	4	14,9	4	12,9	4	11,8	4
AUD	4,3	7	6,0	6	6,6	6	7,6	5	8,6	5
CHF	6,0	5	6,0	5	6,8	5	6,3	6	5,2	6
CAD	4,5	6	4,2	7	4,3	7	5,3	7	4,6	7

Izvor: Bank for International Settlements (2013: 10)

Navedena tablica pokazuje da je američki dolar valuta koja je činila između 80 i 90 % svih valutnih trgovanja, a euro je sačinjavao između 30 i 40 % trgovine. Pored američkog dolara kojim se uvjerljivo najviše trguje, vrlo su zastupljeni euro i japanski jen. Sedam valuta kojima se najviše trguje čini gotovo 90 % prometa na FX tržištu. Od 2004. godine primjetan je pad trgovanja eurom i britanskom funtom te porast trgovanja japanskim jenom. Zanimljivo je primijetiti da među najvećih sedam nema kineskog juana ni ruske rublje, premda se radi o gospodarski vrlo snažnim državama.

Kod čitanja valutnih kvota bitno je znati dva pravila: prvo, valuta u paru navedena na prvom mjestu je osnovna valuta (*base currency*), a na drugom mjestu je kotirana valuta (*quote currency*), i drugo, vrijednost osnovne valute je uvijek 1,00. U tablici 2 prikazani su valutni parovi s najvećim prometom.

Tablica 2. Valutni parovi s najvećim prometom, prosječni dnevni promet u milijardama USD, tekuće cijene

Valutni par	2010.		2013.	
	iznos	udio %	iznos	udio %
USD/EUR	1.098	27,7	1.289	24,1
USD/JPY	567	14,3	978	18,3
USD/GBP	360	9,1	472	8,8
USD/AUD	248	6,3	364	6,8
USD/CAD	182	4,6	200	3,7
USD/CHF	166	4,2	184	3,4
USD/MXN	...	...	128	2,4
USD/CNY	31	0,8	113	2,1
USD/NZD	...	...	82	1,5
USD/RUB	...	...	79	1,5
EUR/JPY	111	2,8	147	2,8
EUR/GBP	109	2,7	102	1,9
EUR/CHF	71	1,8	71	1,3

Izvor: Bank for International Settlements (2013: 11)

Najveći dio prometa odnosi se na trgovinu američkog dolara s ostalim valutama pa je američki dolar često bazna valuta u valutnom paru. Više od 50 % prometa odvija se trgovinom američkog dolara s eurom, japanskim jenom i britanskom funtom. Na trgovinu s kineskim juanom i ruskom rubljom otpada oko 3 % prometa. Valutni parovi koji u sebi sadrže američki dolar nazivaju se glavnim parovima, a ostali se nazivaju ukrštenim valutnim parovima.

FX tržište čine komercijalne banke, centralne banke, financijske institucije i fondovi. Procjenjuje se da je oko 80 % FX transakcija špekulativne naravi, što bi značilo da onaj tko je valutu kupio ili prodao nema, zapravo, namjeru tu istu valutu preuzeti ili isporučiti nego isključivo ostvariti zaradu na trenutnom kretanju i kolebanju cijena. Time se naročito bave *hedge* fondovi koji se bave posuđivanjem i trgovanjem milijardama dolara.

Zahvaljujući razvoju trgovinskih platformi, individualni trgovci sve više sudjeluju na tržištu i predstavljaju rastući segment FX tržišta, premda trenutno mogu trgovati samo putem banaka ili putem brokera.

Banke su važne za *forex* tržište i jer olakšavaju poslove između dviju strana i špekuliraju s valutama, što često čini značajan udio njihovih prihoda. Centralne banke sudjeluju na tržištu deviza u korist i zbog interesa vlastitih zemalja i vlastite monetarne politike. Banke se smatraju toliko velikim igračima da se *forex* tržište naziva i *međubankarsko tržište*. U tablici 3 prikazani su najznačajniji sudionici na FX tržištu.

Tablica 3. Najznačajniji trgovci po prometu na FX tržištu u 2013. godini

Naziv	**Sjedište**	**Udio %**
DEUTSCHE BANK	Njemačka	15,18
CITI	SAD	14,90
BARCLAYS INVESTMENT BANK	Velika Britanija	10,24
UBS AG	Švicarska	10,11
HSBC	Velika Britanija	6,93
JPMORGAN	SAD	6,07
ROYAL BANK OF SCOTLAND	Velika Britanija	5,62
CREDIT SUISSE	Švicarska	3,70
MORGAN STANLEY	SAD	3,15
BANK OF AMERICA MERRILL LYNCH	SAD	3,08

Izvor: Euromoney (2013)

Devet godina za redom njemačka Deutsche Bank je najveći FX trgovac, s ukupnim udjelom od 15,18 % tržišta. Prikazanih deset najvećih trgovaca čine ukupno 78,98 % FX tržišta što govori o važnosti banaka za to tržište, ali i važnosti FX poslova u ukupnim aktivnostima velikih američkih i europskih banaka. Svih deset najvećih sudionika na FX tržištu imaju sjedišta u Europi ili SAD. Najznačajnije svjetsko financijsko središte FX trgovine je London, s gotovo 38 % svjetskog FX prometa (Garnham, 2012).

Prednosti sudjelovanja na *forex* tržištu u odnosu na druga tržišta su brojne. Osim ogromne likvidnosti i lagane dostupnosti i pristupa, tu su još trgovanje uz polugu i kvaliteta izvršenja. Iako zbog specifičnosti samog predmeta trgovine ne postoji tijelo koje bi učinkovito nadziralo *forex* tržište, zbog velikog opsega trgovine, manipulacije tržištem teško su moguće.

2.2 Razvoj *forexa*

Može se reći da trgovanje devizama postoji od same pojave novca. Postoje pisani tragovi o potrebi razmjene novca različitih gradova i država još iz vremena antičke Grčke i ljudima koji su se time bavili (Crump, 1981: 47). U vrijeme srednjeg vijeka razmjena novca postojala je u smanjenom obliku jer je i svjetska trgovina stagnirala. U 15. stoljeću, na području današnje Italije, osobito je bila poznata bankarska i mjenjačka aktivnost obitelji Medici. Već u 17. stoljeću u Amsterdamu je postojalo aktivno i razvijeno tržište valutama.

Jedan od najvažnijih događaja u povijesti *Forexa* zasigurno je prihvaćanje monetarnog sustava na temelju zlatnog standarda u drugoj polovici 19. stoljeća. Temeljna je ideja zlatnog standarda državna garancija konverzije valute za određeni iznos zlata. U to doba sve su gospodarski važne države imale definirani odnos valute i unce zlata. Razlika u cijeni unce zlata postala je temeljni tečaj razmjene valuta. To je bio prvi standardizirani način razmjene valuta u povijesti. Međutim, tijekom Prvog svjetskog rata, zbog povećanih potreba financiranja rata i inflacije, zlatni standard je napušten. Države su počele puštati novac u opticaj bez definiranog omjera.

Krajem Drugog svjetskog rata savezničke su države zaključile da postoji potreba za monetarnim sustavom koji će zamijeniti nekadašnji zlatni standard. Godine 1944. sastali su se predstavnici savezničkih država u američkom gradiću *Bretton Woods*. Sastanak u Bretton Woodsu je rezultirao međunarodnim dogovorom koji će kasnije biti poznat kao *Bretton Woods sustav međunarodnog monetarnog upravljanja*. Taj sustav je doveo do priznavanja dolara kao zamjene zlatnog standarda i postao je glavna rezervna valuta. Također, u Bretton Woodsu osnovane su međunarodne agencije koje će nadgledati ekonomsku aktivnost. Te agencije su danas poznate kao Međunarodni monetarni fond (MMF), Međunarodna banka za obnovu i razvoj te Opći sporazum o carinama i trgovini (GATT). Tako je dolar kao glavna valuta jedini imao pokriće u zlatu.

Tijekom vremena, u ranim sedamdesetim godinama, zlatne rezerve SAD-a su bile potrošene, što je dovelo do toga da ministarstvo financija nije imalo dovoljno zlata za pokriće svih dolara u inozemnim bankama. Zbog nedostatka zlata, američki predsjednik Nixon je 1971. godine ukinuo zlatne rezerve dolara i time ukinuo *Bretton Woods* sustav, nakon čega je prihvaćen fluktuirajući valutni tečaj. No, iako je zlatni standard napušten, fluktuirajući valutni tečaj nisu uvele sve države (Madura, 2011: 134). Nastala su tri nova sustava upravljanja tečajem: dolarizacija, vezani valutni tečaj i upravljani slobodni tečaj. Dolarizacija predstavlja prihvaćanje dolara u državi kao svoje vlastite valute. Iako se smatra da je dolarizacija dobra za gospodarstvo, veliku manu predstavlja nemogućnost izdavanja vlastitog novca i vođenje monetarne politike. Vezani valutni tečaj, s druge strane, je kada država odluči fiksirati tečaj svoje valute za neku drugu valutu. Tako se često omogućuje stabilnost valute, no isto tako, u slučaju velikog pada valute, pati vezani tečaj. Upravljani slobodni tečaj je, za razliku od prva dva, slobodan i mijenja se u odnosu ponude i potražnje. U slučaju velikih fluktuacija, centralne banke interveniraju dižući ili smanjujući kamatne stope kako

bi stabilizirale tečaj. Nakon napuštanja zlatnih rezervi razvila se potreba trgovanja devizama što je dovelo do bržeg razvoja ovog specifičnog tržišta.

FX tržište u hrvatskoj javnosti postalo je poznato kada je jedan zaposlenik nekadašnje Riječke banke trgovanjem i špekuliranjem na međunarodnom deviznom tržištu izgubio veliki novac i gotovo doveo banku do stečaja. Nastala je panika koju su najbolje oslikavali redovi uplašenih štediša koji su satima čekali ispred poslovnica banke. Banka je ubrzo potom prodana stranom investitoru i prestala postojati pod dotadašnjim imenom. Ovaj je događaj, osim gašenja imena banke i redova pred šalterima, doveo i do stvaranja negativnoga stava u javnosti prema špekuliranju na deviznom tržištu.

Hrvatska javnost još se jednom susrela s nazivom *forex* u negativnom kontekstu putem piramidalnih i *Ponzievih* shema koje su ga zlorabile u nezakonitim poslovima koji su doveli do prijevare lakovjernih ulagača i do značajnih gubitaka. Istovremeno, budući da ne postoji organizirano mjesto trgovanja devizama kao što postoji Zagrebačka burza kao mjesto trgovanja vrijednosnicama, veliki dio hrvatske javnosti nije imao priliku informirati se o *forexu* i steći osnovna znanja i motive za trgovanje. Zbog svega toga, još se ponegdje mogu čuti mišljenja kako je *forex* zapravo zabranjen ili, u najmanju ruku, moralno dvojben i financijski opasan.

Izmjenama i dopunama Zakona o deviznom poslovanju (Narodne novine, br. 153/09) ukinuta je zabrana sudjelovanja rezidenata na deviznom tržištu izvan Republike Hrvatske čime je omogućeno uključivanje u globalne financijske tokove i sudjelovanje na globalnom financijskom tržištu. Malim ulagačima na deviznom tržištu na raspolaganju je trgovanje putem interneta, korištenjem raznih trgovinskih platformi i alata koje brokeri, odnosno banke nude u sklopu svojih ponuda.

3. SPECIFIČNOSTI *FOREX* TRŽIŠTA

Forex tržište karakteriziraju određene specifičnosti, stoga su u nastavku predočeni alati i strategije na *forex* tržištu, kao i prednosti i nedostaci ovoga tržišta.

3.1 Alati i strategije na FX tržištu

Tehnička analiza proučava tržišna kretanja, primarno korištenjem grafikona i indikatora u svrhu predviđanja budućih cjenovnih trendova (Murphy, 2007: 25). Temeljno načelo tehničke analize je, pomoću podataka o kretanju tečaja u prošlosti, mogućnost predviđanja očekivanoga kretanja tečaja u budućnosti. Tržišna kretanja uključuju tri glavna izvora informacija dostupnih analitičaru: cijenu, obujam trgovine i kamate. Za razliku od pojma tržišnih kretanja, cjenovna kretanja su puno uži pojam. Tehnički pristup se temelji na dvije glavne pretpostavke. Prva govori da tržišna kretanja uzimaju u obzir sve dostupne informacije. Ta zakonitost se smatra temeljem tehničke analize. Druga pretpostavka tehničke analize prikazuje kako tržište na nove informacije reagira s određenim vremenskim odmakom. Potrebno je uzimati u obzir sve što potencijalno može utjecati na cijenu. Utjecaji mogu biti fundamentalni, politički, psihološki, ekonomski i mnogi drugi. Druga pretpostavka zapravo polazi od činjenice da cijene uvijek slijede trendove. To znači da će se trenutni trend uglavnom vjerojatnije nastaviti nego okrenuti. Cijeli pristup slijeđenja trenda sastoji se u njegovom iskorištavanju sve dok se ne pokažu signali obrata. Treba napomenuti da

veliki sudionici na FX tržištu imaju najmodernije kompjuterske programe i sustave koji neprestano uočavaju nepravilnosti i nelogičnosti u kretanju različitih tečajeva da bi na njihovom iskorištavanju mogli promptno zaraditi. Zbog toga nedosljednosti u kretanju tečajeva traju vrlo kratko i mjere se u sekundama pa je malom ulagaču na njima gotovo nemoguće ostvariti zaradu. U tom smislu, puno više mogućnosti za zaradu pruža praćenje i slijeđenje trenda.

Tehnička analiza je doživjela razvoj raznih tehničkih studija i tehničkih indikatora u posljednjim godinama. Najpoznatiji su: *Bollinger Bands*, *Moving Averages* (pokretni prosjeci), *Parabolic SAR*, *MACD*, *RSI*, Stohastika, standardna devijacija. U praksi se koristi preko 60 indikatora. Iako su indikatori ugrađeni u svakoj trgovačkoj platformi i smatraju se obaveznim sredstvom trgovanja, zbog njihove brojnosti i različitosti potreban je oprez kod interpretacije rezultata.

Vrlo slično kao i kod trgovanja dionicama, gdje se fundamentalnom analizom nastoji procijeniti vrijednost poduzeća, fundamentalnoj analizi na FX tržištu je cilj procijeniti državu i njezinu valutu. Bitni su gospodarski i makroekonomski podaci, te svi drugi podaci koji imaju utjecaj na gospodarske performanse promatrane zemlje. Osobito se promatraju stope gospodarskog rasta i kamatne stope. Kamatne stope bitne su zbog specifičnog načina zarađivanja koji se zove „*currency carry trade*". Investitor posuđuje valutu u zemlji gdje su kamatne stope niske, npr. u Japanu, gdje se kamatne stope kreću blizu nule, i konvertira je u valutu gdje su kamate veće i potom zarađuje na razlici u kamatama. Npr., investitor posuđuje od japanske banke 1.000 JPY i konvertira ih u USD s kojima na američkom tržištu kupuje obveznicu s 5 % kamate. Po naplati kamate, USD konvertira natrag u JPY i vraća posuđeni novac. U slučaju da se za vrijeme držanja obveznice tečaj valutnog para značajno ne promijeni, investitor zarađuje na razlici u kamatama što je u ovom slučaju gotovo 5 %. Ako se uzme u obzir mogućnost trgovanja na polugu, zarada se može višestruko umnožiti. A ako za vrijeme držanja obveznice tečaj USD naraste u odnosu na JPY, investitor ostvaruje dodatnu zaradu. Fundamentalna analiza služi izračunu mogućnost promjene valutnog tečaja koji, zapravo, predstavlja glavni rizik u ovome poslu.

PIP (engl. *percentage in point*) predstavlja najmanju kotaciju valutnog tečaja valutnog para, odnosno najmanji iznos za koji se može promijeniti tečaj bazne valute ili valutnog para. Kod američkog dolara, eura, švicarskog franka i britanske funte jedan pip je 0,0001. Jednostavnije rečeno, jedan pip kod američkog dolara iznosi 1/100 centa. Kod valuta koje kotiraju s dva decimalna mjesta, poput japanskog jena, jedan pip iznosi 0,01. Najčešće se trguje u rasponu do 100 pipova u jednom danu. Npr., ako se trenutni tečaj valutnog para EUR/USD=1.2990 (1 EUR = 1,29 USD) poveća na 1.3000, kaže se da se omjer cijena povećao za 10 pipova. Kupac koji bi platio 129.900 USD po trenutnom tečaju, nakon aprecijacije od 10 pipova imao bi vrijednost od 130.000 USD i zaradu od 100 USD.

Za razliku od tržišta dionica, FX tržište podijeljeno je na više razina, ovisno o snazi sudionika. Na vrhu su najveće komercijalne banke i investicijski fondovi. Raspon cijena (*spread*) razlikuje se ovisno o razini pristupa, a cijene na pojedinoj razini nisu poznate ulagačima na nižim razinama. Razlog tome leži u volumenima, jer najveći igrači provode veliki broj transakcija i trguju velikim iznosima pa mogu zahtijevati manju razliku između ponude i potražnje, odnosno manji i bolji *spread.*

Poluga predstavlja kreditnu podršku brokera svojim klijentima. Na taj način individualni trgovci koji često ne raspolažu velikim iznosima novca, dobivaju bolji pristup tržištu. Ako je poluga npr.

1:100 ili 1 % to znači da sudionik nastupa na tržištu s iznosom koji je sto puta veći od onoga kojim vrši određenu operaciju. Broker traži samo polog od 1.000 USD na računu da bi investitor trgovao sa 100.000 USD. Ovaj iznos od 1.000 USD se naziva marža i služi kao garancija za gubitke (Maričić, 2004: 5). Međutim, premda je poluga velika prednost, u njoj se istovremeno krije i velika opasnost jer se u slučaju pogrešne procjene kretanja tečaja gubici umnožavaju jednako kao i dobici.

3.2 Prednosti i nedostaci FX tržišta

Brzom rastu FX tržišta pridonosi nekoliko glavnih značajki: njegova veličina i globalna struktura zbog koje je otvoreno 24 sata dnevno, likvidnost koja je neusporediva s bilo kojim drugim tržištem na svijetu, dubina tržišta te velike mogućnosti trgovanja na *margini*. Razvoj interneta i kompjuterske tehnologije predstavlja tehničku pretpostavku da navedene značajke uopće dođu do izražaja u tolikoj mjeri. Isto tako, razvoj interneta i tehnologije otvorio je brojnim malim ulagačima mogućnost uključivanja na tržište kojem su dotad samo veliki i značajni sudionici imali pristup. Na grafikonu 2 je, temeljem dosadašnjih podataka, uz pomoć linije trenda prikazano predviđanje budućeg prometa na FX tržištu.

Grafikon 2. Dnevni promet na FX tržištu – linija trenda

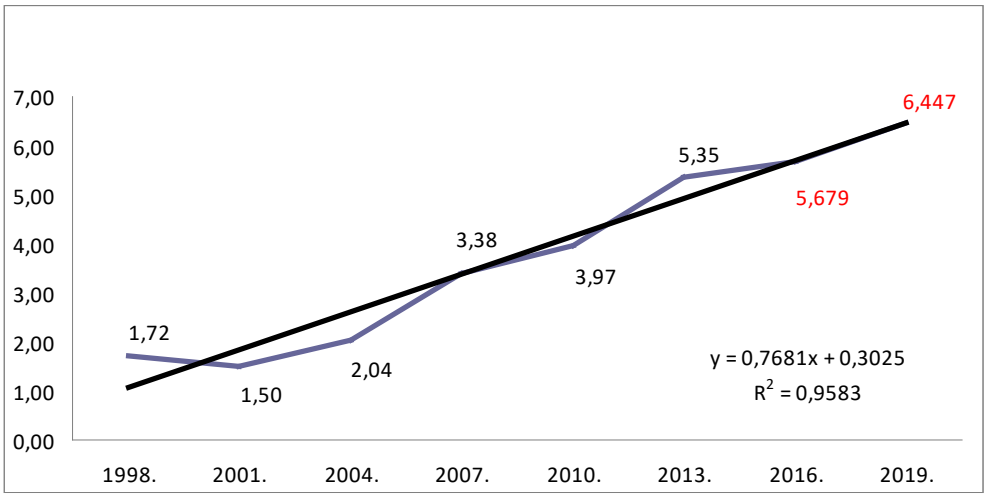

Izvor: obrada autora prema Bank for International Settlements (2013)

FX tržište funkcionira znatno jednostavnije u usporedbi s klasičnim tržištima vrijednosnih papira jer se najčešće trguje s malim brojem valutnih parova. Stoga je jednostavnije praćenje i analiza pokazatelja koji su bitni za trgovanje. Ipak, zbog tako uske usredotočenosti, reakcije velikih investitora vrlo su brze pa ne ostaje puno vremena za ostvarivanje profita na vijestima o promjenama makroekonomskih pokazatelja promatranih zemalja i njihovih valuta.

Budući da je FX tržište sve češće u interesu malih ulagača i budući da se očekuje da će njihov udio s vremenom još više rasti, oni predstavljaju značajan segment tržišta koji sve više postaje zanimljiv brokerskim kućama širom svijeta. Brokeri ulagačima nude potporu u vidu mogućnosti trgovanja

uz veliku *marginu*, trgovanje bez provizije ili naknade, gdje sam raspon cijene, odnosno *spread* postaje brokerska zarada. Dodatno se nude besplatne edukacije i korištenje trgovinske platforme bez naknade ili pak vođenje upravljanih računa za investitore koji nemaju sklonosti sami ulaziti u problematiku trgovanja. Isto tako, u nekadašnjim tranzicijskim zemljama koje su se ranije pridružile EU-u, aktivno se trguje na FX tržištu. Grafikon 3 prikazuje promet u 10 nekadašnjih tranzicijskih zemalja (Češka, Slovačka, Poljska, Mađarska, Latvija, Litva, Estonija, Bugarska, Rumunjska i Slovenija).

Grafikon 3. Dnevni FX promet u nekadašnjim tranzicijskim zemljama, u milijardama dolara

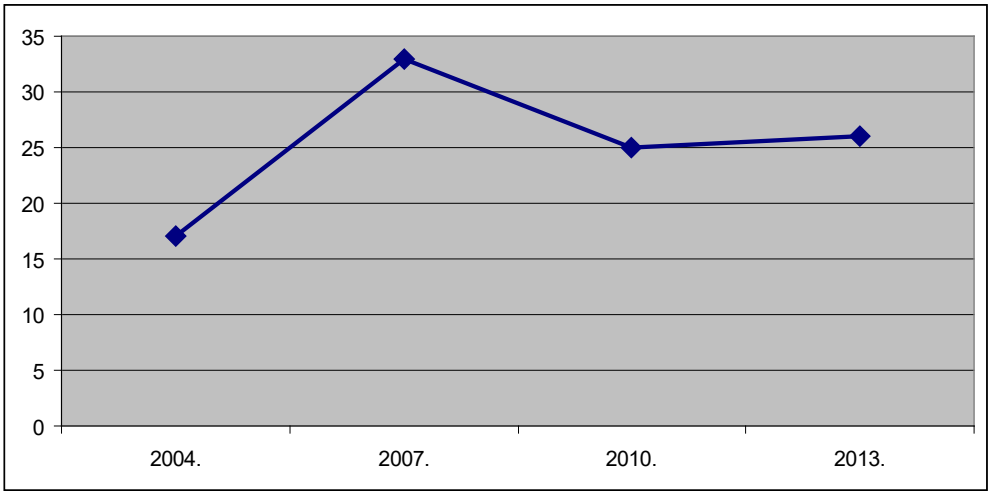

Izvor: obrada autora prema Bank for International Settlements (2013)

Očekuje se da će FX promet u tranzicijskim zemljama i dalje rasti, bez obzira na privremeni pad koji se pojavio zbog gospodarske krize.

Zbog svega navedenoga, usprkos recesiji i krizi te bez obzira na negativan kontekst u kojem se *forex* dosad pojavljivao, i u Hrvatskoj se može očekivati značajan porast broja malih ulagača. Međutim, bez obzira na sve navedene prednosti *forexa*, treba napomenuti da za uspješno trgovanje ipak treba imati određenu razinu stručnosti i informiranosti. Zbog izrazite dubine tržišta, manipulacije tečajevima teško su moguće pa kod neiskusnih ulagača može doći do idealiziranja FX tržišta. Nakon negativnih iskustava s imenom *forex* u Hrvatskoj te nakon znatnih gubitaka ostvarenih zbog kraha hrvatskog investicijskog balona, ulazak na ovakvo tržište može se činiti vrlo privlačnim. U osnovi, FX tržište i jest takvo, ali zajedno s velikim mogućnostima koje ono nudi, dolaze i veliki rizici. Jedan od takvih rizika je trgovanje na polugu koja je višestruko veća nego što je to slučaj kod trgovanja dionicama. Dok većina banaka u Hrvatskoj za trgovanje na polugu sada propisuje vrlo stroge uvjete, a poluga je u najboljem slučaju u omjeru 1:1, trgovanje na polugu na FX tržištu moguće je u omjeru 1:100 ili čak 1:500. Drugim riječima, s 1.000 uloženih EUR, ulagač može trgovati sa 100.000, odnosno s 500.000 EUR. Promjena tečaja u korist ulagača od 1 % dovest će do dobitka 1.000 EUR ili, u drugom slučaju, kad se koristi poluga 1:500, promjena od samo 0,2 % dovodi do

dobitka od 1.000 EUR. No, ista takva promjena u suprotnom pravcu, dovest će do gubitka svog uloženog novca i do neželjenog privremenog ili trajnog napuštanja tržišta. Početni dobici mogu djelovati tako da nedovoljno iskusni trgovci zapostave oprez te da, privučeni zaradom, ulože puno veće iznose od onih čiji bi gubitak realno mogli podnijeti. Financijske posljedice takvih odluka mogu biti teške i zato je prije ozbiljnijeg ulaska na tržište potrebno steći određeno znanje i iskustvo. FX tržište u Hrvatskoj još je uvijek nedovoljno poznato široj javnosti, ali sudeći po trendovima i iskustvima, takva bi se situacija mogla promijeniti pa bi određeni broj građana i poduzeća uskoro mogao početi aktivno trgovati. Vrlo je važno da ulagači ne uđu na FX tržište nespremni, odnosno bez dovoljno znanja i informacija o procesima i njihovoj naravi. Slom investicijskog balona u Hrvatskoj do kojega je došlo koncem 2008. godine, rezultirao je financijskim gubicima kod brojnih građana i poduzeća te putem smanjenja ukupnog investicijskog potencijala pridonio nastanku i trajanju recesije. Kod *forexa* se, zasad, ne treba očekivati slom tržišta, ali rizici postoje i financijski gubici realno su mogući. Informiranost i stjecanje znanja potencijalnih ulagača glavna su garancija izbjegavanja većih financijskih gubitaka.

4. ZAKLJUČAK

Foreign exchange market, odnosno *forex*, međunarodno je tržište na kojem se trguje najznačajnijim svjetskim valutama, a visoke razine dnevnog prometa čine ga najlikvidnijim tržištem na svijetu. Sedam svjetskih valuta kojima se najviše trguje čini glavninu prometa na FX tržištu, a najviše se trguje američkim dolarom. Uz njega su vrlo zastupljeni euro i japanski jen. Valutni parovi koji u sebi sadrže američki dolar nazivaju se glavnim parovima, a ostali se nazivaju ukrštenim valutnim parovima. FX tržište čine komercijalne banke, centralne banke, financijske institucije i fondovi. Procjenjuje se da su FX transakcije najvećim dijelom špekulativne naravi, što znači da se najviše transakcija obavlja s ciljem ostvarivanja zarade na trenutnom kretanju i kolebanju cijena. Zahvaljujući razvoju trgovinskih platformi individualni trgovci sve više sudjeluju na tržištu i predstavljaju rastući segment FX tržišta. Likvidnost i lagana dostupnost i pristup, te trgovanje uz polugu i kvaliteta izvršenja, predstavljaju velike prednosti FX tržišta. Zbog velikog opsega trgovine i dubine tržišta, cjenovne manipulacije gotovo su nemoguće. FX tržište funkcionira jednostavnije u usporedbi s klasičnim tržištima vrijednosnih papira jer se najčešće trguje s malim brojem valutnih parova. Sve to dovodi do predodžbe da je na FX tržištu moguće lakše i brže zaraditi nego na ostalim financijskim tržištima. Početni dobici mogu djelovati na zapostavljanje opreza nedovoljno iskusnih trgovaca i da, privučeni zaradom, ulože puno veće iznose od onih čiji bi gubitak realno mogli podnijeti. FX tržište u Hrvatskoj još je uvijek nedovoljno poznato široj javnosti, ali može se očekivati da će ulagači iz Hrvatske biti privučeni njegovim mogućnostima. Špekulativni karakter tržišta, uz prisutnost velikih igrača, može dovesti do gubitaka koji posljedično djeluju na smanjenje investicijskog potencijala i produljenja trajanja recesije. U tom smislu, informiranost i stjecanje znanja prije ulaska na tržište postaju glavna garancija izbjegavanja većih financijskih gubitaka.

LITERATURA

Bank For International Settlements, (2013) *Triennial Central Bank Survey: Foreign exchange turnover in April 2013: preliminary global results*, http://www.bis.org/publ/rpfx13fx.pdf (30. 12. 2013.)

Cofnas, A. (2008) *Forex: kako uspješno trgovati devizama*, Zagreb: MASMEDIA

Crump, T. (1981) *The Phenomenon of Money*, London: Routledge & Kegan Paul Ltd

Foley, B. J. (1998) *Tržišta kapitala*, Zagreb: MATE

Euromoney, (2013) *FX survey results revealed*, http://www.euromoney.com/Article/3202090/Euromoney-FX-survey-results-revealed.html (30. 12. 2013.)

Finberg, R. (2013) *April 2013 Global Central Bank Foreign Exchange Survey – Spot Higher, Swaps Mixed*, http://forexmagnates.com/april-2013-global-central-bank-foreign-exchange-survey-spot-higher-swaps-mixed/. (30. 12. 2013.)

Lazibat, T., Kolaković, M. (2004) *Međunarodno poslovanje u uvjetima globalizacije*, Zagreb: Sinergija

Madura, J. (2011) *International Financial Management*, Boston: Cengage

Malkiel, B. (2008) *Uspješna strategija burzovnog trgovanja: strategija za uspješno investiranje provjerena u praksi*, Zagreb: MASMEDIA

Maričić, Z. (2011) „Forex – karakteristike, trgovanje, tehnička i fundamentalna analiza", Zbornik radova Međimurskog Veleučilišta u Čakovcu, vol. 2(1), Čakovec

Murphy, J. (2007) *Tehnička analiza financijskih tržišta*, Zagreb: MASMEDIA

Simić, S. (2008) *Novo tržište kapitala*, Zagreb: HANFA

Zakon o deviznom poslovanju, Narodne novine, br. 96/03 do 76/13

Denis Buterin[1]
Julijan Plenča [2]
Eda Ribarić Aidone [3]

Review article
UDK 336.76:65.011.3

POSSIBILITIES AND RISKS OF INVESTING IN THE FOREX MARKET[4]

ABSTRACT

Foreign exchange market or simply FOREX is an international market of major world currencies and the most liquid market in the world. Along with the development of internet and communication technology, more and more small investors have been entering this market, trying to make profits through speculative investments. Despite having a negative connotation among the Croatian public, it is expected that FOREX will attract an increasing number of Croatian investors due to the great opportunities it provides. In this context, its potential importance for Croatian investors is predicted in this paper. Trading options unique to the FOREX market provide opportunities for numerous investors, especially the small ones. This paper is based on data analysis which shows functioning of international currency markets. Its aim is to point out the opportunities and risks that are present in the FOREX market, as well as the specifics of the market compared to other financial markets. Due to its unique aspects, the FOREX market provides great opportunities to earn profits, but, on the other hand, also a high risk of rapid and permanent loss. The paper stresses the importance of good preparation, information gathering, and knowledge accumulation before entering the FOREX market and making investment decisions, which is particularly important because the size of the market and its speculative character can cause losses that could subsequently reduce the investment potential and have the additional effect of recession.

Key words: *money, forex, analysis, financial risks*

[1] MSc, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: denis.buterin@veleri.hr
[2] Student, Bacc. oec. E-mail: plencajulijan@yahoo.com
[3] MSc, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: eribaric@veleri.hr
[4] Received: 17. 2. 2014.; accepted: 5. 5. 2014.

Denis Buterin [1]
Nikolina Blašković [2]
Eda Ribarić Aidone [3]

Pregledni rad
UDK 343.537:336.1(497.5)

SUZBIJANJE KRUŽNIH PRIJEVARA U CILJU ZAŠTITE JAVNIH FINANCIJA HRVATSKE[4]

SAŽETAK

Kružne prijevare predstavljaju način organiziranog i sustavnog izvlačenja novca iz državnog proračuna iskorištavanjem nedostataka europskog poreznog sustava. Načelom odredišta omogućuje se isti porezni tretman i isti tržišni položaj domaće i uvezene robe, ali ono isto tako omogućava činjenje kružnih prijevara. Posljednjih godina njihovo praćenje i suzbijanje postaje sve zahtjevnije jer se njihovo težište preselilo u domenu nematerijalne imovine, a odvijaju se sve više internetom. U radu se analizira način funkcioniranja kružnih prijevara, kao i načini njihova suzbijanja. Analiziraju se dosadašnja postignuća u njihovom sprječavanju i ukazuje na poteškoće do kojih dolazi kad ih se pokušava spriječiti redovitim poreznim postupcima. Cilj rada je ukazati na ozbiljnost problema i na opasnost za javne financije kojoj je Hrvatska postala izložena pristupanjem EU-u. Istaknuta je uloga nadzornih tijela i nadležnog ministarstva. U radu se predlažu mjere kojima bi Hrvatska učinkovito mogla suzbiti kružne prijevare na svom području dok se ne donese trajno rješenje na području cijele Unije.

***Ključne riječi**: kružne prijevare, MTIC* fraud*, javne financije, EU*

1. UVOD

Kružne prijevare predstavljaju jedan od najvećih poreznih problema s kojim se suočavaju zemlje članice Europske unije. Procjenjuje se da je izravna šteta koju godišnje prouzroče kružne prijevare oko 100 milijardi eura. Karakteristike kružnih prijevara su da se odvijaju iznimno brzo, da ih je vrlo teško uočiti te da i kod njihovog eventualnog procesuiranja dolazi do brojnih problema. Najveći problem je što se u vrlo malom broju slučajeva novac može vratiti u proračun. Posljednjih godina počinitelji kružnih prijevara sve se više okreću trgovanju nematerijalnom imovinom, što dodatno otežava njihovo sprječavanje.

Hrvatska, kao nova članica EU-a, nema iskustva u borbi protiv kružnih prijevara, zbog čega je vrlo ranjiva. Dodatnu poteškoću predstavlja što Hrvatska nije u dovoljnoj mjeri percipirala nadolazeću opasnost, pa se organizacijski nedovoljno pripremila na taj problem. Naime, iako svijest o problemu postoji, dosadašnje aktivnosti pokazuju da se podcjenjuje

[1] Mr. sc., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* denis.buterin@veleri.hr
[2] Student, bacc. oec., direktorica u Vili Berto Crikvenica, Braće Car Uračić, Crikvenica, Hrvatska. *E-mail:* pansionberto@gmail.com
[3] Mr. sc., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* eribaric@veleri.hr
[4] Datum primitka rada: 17. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

potencijalna šteta. U tom je smislu cilj ovog rada ukazati na veliku opasnost koju kružne prijevare predstavljaju za državne financije. Ovo osobito dolazi do izražaja u trenutku kad Hrvatska zbog krize već ima problema s prekomjernim deficitom i rashodnom stranom proračuna, gdje izvlačenje novca iz proračuna kružnim prijevarama dodatno otežava situaciju.

U članku se obrazlažu najvažnije značajke kružnih prijevara, njihova povijest i načini funkcioniranja te njihovi najnoviji trendovi. Posebno su objašnjeni načini njihova suzbijanja, ali i najvažnija iskustva zemalja koje su u tome uspješne, da bi se njihovim razumijevanjem i implementacijom zaštitilo hrvatske javne financije.

2. NASTANAK I TERMINOLOGIJA KRUŽNIH PRIJEVARA

Smatra se da su kružne prijevare najteži oblici PDV-prijevara u EU-u. Kružna prijevara ili *carousel fraud* jedan je od najznačajnijih oblika tzv. MTIC *fraud*[5], prijevara na PDV-u u EU-u, a procjenjuje se da kroz ove sustavne oblike prijevara države članice gube 100 milijardi eura godišnje (Podlipnik, 2012:458). U nastavku su predočeni uvjeti nastanka te vrste i funkcioniranje MTIC prijevara.

2.1 Uvjeti nastanka

Definicija kružne prijevare kao jedne od najznačajnijih oblika MTIC fraud prijevara uključuje sljedeće obvezne elemente: transakcije poduzeća u najmanje dvjema država članicama, velik broj kupoprodajnih transakcija više poduzeća u kratkom razdoblju kako bi se prikrilo stvarne namjere te najmanje jednog nedostajućeg trgovca tzv. missing tradera (Raspudić, 2004: 66).

Pojavile su se kao odgovor na temeljni nedostatak sustava PDV-a među zemljama članicama. Tvrtke koje sudjeluju u prijevarama iskorištavaju manjkavost u dizajnu sustava PDV-a koja postoji od 1. siječnja 1993. godine, od kada je osnovano zajedničko tržište kad su prepreke u unutarnjem prometu među državama članicama ukinute. Usvojen je prijelazni sustav pod kojim se unutar zajednice poslovne transakcije oporezuju u državi članici odredišta po stopi i pod uvjetima te države. Transakcije se u osnovi oporezuju kao da su izvoz jedne države članice i uvoz druge države članice. To znači da se na takvu prodaju primjenjuje nulta stopa poreza, te se ne zaračunava PDV na kupovinu. U usporedbi s pravim uvozom i izvozom unutar Unije transakcija roba ne kontrolira se fizički na granicama, već samo kroz kontrolu dokumenata.

Dobra i usluge u međunarodnoj razmjeni mogu se oporezivati prema načelu podrijetla ili prema načelu odredišta. Prema načelu podrijetla PDV-om se oporezuju sva dobra koja su proizvedena u nekoj zemlji, bez obzira troše li se ona u toj zemlji ili se ona kasnije izvoze. Prema ovom načelu sva dobra koja se u zemlju uvoze te se u njoj prodaju i troše ne oporezuju se. Primjena načela podrijetla znači da su sva dobra i usluge koji se izvoze opterećeni PDV-om, dok su istodobno sva dobra i usluge koji se uvoze u zemlju oslobođeni

[5] *Engl. missing trader – intra community fraud:* prijevara unutar zajednice putem trgovca koji nestaje.

PDV-a. Suprotno od načela podrijetla, prema načelu odredišta dobra i usluge oporezuju se u mjestu gdje se troše, bez obzira jesu li proizvedena u tuzemstvu ili su uvezena. Zbog toga se načelo odredišta naziva još i načelom mjesta potrošnje. Ovo načelo pretpostavlja da je izvoz oslobođen od plaćanja PDV-a, dok je uvoz dobara i usluga u pravilu oporeziv. Davanje prednosti načelu odredišta u sustavu oporezivanja PDV-om opravdano je činjenicom što su tako domaći i uvezeni proizvodi porezno izjednačeni na domaćem tržištu (Sixth Council Directive, OJ L 145, 1977). Upravo sustav oporezivanja po načelu odredišta čini MTIC prijevare mogućima jer dobavljač ima pravo na odbitak PDV-a ili povrat ulaznog PDV-a pri izvozu u državu članicu.

2.2 Vrste i funkcioniranje MTIC prijevara

MTIC prijevare sustavan su napad na sustav PDV-a otkriven u brojnim članicama Unije. U suštini se počinitelji prijevara registriraju u sustav PDV-a kako bi bez poreza mogli nabavljati robu iz druge zemlje članice. Nakon toga prodaju robu po cijeni s uključenim PDV-om te nestanu ne plaćajući PDV što su ga naplatili od kupca. Prijevaru se najčešće izvodi vrlo brzo i počinitelji nestaju prije nego porezne vlasti u redovitom poreznom postupku stignu reagirati.

Što je sustav jednostavniji, to je poreznim obveznicima lakše poštovati pravila, a mogućnosti prikrivanja prijevara su manje. Složeni porezni sustavi s velikim brojem poreznih stopa mogu pridonijeti nepridržavanju propisa, isto kao i porezni zakoni koji se često mijenjaju.

Postoje dvije osnovne inačice MTIC prijevare: kružna prijevara – c*arousel fraud* i akvizicijska prijevara – a*cquisition fraud* te hibridna inačica *contra trading* (HM Revenue & Customs, 2014).

Carousel fraud – Kružna prijevara, financijska prijevara koja rezultira oštećenjem državnog proračuna zloporabom sustava PDV-a. Roba ili usluge nabavljaju se po nultoj stopi PDV-a iz zemalja članica EU-a. Stjecatelj prodaje robu s uračunatim PDV-om i nestaje prije plaćanja PDV-a državi, a krajnji kupac potražuje pretporez od države. Nabavljena dobra ponovno se prodaju velikom broju poduzeća. Nikad ne završe u maloprodaji na domaćem tržištu, odnosno ne postaju dostupna za potrošnju, nego ih se vraća fiktivno ili stvarno u zemlju podrijetla ili ih se iskorištava za pokretanje novog lanca prijevare otkuda potječe naziv kružna prijevara.

Acquisition fraud – Akvizicijska prijevara, podrazumijeva prodaju uvezene robe po nultoj stopi PDV-a na domaćem crnom tržištu. Uvoznik nakon prodaje ne zaračunava PDV na oporezive isporuke, čime može robu prodati jeftinije od ostalih sudionika na tržištu. Budući da ne naplaćuje PDV, izravno oštećuje državni proračun. U ovom slučaju kazneno djelo lako je dokazivo, pa je i procesuiranje lakše.

Contra trading – Kontra prijevara: radi sprječavanja otkrivanja MTIC prijevara počinitelji je često pokušavaju prikriti komplicirajući načine trgovanja. Jedan od opisanih načina je tzv. *contra trading*. Pojam kontra trgovac odnosi se na poreznog obveznika koji sudjeluje u

dvije odvojene vrste lanca transakcija, od kojih je jedna vrsta transakcija legalna, a provodi se s ciljem da se prikrije kružna prijevara.

Temeljni načini funkcioniranja jednostavne kružne prijevare predočen je shemom 1.

Suština funkcioniranja kružne prijevare može se opisati na sljedeći način: poduzeće A iz zemlje EU-a prodaje robu vrijednu 1.000.000 eura poduzeću B na domaćem tržištu, te je oslobođeno plaćanja poreza. Poduzeće B prodaje robu poduzeću C za 1.250.000 eura s uračunatim PDV-om. Iznos od 250.000 eura poduzeće B treba unutar roka uplatiti u državni proračun, dok poduzeće C taj PDV iskazuje kao pretporez. Unutar roka plaćanja poduzeće B prestaje poslovati, odnosno nestaje (*missing trader*), a država je prevarena za 250.000 eura. Porezna uprava s vremenom će blokirati poduzeće B te pokrenuti ovršni postupak, ali B posluje u unajmljenom prostoru, s unajmljenim namještajem, bez zaposlenih i bez novca na računu, pa od blokade i ovrhe neće biti koristi.

Za to vrijeme poduzeće C dalje prodaje robu poduzeću D, poduzeće D prodaje poduzeću E, a poduzeće E prodaje robu poduzeću F. Svako od navedenih poduzeća zaračunava određenu maržu i uredno plaća razliku PDV-a da bi posao izgledao istinit. Poduzeće F potom robu prodaje bez poreza natrag poduzeću A u prvoj državi ili nekom drugom poduzeću kojem takva roba treba.

Poduzeća C, D i E služe ometanju praćenja traga novca i prikazivanju cijele transakcije istinitim i pravim poslovnim događajem. Ta se poduzeća nazivaju *bufferi*. Radi se o poduzećima koja inače posluju na domaćem tržištu i koja uglavnom ranije nisu bila upletena u porezne prekršaje. Na svaku isporuku robe u lancu zaračunavaju određeni postotak zarade kako bi dio kružne transakcije koji se na njih odnosi izgledao kao istinit i ekonomski opravdan poslovni događaj. Na taj se način postiže da cijela prijevara nema izgled prividnog pravnog posla, što je vrlo bitno ako eventualno porezna ili druga nadzorna tijela otkriju prijevaru. Naime, članak 11. Općeg poreznog zakona (Narodne novine, br. 147/08 do 73/13) propisuje da u slučaju prikrivanja pravnog posla prividnim pravnim poslom, osnovica za oporezivanje postaje prikriveni pravni posao. Kako se ovdje radi o poduzećima koja na tržištu posluju od ranije i kako na svaku isporuku zaračunavaju određeni iznos zarade te kako je roba na transportnom sredstvu zaista prešla graničnu crtu, zajedno sa svom pratećom dokumentacijom, dokazivanje prividnog pravnog posla vrlo je težak zadatak. Budući da je za učinkovito provođenje klasične kružne prijevare nužno da roba u stvarnosti prijeđe graničnu crtu domaće zemlje, uglavnom se radi o skupoj robi malih gabarita radi što manjih transportnih troškova.

Shema 1. Transakcijski lanac u jednostavnoj MTIC kružnoj prijevari

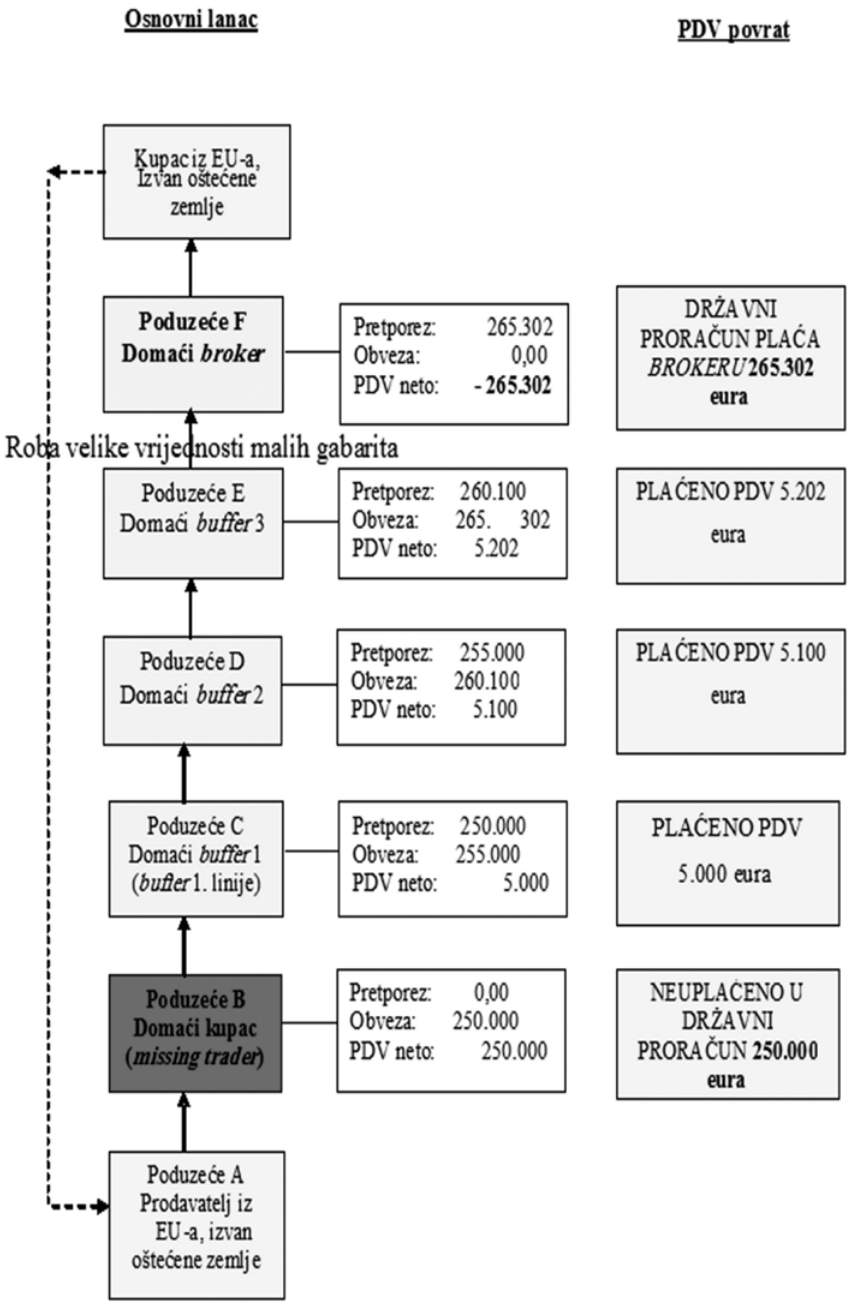

Izvor: obrada autora prema HM Revenue & Customs (2014)

Kada se tome pridoda da poduzeće B svoju poreznu obvezu uredno prijavljuje premda je kasnije nikad ne plati, namjeru utaje poreza gotovo je nemoguće dokazati. K tome, poduzeća *bufferi* – C, D i E smješteni su u različitim gradovima zemlje, tako da je provođenje vezanih poreznih nadzora dodatno otežano pravilima o teritorijalnoj nadležnosti poreznih tijela, kao što je slučaj s hrvatskom Poreznom upravom. Isto su tako i poduzeća B i F uglavnom smještena u različitim gradovima, što otežava nadzor i praćenje tragova robe i novca. Treba napomenuti da se i sva plaćanja među poduzećima u lancu također uredno provode pa se porezna tijela nalaze pred gotovo nerješivim problemom. U svrhu prikrivanja tragova novca i robe moguće je uključiti velik broj *buffera*, od kojih neki mogu biti u drugim zemljama EU-a ili čak u trećim zemljama.

Poduzeće F, koje robu kupuje od *buffera* – poduzeća E, naziva se *broker*. Ono robu izvozi u drugu zemlju članicu, najčešće upravo poduzeću A od kojega je roba i krenula. Uglavnom je slučaj da su sva uključena poduzeća svjesni sudionici prijevare, iako kod opsežnijih kružnih prijevara kao nenamjerni *bufferi* ponekad bivaju uključivane i ozbiljne tvrtke koje prijevaru niti ne opaze. Ponekad je u kružne prijevare uključeno deset i više *buffera*, pa je vezanim nadzorima vrlo teško doći do *brokera*.

Shemom 2 prikazan je način funkcioniranja jednostavne akvizicijske prijevare.

Shema 2. Transakcijski lanac u MTIC akvizicijskoj prijevari

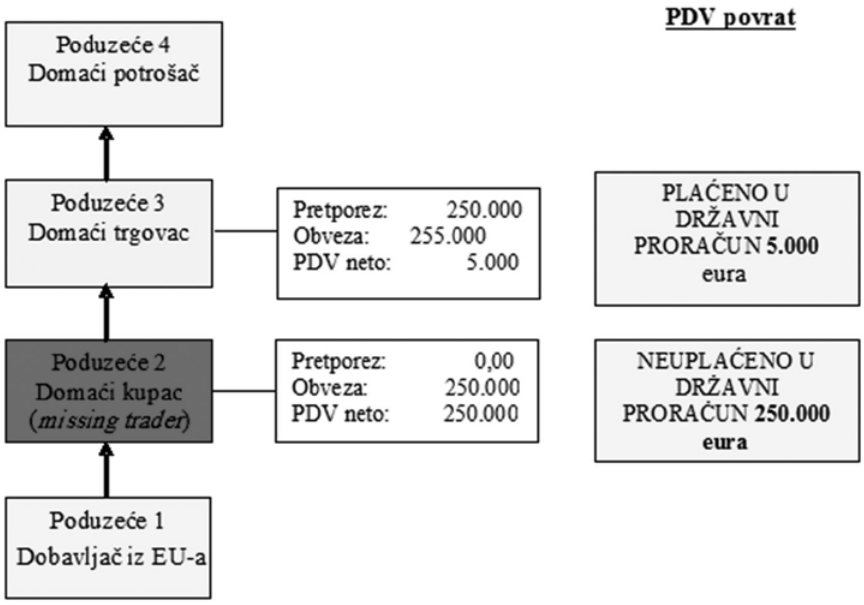

Izvor: obrada autora prema HM Revenue & Customs (2014)

U ovom slučaju poduzeće 1 iz zemlje EU-a prodaje robu vrijednu 1,000.000 eura poduzeću 2 na domaćem tržištu te je oslobođeno plaćanja poreza. Poduzeće 2 prodaje robu poduzeću 3 za 1,250.000 eura s uračunatim PDV-om. Iznos od 250.000 eura poduzeće 2 treba unutar roka uplatiti u državni proračun, dok poduzeće 3 taj PDV iskazuje kao pretporez. Unutar roka plaćanja poduzeće 2 prestaje poslovati, odnosno nestaje (*missing trader*), a država je prevarena za 250.000 eura. Za razliku od prethodnog slučaja poduzeće 3 robu ne izvozi nego prodaje poduzeću 4 na domaćem tržištu, koje je krajnji kupac i koje najčešće ne zna da sudjeluje u kružnoj prijevari. Poduzeće 3 robu prodaje uz minimalnu maržu i s uračunatim PDV-om, primjerice za 1,020.000 eura plus 255.000 eura. Poduzeće 3 u poreznoj prijavi prijavljuje 255.000 eura PDV-a umanjeno za 250.000 eura pretporeza, što čini ukupno 5.000 eura porezne obveze. Iz cijele transakcije država je izgubila 250.000 eura, a naplatila 5.000 eura te je u konačnici oštećena za 245.000 eura. Poduzeće 4 služi samo da bi se sudionici kružne prijevare riješili robe i da prodajom krajnjem kupcu otežaju eventualne istrage i praćenje tragova.

Za *missing tradere* karakteristično je da nemaju zaposlenih, nemaju poslovnih prostorija, nemaju dugu povijest poslovanja, nemaju poslovne imovine koju bi se moglo zaplijeniti i sl. Upravo zbog tih karakteristika takva poduzeća rijetko predstavljaju interes poreznih tijela koja se bave redovnim nadzornim aktivnostima. S druge strane, osnivači i odgovorne osobe takvih poduzeća u pravilu su nedostupni ili neupućeni, ucijenjeni ili poslovno nesposobni. Često su to osobe s fiktivnim prebivalištem ili osobe čiji je identitet uz pomoć ukradenih ili ustupljenih dokumenata zloupotrijebljen.

3. NOVI TRENDOVI I NAČINI SUZBIJANJA

Gubici koji proizlaze iz kružnih prijevara značajni su za države članice, stoga se ulažu napori kako bi se takve prijevare suzbile, posebice uslijed korištenja nematerijalnih dobara kao temelja za počinjenje kružnih prijevara. U nastavku je predočena problematika robe u kružnim prijevarama te uloga Eurofisca u suzbijanju takvih prijevara, kao i primjena mehanizma brze reakcije.

3.1 Roba u kružnim prijevarama

U nezakonitim transakcijama opisanih kružnih prijevara tradicionalno se pojavljivala roba velike vrijednosti i malog volumena kao što su mobilni telefoni, igraće konzole, kompjutorski dijelovi, parfemi, zlato i slično. Za počinitelje kružnih prijevara bitno je bilo da se radi o robi koja je tražena na tržištu, odnosno kojom se lako trguje, koja je skupa i koja se lako može transportirati. Na takve se prijevare donekle i moglo reagirati tradicionalnim načinima poreznog nadzora jer se trag robe ipak može više ili manje učinkovito pratiti, roba može biti oduzeta, a počinitelji pritvoreni. Izgubljeni PDV rijetko može biti vraćen, ali ipak je donekle bilo moguće suprotstaviti se prijevarama. Kad je roba kojom se trguje u digitalnom obliku, što je sve više slučaj, nadzori se uvelike kompliciraju i postaju teže provedivi. Kružne prijevare moguće je ostvariti raznim oblicima digitalne imovine, primjerice raznim certifikatima i dozvolama na trgovinu kojima se plaća PDV. Za počinitelje kružnih prijevara nematerijalna dobra vrlo su privlačna jer nema transportnih troškova, a praćenje i nadzor daleko su složeniji i teži. To je vrlo osjetljivo područje jer u brojnim zemljama porezne vlasti nemaju dovoljno znanja i iskustva za suočavanje s tim problemom.

Nakon stupanja na snagu Kyotskog protokola 2005. godine intenzivirala se trgovina certifikatima za emisiju CO2, takozvanim *carbon credits* certifikatima: *Eurupean Union Allovances* (EUAs), *Certified Emission Reductions* (CERs) i *Emission Reduction Units* (ERUs).[6] Trgovina se nije odvijala samo među poduzećima koja su imala višak ili manjak certifikata, nego su se aktivno uključili investicijski i mirovinski fondovi, banke, osiguravajuća društva i ostali trgovci i špekulanti. Već 2009. godine promet navedenim certifikatima bio je veći od 100 milijardi eura, a prema posljednjim objavljenim podacima promet u 2011. godini bio je veći od 129 milijardi eura (World Bank, 2012:10). CO2 certifikati nematerijalna su imovina koja nestaje iz opticaja nakon upotrebe i kojoj je vrlo teško pratiti trag nakon što prijeđe granicu. Uskoro su se u trgovinu CO2 certifikatima uključili i počinitelji kružnih prijevara tako da su ih bez PDV-a uvozili iz zemalja članica te ih potom prodavali na domaćem tržištu. Od kolovoza 2008. godine započela je prava ekspanzija trgovine, ali iza toga su stajale kružne prijevare. U Francuskoj, Danskoj, Nizozemskoj, Španjolskoj i Velikoj Britaniji promet CO2 certifikatima dosegao je dotad nezamislive iznose. U ožujku 2009. godine nizozemsko porezno tijelo FIOD prvo je povezalo neuobičajeni porast prometa CO2 certifikatima s mogućim kružnim prijevarama. Procjenjuje se da je u razdoblju od kolovoza 2008. do ožujka 2009. godine samo na CO2 certifikatima kružnim prijevara nastala šteta za navedene države u iznosu većem od 5 milijardi eura (Europol, 2009). Nizozemska je odmah promijenila porezno pravo za ove transakcije tako da je umjesto prodavatelja obveznik plaćanja PDV-a postao stjecatelj, čime je trgovina certifikatima u toj državi prestala biti pogodna za kružne prijevare. To se naziva *reverse charge mechanism VAT*, odnosno mehanizam obrnute naplate PDV-a. Odmah nakon toga trgovina navedenim certifikatima gotovo je stala, što je značilo da je mjera bila opravdana (Wolf, 2010:405). Ova je odluka bila u suprotnosti s PDV Direktivom Unije, ali Nizozemska se u ovom slučaju vodila zaštitom svojih fiskalnih interesa. Uskoro su brojne druge zemlje slijedile nizozemski primjer, a trgovina CO2 certifikatima u tim zemljama pala je do 90 %. Godinu dana kasnije, u ožujku 2010. usvojena je Direktiva 2010/23/EU kojom se dozvoljava mehanizam obrnute naplate PDV-a za određene usluge koje mogu biti predmet prijevara u PDV-u (Council Directive 2010/23/EU, OJ L 72/1, 2010). Počinitelji kružnih prijevara potom su trgovinu CO2 certifikatima preselili u zemlje koje nisu bile uvele mehanizam obrnute naplate, poput Poljske, Italije i Češke. Godine 2010. talijanska Guardia di Finanza provela je opsežnu akciju i zatvorila oko 150 poduzeća u osam talijanskih regija. Procjenjuje se da su dotad na CO2 certifikatima oštetili Italiju za oko 500 milijuna eura PDV-a (Europol, 2010). Iste godine i u Češkoj je otkriven lanac kružnih prijevara s CO2 certifikatima.

Osim u domeni CO2 certifikata, očekuje se da bi pojačana aktivnost počinitelja kružnih prijevara mogla biti usmjerena na posebne segmente u trgovanju plinom i električnom energijom (Europol, 2010). Koncem 2012. godine u Velikoj Britaniji, Njemačkoj i Nizozemskoj uočene su kružne prijevare s bakrenim katodama koje se koriste u metalnoj industriji (Tax-News, 2012). Sve to dokazuje da se počinitelji kružnih prijevara sve više prebacuju s klasičnih vrsta roba na područja visokog tehnološkog sektora te da vjerojatno postoji još čitav niz

[6] Kyoto Protokol uveo je dva mehanizma emisijskih prava: *Clean Development Mechanism* (CDM) i *Joint Implementation* (JI). *Joint Implementation* odnosi se na tranzicijske zemlje među kojima je i Hrvatska. Pod JI zemlje, među kojima je i RH, izdaju *Emission Reduction Units* (ERUs)

roba u materijalnom i nematerijalnom obliku kojima oni trguju, a što nadzorna tijela još nisu uspjela uočiti.

Godine 2010. u Italiji je otkriveno da je predmet kružnih prijevara bila nematerijalna imovina za koju je dotad bilo nezamislivo stavljanje u takav kontekst: VOIP – *voice over internet protocol*.[7] U toj prijevari sudjelovale su dvije talijanske najveće telekomunikacijske kompanije: *Telecom Italia* i *FastWeb*. Procjenjuje se da je ukupna šteta oko 400 milijuna eura PDV-a. (Ainsworth, 2010 b:28). Zanimljivo je da se u VOIP transakcijama trguje dvjema stvarima: 1) opremom, čiji je trag moguće pratiti, i 2) minutama, za čije je praćenje potrebno ekspertno znanje (Ainsworth, 2010 a:9). Trguje se doslovno minutama koje se nastoji jeftino kupiti i skuplje prodati. Iako je prijevara otkrivena u Italiji, zasad nema saznanja je li i ranije bilo prijevara s VOIP-om, te ima li ih i u drugim državama članicama, što je sasvim lako moguće. Navedeno ukazuje da počinitelji neprestano pronalaze nove predmete trgovanja pogodne za realizaciju kružnih prijevara, a osobito pokazuje koliki je zapravo raskorak između kapaciteta tradicionalnih poreznih tijela i suvremenih vidova prijevara u PDV-u.

Nadzor još više otežava uvođenje *cloud* knjigovodstva jer se tu pojavljuju i neriješena pravna pitanja. Godišnje se unutar Unije odvija na stotine milijuna transakcija, a procjenjuje se da na 10.000 poduzeća dolazi jedno koje sudjeluje u kružnim prijevarama (Hulot, 2013). Zato je poreznim tijelima vrlo teško u tolikom broju podataka pravovremeno prepoznati transakcije koje su sumnjive.

3.2 Eurofisc

Eurofisc je mreža koja služi za brzu razmjenu ciljanih informacija među članicama Unije. Osnovan je Uredbom Vijeća EU-a o administrativnoj suradnji i suzbijanju prijevara u području PDV-a br. 904/2010. To je decentralizirana mreža bez pravne osobnosti što su je uspostavile članice Unije radi promicanja i olakšavanja multilateralne i decentralizirane suradnje. Omogućuje ciljano i brzo djelovanje odnosno brzu razmjenu informacija. Države članice same odlučuju hoće li sudjelovati u radu *Eurofisca* te o prekidu sudjelovanja. Nakon pristanka na sudjelovanje, država mora biti aktivna u multilateralnoj razmjeni ciljanih informacija s drugim državama sudionicama. Razmijenjene su informacije povjerljive, a za države članice izvori informacija jednako su dostupni (Radusin-Lipošinović, 2013).

Glavni ciljevi multilateralne suradnje i kontrola jesu: zaustaviti isporuke dobavljača s područja Unije *missing traderima*, prepoznati sve strane u lancu prijevara: *bufere*, *brokere*, ali i špeditere, odvjetnike, banke i sl. te prikupljanje bitnih činjenica za pokretanje nacionalnih i međunarodnih kriminalnih istraga. Sve države članice u lancu prijevara prikupljaju podatke o dobavljačima, i to o narudžbama, računima, logistici, plaćanjima, prepisci te bilo kojoj drugoj dokumentaciji korisnoj za otkrivanje uključenih u lanac kružnih prijevara. Stvorena je baza podataka poduzeća koja su sudjelovala u dosad otkrivenim kružnim prijevarama, što može biti od znatne koristi, budući da se imena umiješanih osoba često ponavljaju. Poduzeća koja sudjeluju u kružnim prijevarama nazivaju se *conduit companies*. Takva baza omogućuje međunarodnu suradnju u financijskim istragama, simultane porezne nadzore u više zemalja, rano otkrivanje novih *buffera* i *brokera* te analizu rizika i

[7] Istraga je poznata pod imenom „Phuncards-Broker"

izdvajanje sumnjivih transakcija analizom rizika iz VIES baze. VIES baza sama po sebi teško je čitljiva jer sadrži podatke o stotinama milijuna transakcija godišnje, pa je za potrebe suzbijanja kružnih prijevara *Eurofiscov* sustav analize rizika neophodan.

Ciljevi su što učinkovitije se suprotstaviti kružnim prijevarama uspostavljenim sustavom analize rizika, proširiti pristup podacima, uskladiti akcije i mjere te što ranije slati upozorenja poreznim tijelima svih zemalja članica. Najvažnijim čimbenicima uspjeha smatraju se ciljane istrage, brzina izrade analize rizika kao učinkovitog alata ranog otkrivanja prijevara, spontana razmjena obavijesti, suradnja sa stručnjacima i dr. Otkrivanje kružnih prijevara otežavaju: složeno okruženje, velika brzina prijevara, česte promjene zakona u pojedinim članicama, promjene u ponašanju prevaranata, zemljopisna rasprostranjenost, neiskustvo i nepripremljenost pojedinih zemalja.

Smatra se kako je najveća vrijednost *Eurofisca* razmjena informacija u ranoj fazi. Pojavnosti kružnih prijevara koje uoči pojedina zemlja članica prosljeđuju se svim ostalim članicama radi donošenja brzih i učinkovitih mjera. Isto tako, vrlo su važni podaci o sudionicima kružnih prijevara koji se razmjenjuju, bez obzira radi li se o pravnim osobama ili njihovim osnivačima. Pod slabosti se mogu svesti teškoće u dobivanju povratnih informacija, neaktivno sudjelovanje pojedinih država, nedovoljna ciljanost i fokusiranost pojedinih informacija te neučinkovita suradnja poreznih uprava i ostalih nadzornih tijela.

3.3 Mehanizam brze reakcije

Direktivom Vijeća 2013/42/EU koja se odnosi na mehanizam brze reakcije (MBR) na prijevare u vezi s PDV-om, propisano je da država članica može zbog hitnosti odrediti primatelja kao osobu odgovornu platiti PDV za neke isporuke robe i usluga. To je posebna mjera MBR-a za suzbijanje iznenadnih i velikih prijevara koje mogu dovesti do znatnih i nenadoknadivih gubitaka. Država članica koja želi uvesti posebnu mjeru MBR-a istodobno šalje obavijest Komisiji i drugim državama članicama u kojoj dostavlja informacije u kojima se navodi sporni sektor, vrsta i obilježja prijevare, postojanje razloga iznimne hitnosti, iznenadnost i opseg prijevare te posljedice – znatne i nenadoknadive gubitke. Ako Komisija smatra da nije dobila sve nužne informacije, poziva državu članicu u roku dva tjedna nakon primitka obavijesti te navodi koje su joj dodatne informacije nužne. Sve dodatne obavijesti što ih država članica dostavlja Komisiji istodobno se šalju drugim državama članicama, a ako su nedostatne, Komisija o tome izvješćuje državu članicu u roku tjedan dana. Kad Komisija primi sve informacije što ih smatra nužnima za procjenu obavijesti, izvješćuje države članice. Ako se protivi osobitoj mjeri MBR-a, daje negativno mišljenje u roku mjesec dana od te obavijesti i o tome obavješćuje državu članicu i Odbor za PDV. Ako se Komisija ne protivi, potvrđuje to u pisanom obliku državi članici i Odboru za PDV u istome razdoblju. Država članica može donijeti posebnu mjeru MBR-a nakon što primi te potvrde. Pri procjeni obavijesti Komisija uzima u obzir stajališta svake druge zainteresirane države članice. U okolnostima iznimne hitnosti postupak se dovršava u roku šest mjeseci nakon što Komisija zaprimi zahtjev. Ova Direktiva primjenjuje se do 31. prosinca 2018. godine.

Bez obzira što ova mjera spada u mehanizam brze reakcije, u praksi ona vrlo malo može doprinijeti zaštiti države od kružnih prijevara. Naime, najprije je potrebno takve robe ili usluge uočiti i detektirati kao potencijalno opasne, potom formirati zahtjev Komisiji te zatim čekati odobrenje

u praksi. U međuvremenu, promet takvim robama ili uslugama i dalje se nesmetano odvija. Kad Komisija eventualno odobri zahtjev, počinitelji kružnih prijevara odnosno *conduit* kompanije jednostavno prestaju trgovati takvom robom ili uslugama i prebacuju svoje poslovanje na trgovanje drugom robom. Dakle, problem je što su počinitelji kružnih prijevara vrlo brzi i odmah reagiraju na promjene takve vrste pa za prijevare koriste drugu vrstu robe ili usluga. Do novog detektiranja i odobrenja proći će u najboljem slučaju novih šest mjeseci, što je zapravo vrlo neučinkovito jer se kružne prijevare odvijaju iznimno brzo. Primjena mehanizma obrnute naplate ne rješava problem nego ga prebacuje s jedne vrste robe na drugu.

Najbolji način zaštite države od kružnih prijevara je učinkovito otkrivanje i kažnjavanje, a osobito preventivno djelovanje što se postiže uključivanjem brojnih segmenata državne uprave u tu problematiku. Praksa je pokazala da *conduit* kompanije izbjegavaju države gdje je borba protiv njih učinkovita, poput, primjerice, Nizozemske ili Belgije. *Conduit* kompanije sele se u one zemlje koje su nedovoljno pripremljene ili koje ovaj problem nedovoljno ozbiljno shvaćaju.

4. HRVATSKA I KRUŽNE PRIJEVARE

Aktivnosti koje je dosad poduzelo Ministarstvo financija pokazuju da Hrvatska spada u skupinu relativno nepripremljenih zemalja. Hrvatska je nova članica EU-a koja još nije stekla iskustvo u borbi protiv kružnih prijevara pa je to čini relativno ranjivom. Treba napomenuti da je Porezna uprava imenovala koordinatora za područje rada Eurofisca i službenike za vezu te se na taj način uključila u njegov rad i razmjenu informacija. No problem je što su imenovane osobe državni službenici kod kojih je zbog hijerarhijske strukture upitno jesu li u mogućnosti donositi odluke i predlagati mijenjanje organizacije ili propisa u svrhu učinkovite primjene znanja i informacija stečenih putem *Eurofisca*. Iskustva zemalja koje su uspješne u borbi protiv kružnih prijevara, poput Nizozemske ili Belgije, pokazuju da je vrlo bitno da osobe koje surađuju s *Eurofiscom* budu osobe koje u svojim zemljama imaju stvarni utjecaj na primjenu i provođenje korisnih znanja.

Nadalje, iako je u Poreznoj upravi unutar Sektora za nadzor ustrojena Služba za borbu protiv prijevara u PDV-u (Narodne novine, br. 102/13), zbog svojeg teritorijalnog i organizacijskog ustroja Porezna uprava teško se može protiv kružnih prijevara učinkovito sama boriti. U slučajevima kad su *broker, bufferi* i *missing trader* iz gradova u različitim županijama, za nadzor nad njima nadležni su različiti područni uredi, što dovodi do brojnih administrativnih postupaka i posljedično do usporavanja djelovanja. Kružne prijevare odvijaju se iznimno brzo, ponekad i u roku od jednog dana, a tijelo veličine Porezne uprave nije u stanju organizirati nadzore u različitim gradovima i blokirati sumnjive transakcije u tako kratkom vremenu. Osim toga, Porezna uprava bavi se svojim redovitim poslovanjem u kojem su nadzori tek jedan od segmenata tog poslovanja. Nadzori se uglavnom provode prema unaprijed utvrđenim planovima i na način koji treba imati svoja pravila, određeno vrijeme trajanja i određene načine mjerenja učinkovitosti. Kod borbe protiv kružnih prijevara prioritet treba biti zaustavljanje sumnjivih transakcija i blokiranje isplate PDV-a, a to se može postići brzim reakcijama i dobrom koordinacijom, što je često u suprotnosti s redovnim poslovanjem Porezne uprave.

Od dana hrvatskog pridruživanja EU-u u Hrvatskoj nije procesuiran ni jedan slučaj kružne prijevare, iako je vrlo izvjesno da se one odvijaju. Za rješavanje problema kružnih prijevara potrebno je koristiti iskustva uspješnih zemalja i prilagoditi ih domaćim okolnostima. Prvo, potrebno je ustrojiti posebno tijelo čija će glavna aktivnost biti borba protiv kružnih prijevara. Takvo tijelo treba biti operativno, s kapacitetima za provođenje nadzora u cijeloj Hrvatskoj i s ovlastima za trenutno postupanje. Bez obzira osnuje li se kao tijelo Ministarstva financija ili unutar Porezne uprave, ono mora biti samostalno u provođenju operativnih aktivnosti. Njegova zadaća prvenstveno treba biti zaštita državnih financija sprječavanjem kružnih prijevara, a ne regularni porezni nadzor i utvrđivanje poreznih obveza. Takvo tijelo trebalo bi imati usku suradnju s policijom, carinom, državnim odvjetništvom i drugim nadzornim tijelima te suradnju sa sličnim tijelima izvan Hrvatske. U Belgiji su, primjerice, kružne prijevare gotovo iskorijenjene te se procjenjuje da su porezni gubici smanjeni s 1,1 milijarde eura u 2002. godini na 18,5 milijuna eura u 2012. godini, odnosno za 98 % (Hulot, 2013). Tamo postoji posebno porezno tijelo koje se upravo time bavi. Slično je i u Nizozemskoj koja ima vrlo dobra iskustva u suzbijanju kružnih prijevara. I tamo postoji posebno porezno tijelo FIOD (*Fiscale Inlichtingenen Opsporingsdienst*) kojemu je prvenstveni zadatak zaštita državnih financija od poreznih prijevara.

Sljedeće, potrebno je organizirati edukaciju državnih službenika radi ranog otkrivanja pokazatelja kružnih prijevara jer se pokazalo da je prevencija jedna od najvažnijih pretpostavki njihovog učinkovitog suzbijanja. U Nizozemskoj postoji praksa da se poduzećima za koja se pretpostavlja da bi mogla biti upletena u kružne prijevare uputi pismo u kojem ih se upozorava da su pod posebnom prismotrom Ministarstva financija. U nekim slučajevima, svim poslovnim partnerima takvog poduzeća, kao i trećim strankama, poput odvjetnika, knjigovođa, špeditera i bilježnika koji rade s takvim poduzećem, šalje se pismo u kojem ih se upozorava na mogućnost prijevare s PDV-om i na mogućnost utvrđivanja njihove odgovornosti te ih se ohrabruje da sami prijavljuju moguće kružne prijevare. Kružne prijevare vrlo je teško otkriti, a ako se eventualno i otkriju, novac je najvećem broju slučajeva već povučen iz državnog proračuna.

Poseban problem predstavlja činjenica što se ne radi o ispostavljanju fiktivnih računa nego se roba zaista isporučuje, računi se plaćaju, a porezne prijave se dostavljaju bez obzira što *missing traderi* porez kasnije ne uplaćuju. Sve to čini teško dokazivim namjeru ostvarivanja kružne prijevare i utaje poreza. U tom smislu, potrebno je ostvariti suradnju s državnim odvjetništvom jer podizanje kaznenih prijava ima vrlo učinkovito preventivno djelovanje na buduće aktivnosti osoba umiješanih u kružne prijevare. Posebno je značajan slučaj iz sudske prakse Europskog suda pravde, *Kittel case* (Case C-439/04) prema čijoj presudi će se osoba „koja je znala ili je trebala znati da kupnjom proizvoda ili usluge sudjeluje u prijevari povezanoj s PDV-om smatrati sudionikom u toj prijevari, bez obzira je li prodajom te robe ostvarila kakvu zaradu ili nije" (Court of Justice of the European Union, 2006). U smislu Šeste Direktive ova presuda znači da se PDV može naplatiti od svake takve osobe koja je sudjelovala u predmetnoj prijevari, odnosno može joj se uskratiti pravo na povrat pretporeza. To dalje znači da je moguće procesuirati sve sudionike kružnih prijevara, bez obzira je li im moguće dokazati namjeru utaje poreza ili prijevare. Premda postoji mogućnost izdavanja posebnih certifikata kojim se potvrđuje validnost identifikacijskog poreznog broja stjecatelja u drugoj zemlji čime isporučitelji nastoje dokazati da su poslovali u dobroj vjeri,

pokazalo se da procesuiranje i pravomoćne presude imaju snažno preventivno djelovanje. No Ministarstvo financija mora biti to tijelo koje će potaknuti i pokrenuti takvu praksu i suradnju s državnim odvjetništvom.

Sudionici kružnih prijevara biraju i mijenjaju robu koja im je pogodna za trgovanje te biraju i mijenjaju države u kojima provode svoje aktivnosti. Napuštaju države koje su u suzbijanju učinkovite i premještaju svoje poslovanje u nedovoljno pripremljene zemlje. Hrvatska još nije stekla dovoljno iskustva na suzbijanju kružnih prijevara, ali isto tako, Ministarstvo financija nije se na njih u dovoljnoj mjeri pripremilo. Promjenama u ustroju Ministarstva financija te promjenama u pristupu prema kružnim prijevarama Hrvatska bi mogla učinkovitije suzbijati kružne prijevare te na taj način djelotvornije štititi svoje javne financije.

5. ZAKLJUČAK

Kružne prijevare ili *carousel frauds* predstavljaju jedan od najvećih poreznih problema u Europskoj uniji, a njihovo odvijanje omogućeno je još 1993. godine usvajanjem prijelaznog poreznog sustava po kojem se potrošnja oporezuje prema načelu odredišta. U kružnoj prijevari roba se uvozi iz druge zemlje članice, a obveza plaćanja PDV-a nastaje tek kad se roba proda na domaćem tržištu. Obveznik plaćanja PDV-a porez prijavljuje ali ga ne uplati, a poduzeće koje je od njega robu kupilo iskazuje pretporez, što državama članicama stvara značajne fiskalne štete. U novije vrijeme predmet kružnih prijevara sve više postaje roba u digitalnom obliku, poput raznih certifikata i dozvola, a očekuje se postupni prelazak na tržište električne energije i plina. Porezne prijevare s takvim vrstama roba teško je otkriti tradicionalnim nadzornim metodama zbog specifičnosti koje prate njihovo trgovanje. Pojedine zemlje EU-a uspješno suzbijaju kružne prijevare na svom području, poput Nizozemske i Belgije, pa se počinitelji premještaju u zemlje koje su u tome manje uspješne. Hrvatska je najnovija članica Unije i dosad se nije imala prilike susresti s problemom kružnih prijevara u ovakvom obliku. K tome, dosad poduzete aktivnosti pokazuju da se Hrvatska organizacijski nije u dovoljnoj mjeri pripremila te je stoga vrlo ranjiva i izložena počiniteljima koji već imaju veliko znanje i iskustvo. U cilju suzbijanja i prevencije kružnih prijevara Hrvatska treba implementirati iskustva i stečena znanja uspješnih zemalja EU-a. Promjenama u ustroju Ministarstva financija te promjenama u pristupu prema kružnim prijevarama Hrvatska bi mogla učinkovitije suzbijati kružne prijevare te na taj način djelotvornije štititi svoje javne financije.

LITERATURA

Ainsworth, R., T. (2010 a) *MTIC (VAT Fraud) in VOIP – Market size: 3.3b*, Boston University School of Law Working Paper No.10-03, Boston

Ainsworth, R., T. (2010 b) *VOIP MTIC – The Italian Job (Operazione "Phuncards-Broker")*, Boston University School of Law Working Paper No.10-09, Boston

Hulot, Y. (2013) *How hybrid fraud detection cut losses by 98% in Belgium*, http://www.sas.com/en_us/customers/tax-fraud-belgium.html (30. 12. 2013.)

Kesner-Škreb, M. (1995) *„Porez na dodanu vrijednost", Financijska praksa*, Zagreb, Vol. 19(6)

Lomas, U.: Netherlands Tackles VAT Carousel Fraud In Metal Industry, http://www.tax-news.com/news/Netherlands_Tackles_VAT_Carousel_Fraud_In_Metal_Industry___58281.html (30. 12. 2013.)

Podlipnik, J. (2012) „Missing trader intra community and carousel VAT frauds", *Croatian Yearbook of European Law & Policy*, Vol. 8

Radusin-Lipošinović, M. (2013) „Uloga EUROFISC-a u borbi protiv prijevara s PDV-om", *Porezni vjesnik*, Zagreb, Vol. 23(12)

Raspudić, R. (2004) „Kriminalne zlouporabe sustava PDV-a", *Porezni vjesnik*, Zagreb, Vol.13

Wolf, R. (2010) „The Sad History of Carbon Carousels"**,** *International VAT Monitor*, IBFD

Europol (2009), https://www.europol.europa.eu/print/content/press/carbon-credit-fraud-causes-more-5-billion-euros-damage-european-taxpayer-1265 (30. 12. 2013.)

Europol (2010), https://www.europol.europa.eu/print/content/press/further-investigations-vat-fraud-linked-carbon-emissions-trading-system-641 (30. 12. 2013.)

World Bank (2012) *State and Trends of the Carbon Market Report 2012*, World Bank, http://siteresources.worldbank.org/INTCARBONFINANCE/Resources/State_and_Trends_2012_Web_Optimized_19035_Cvr&Txt_LR.pdf (30. 12. 2013.)

VAT – Reverse Charge-Mechanism, http://www.insatax.com/pages/reversecharge.php (30. 12. 2013.)

Council Directive 2010/23/EU (2010), *Official Journal of the European Union L 72/1*

Council Directive 2013/42/EU (2013), *Official Journal of the European Union, L 201*, Vol. 56

Court of Justice of the European Union (2006) J*oined cases C-439/04 and C-440/04, Reports of Cases 2006 I-06161*, http://curia.europa.eu/jcms/jcms/j_6/ (30. 12. 2013.)

Opći porezni zakon, Narodne novine, br. 147/08 do 73/13

Sixth Council Directive, OJ L 145, 1977., http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:1977:145:0001:0040:EN:PDF (30. 12. 2013.)

Sixth VAT Directive, http://europa.eu/legislation_summaries/other/l31006_en.htm (30. 12. 2013.

Denis Buterin [1]
Nikolina Blašković [2]
Eda Ribarić Aidone [3]

Review article
UDC 343.537:336.1(497.5)

SUPPRESSION OF CAROUSEL VAT FRAUDS IN ORDER TO PROTECT CROATIAN PUBLIC FINANCES[4]

ABSTRACT

Carousel frauds are a systematic and organized way of extracting money from the state budget by exploiting flaws in the European tax system. The VAT on destination principle was adopted in the EU in 1993 as a temporary solution, but at present there is no indication that it will be replaced by the permanent one. Recently, monitoring and suppression have become more and more demanding tasks because the fraud system is based on trading an intangible asset, which is increasingly conducted electronically. This paper analyzes the technical functioning of carousel fraud and ways to combat it. It analyzes the current achievements in their prevention and highlights the difficulties that occur when efforts are made to prevent such practices by regular tax procedures. It is necessary to point out the seriousness of the problem and the threat to public finances which Croatia has become exposed to as a member of the EU. The paper emphasizes the role of supervisory authorities and the ministry in charge and proposes measures which Croatia could employ to effectively combat carousel frauds in its territory until permanent solution for the whole EU is found.

Key words: *carousel frauds, MTIC fraud, public finance, EU*

[1] MSc, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: denis.buterin@veleri.hr
[2] Student, Bacc. oec., director in Vila Berto Crikvenica, Braće Car Uračić, Crikvenica, Croatia. E-mail: pansionberto@gmail.com
[3] MSc, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: eribaric@veleri.hr
[4] Received: 17. 2. 2014.; accepted: 5. 5. 2014.

Silvano Čulinović [1]
Marin Kaluža [2]
Dijana Liverić [3]

Pregledni rad
UDK 004.772.057.4

USPOREDBA PROTOKOLA ZA PRIJENOS DATOTEKA[4]

SAŽETAK

Za pristup podatkovnim (datotečnim) resursima sustava, na korisničkoj razini upotrebljavaju se za to izgrađene namjenske aplikacije. Takav aplikativni softver može se izvršavati lokalno na računalu korisnika i na udaljenom aplikacijskom poslužitelju. U oba slučaja komunikacija korisnika s podatkovnim (datotečnim) poslužiteljem odvija se korištenjem mrežnih resursa. Mrežni resursi predstavljaju najsporije komponente u radu sustava. Aplikativni softver za komunikaciju s datotečnim poslužiteljem može koristiti različite mrežne protokole. U ovom radu analizirani su protokoli za prijenos datoteka na aplikacijskom sloju. Objašnjeni su korišteni sigurnosni mehanizmi u analiziranim protokolima. Izvršeno je mjerenje vremena i brzine prijenosa datoteka u LAN mreži na brzinama 10 Mbps, 100 Mbps i 1 Gbps, te u nezaštićenoj i zaštićenoj (VPN) WAN mreži. Pokazano je da su protokoli koji koriste sigurnosne mehanizme sporiji od protokola koji ne koriste sigurnosne mehanizme. Također je pokazano da korištenje FTP HTTPS sigurnog protokola predstavlja optimalno rješenje – visoka razina sigurnosti i ne značajno manja brzina.

Ključne riječi: *protokol za razmjenu datoteka, sigurnost, mreža, brzina prijenosa*

1. UVOD

Korisnička aplikacija predstavlja osnovu komunikacije između korisnika i računala. Korisnik putem aplikacije upućuje zahtjeve te vrši obrade više ili manje složenih (multimedijskih) podataka.

Aplikacije koje koriste podatkovne (datotečne) resurse s udaljenih mjesta mogu biti instalirane na računalu korisnika, a može im se pristupati udaljeno. Aplikacije koje su instalirane na računalu korisnika izvode lokalno sve osnovne operacije čitanja i ažuriranja udaljenih podatkovnih resursa. Programske operacije koje se izvode na lokalnom računalu koristeći radnu memoriju i sekundarne nosioce podataka, brže se izvode od programskih operacija koje koriste udaljene podatkovne resurse. Propusnost internih računalnih sabirnica veća je od propusnosti mrežnih komponenti. Za komunikaciju prema sekundarnim nosiocima podataka računalo često koristi SATA, SCSI ili

[1] Bacc. inf., policijski tehničar za održavanje EOP opreme, MUP RH PU primorsko-goranska, Ulica žrtava fašizma 3, Rijeka, Hrvatska. *E-mail:* silvano.culinovic@gmail.com

[2] Mr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* mkaluza@veleri.hr

[3] Asistent, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* dliveric@veleri.hr

[4] Datum primitka rada: 16. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

USB sabirnice kojima je propusnost uglavnom višestruko veća od 480 Mbps, što je brzina USB 2.0 sabirnice. S druge strane propusnosti dostupnih i korištenih mreža su uglavnom niže od propusnosti 100 Mbps LAN mreže. Komunikacijski kanal aplikacije s udaljenim podatkovnim resursima koristi mrežne resurse korisničkog računala i time predstavlja najsporiju aplikacijsku komponentu sustava. S druge strane, aplikacije kojima korisnik pristupa udaljeno ne izvode se na računalu korisnika, a korisniku je dostupno sučelje korištenja aplikacijskih operacija. Upravo komunikacija korisničkog sučelja s udaljenim aplikacijskim poslužiteljem također koristi mrežne resurse i time predstavlja najsporiju aplikacijsku komponentu sustava.

Bez obzira na lokaciju izvođenja aplikacije, komunikacija korisnika sa sustavom koristi mrežne resurse korisničkog računala i provodi se standardiziranim mrežnim protokolima.

Komunikacija između dvaju računala, prema OSI modelu, provodi se kroz sedam slojeva. Ti slojevi su (počevši od najnižega): fizički (engl. *physical*), podatkovni (engl. *data link*), mrežni (engl. *network*), transportni (engl. *transport*), sesijski (engl. *session*), prezentacijski (engl. *presentation*) i aplikacijski (engl. *application*) (Dulaney, Harwood, 2012:45). Kada aplikacijski (vršni) korisnički sloj na jednom računalu provodi komunikaciju s aplikacijskim slojem na drugom računalu koriste se unaprijed definirani komunikacijski mehanizmi (protokoli) nižih razina. Neki od TCP/IP protokola koji se koriste na aplikacijskom sloju su: FTP, SFTP, HTTP/S (Dulaney, Harwood, 2012:69-70).

Protokoli koji se u radu analiziraju koriste različite mehanizme za osiguranje povjerljivosti i integriteta paketa (certifikati, privatni ključevi, enkriptirana veza itd.). Protokoli koji koriste potpunije (opširnije) sigurnosne mehanizme su opisom veći (širi), a time je i paket fizički teži (ima više bajtova), pa se može pretpostaviti da će i vrijeme potrebno za prijenos podataka (datoteka) biti dulje, odnosno proces prijenosa sporiji.

Kako mrežna komunikacija predstavlja najsporiju aplikacijsku komponentu sustava, u komunikaciji je potrebno koristiti što brže komunikacijske protokole.

Udaljeni podatkovni ili aplikacijski poslužitelj ne mora biti u LAN mreži korisnika, može biti dostupan kroz WAN mrežu. Komunikacija korisnika sa sustavom provodi se putem nezaštićenog kanala, pa je potrebno koristiti što sigurnije komunikacijske protokole. Radom će se analizirati sigurnosni mehanizmi dostupnih i često korištenih protokola za prijenos datoteka. Pokazat će se koji protokoli zadovoljavaju sigurnosne zahtjeve u komunikaciji.

Izmjerit će se vrijeme prijenosa i prosječna brzina prijenosa datoteka pomoću analiziranih protokola. Zbog kombiniranja različitih „nižih" protokola u osnovnim aplikacijskim protokolima s ciljem osiguranja komunikacije, izmjerit će se vrijeme i prosječna brzina prijenosa na različitim mrežama.

Radom će se pokazati da su protokoli koji koriste sigurnosne mehanizme apsolutno sporiji od protokola koji ne koriste sigurnosne mehanizme. Istražit će se koji protokol i u kojim mrežnim uvjetima postiže najbolje rezultate - najviša razina sigurnosti i najveća brzina.

2. PROTOKOLI ZA PRIJENOS DATOTEKA

2.1 FTP

Standardizirani protokol koji se koristi za prijenos datoteka. Baziran je na arhitekturi klijent-poslužitelj, pri čemu, u ovisnosti o konfiguraciji, poslužitelj može zahtijevati autentifikaciju ili pristup može biti anoniman pa ona nije potrebna. Najčešće se koristi dedicirani port 21.

Prilikom dizajna ovog protokola u obzir nisu uzeti sigurnosni standardi pa tako protokol ne provodi enkripciju podataka. Drugim riječima, putem dostupnih softvera za presretanje mrežnih paketa moguće je, u tekstualnom obliku, pročitati naredbe, korisničko ime, zaporku, sadržaj datoteka itd. Neki od sigurnosnih propusta su (Allman, Ostermann, 1999):

- *bounce* napad
- *brute force* napad
- presretanje paketa
- krađa dediciranog porta
- *spoof* napadi.

2.2 FTPS

S obzirom na brojne sigurnosne propuste FTP protokola, pojavila se potreba za njegovom „nadogradnjom". Jedan od načina ublažavanja potencijalnih napada tijekom otvorene sesije je korištenje sigurnosnog protokola za enkripciju podataka koji se prenose između klijenta i poslužitelja. FTPS koristi TLS ili SSL sigurnosni protokol.

SSL protokol kreirao je Netscape. Posljednja verzija je SSL 3.0 koja datira iz 1999. godine. Kao odgovor na SSL protokol, a potaknuto zahtjevom za standardiziranim protokolom, IETF (engl. *Internet Engineering Task Force*)[5] kreirao je TLS protokol. Prva verzija TLS protokola izdana je 1999. godine, a posljednja verzija TLS 1.2 datira iz 2008. godine. TLS pruža sljedeća svojstva (Ford-Hutchinson, 2005):

- fleksibilna razina sigurnosti, podržava povjerljivost, integritet, autentifikaciju ili njihovu kombinaciju, što tijekom sesije omogućuje da klijent i poslužitelji dinamički odlučuju o potrebnoj razini sigurnosti za specifičan prijenos datoteka
- pruža snažniju autentifikaciju na FTP poslužitelju
- formalizirano upravljanje javnim ključem (engl. *public key*), korištenjem utvrđenih mehanizama identifikacije klijenata u fazi autentifikacije, u središnju funkciju može biti ugrađeno upravljanje certifikatom
- kompatibilnost s autentifikacijskim mehanizmima koji se već koriste unutar HTTP protokola, što *web*-preglednicima omogućuje ugradnju sigurnog prijenosa datoteka korištenjem iste postavljene infrastrukture koja omogućuje sigurno pregledavanje *web*-sadržaja.

Osnovna zadaća TLS protokola je pružanje privatnosti i integriteta podataka između klijenta i poslužitelja. Sastoji se od dvaju slojeva - TLS Record protokol i TLS Handshake protokol.

[5] http://www.ietf.org/

TLS Record protokol omogućuje sigurnost veze koji ima dva osnovna svojstva:

- veza je privatna, koristi se simetrična kriptografija za enkripciju podataka, ključevi su jedinstveni za svaku vezu i bazirani su na TLS Handshake protokolu
- veza je pouzdana, prijenos poruka uključuje provjeru integriteta poruke korištenjem *hash* funkcija (SHA, MD5 itd.).

TLS Record protokol može se koristiti bez enkripcije i bez *hash* funkcije. Nadalje, koristi se prilikom enkapsulacije različitih protokola na višim razinama, kao npr. TLS Handshake protokol.

TLS Handshake protokol omogućuje autentifikaciju između klijenta i poslužitelja te njihov „dogovor" oko korištenog enkripcijskog algoritma i kriptografskih ključeva prije nego aplikacijski protokol pošalje ili primi prve podatke. Protokol pruža sigurnost veze uz tri osnovna svojstva:

- provjera autentičnosti može se utvrditi korištenjem asimetrične kriptografije (javnog ključa)
- nije moguće presresti „dogovorenu" lozinku (engl. *shared secret*)
- „dogovaranje" je pouzdano, napadač ne može mijenjati dogovorenu komunikaciju bez da bude otkriven.

Sigurnosnim mehanizmima koje koristi ovaj protokol umanjuje se zlonamjerno iskorištavanje ranije navedenih sigurnosnih propusta FTP protokola. Najčešće se koristi dedicirani port 990.

2.3 SFTP

SFTP protokol i FTP protokol nisu kompatibilni. SFTP softver ne može se koristiti za siguran pristup FTP poslužitelju. SFTP protokol, nadalje, ne posjeduje niti jednu sigurnosnu značajku. Za sigurnost je zadužen SSH protokol (Barrett, 2005:81-82). Najčešće se koristi dedicirani port 22.

SSH protokol pojavio se 1995. godine u verziji SSH-1. Kako se povećavao broj aktivnih korisnika, otkriveni su brojni propusti i nedostaci, što je rezultiralo razvojem i standardizacijom SSH-2 protokola od strane Secure Shell (SECSH) radne skupine osnovane pri IETF-u.

SSH protokol omogućuje korištenje sigurnih mrežnih servisa korištenjem nesigurnih (javnih) mreža. Sastoji se od triju glavnih komponenti (Ylonen, Lonvick, 2006):

- SSH-TRANS protokol pruža autentifikaciju poslužitelja, povjerljivost i integritet, te opcionalno i kompresiju
- SSH-USERAUTH protokol služi za autentifikaciju klijentskih računala na poslužitelju
- SSH-CONNECT protokol provodi multipleksiranje enkriptiranog tunela u nekoliko logičkih kanala.

SFTP protokol omogućuje siguran prijenos datoteka, pod pretpostavkom da se koristi siguran komunikacijski kanal koji je omogućen korištenjem SSH-2 protokola. SFTP protokol radi na principu *request-response* modela, pri čemu postoji velik broj *request* poruka, ali mali broj mogućih *response* poruka (Galbraith, Saarenmaa, 2006).

2.4 FTP preko HTTP-a

Kombinacijom FTP i HTTP protokola, moguć je prijenos datoteka korištenjem *web*-preglednika. *Web*-preglednik omogućuje pristup FTP poslužitelju neovisno o uređaju kojim se pristupa (pametni telefon, desktop/tablet/prijenosno računalo), neovisno o operacijskom sustavu (Windows, MacOS, Linux, Android, iOS itd.). *Web*-preglednik prikazuje korisničko sučelje sustava kojem korisnik pristupa.

Ovakav pristup FTP poslužitelju nije zaštićen. Uz ranije navedene sigurnosne propuste samog FTP protokola, kako se radi o *web*-aplikaciji, mogući su i DoS napadi. Najčešće se koristi HTTP dedicirani port 80.

2.5 FTP preko HTTPS-a

Razvojem interneta kao medija sve veći broj osjetljivih *web*-aplikacija (bankarske usluge i sl.) ukazuje na brojne sigurnosne propuste i nedostatke HTTP protokola. Kao odgovor stvoren je HTTPS protokol koji omogućuje enkripciju podataka korištenjem TLS/SSL protokola. HTTPS protokol je ustvari HTTP protokol zaštićen SSL/TLS protokolom.

Na nižoj razini aplikacijskog sloja OSI modela kreira se sigurna enkriptirana veza korištenjem SSL/TLS protokola, Pri prijenosu podataka cjelokupan HTTP promet (zaglavlje paketa, *get/post* zahtjevi, URL, podaci itd.) šalju se kroz zaštićeni SSL/TLS tunel.

S obzirom na to da HTTPS koristi iste sigurnosne mehanizme kao i FTPS protokol, može se reći da je ovo *web*-inačica FTPS protokola. I u tom slučaju *web*-aplikacija zamjenjuje klijentski softver. Najčešće se koristi dedicirani port 443.

2.6 Druge značajke mreže u prijenosu podataka

Svaki od protokola na podatkovnom sloju OSI modela ima definiranu veličinu okvira za podatke koji se prenose. Unutar Ethernet LAN mreže, definirana veličina okvira je 1.500 bajtova. Kako bi se omogućilo korištenje IP protokola neovisno o fizičkoj mreži, definirano je visoko ograničenje na veličinu IP okvira 65.535 bajtova. S obzirom na to da su veličine okvira na podatkovnom sloju manje od veličine okvira IP protokola, IP okvir se u prijenosu fragmentira na pakete veličine okvira podatkovnog sloja.

Proces fragmentacije IP okvira odvija se na transportnom sloju OSI modela, pri čemu svaki od fragmenata postaje zaseban paket. Zbog preusmjeravanja, na putu od izvora do odredišta paketi promijene nekoliko različitih mreža (WAN), pri čemu na svakom usmjerivaču (engl. *routeru*) dolazi do dekapsulacije (raspakiravanja) paketa, obrade i ponovne enkapsulacije (pakiranja) paketa. Zbog razlike u veličini okvira podatkovnog sloja mreže u kojoj se paket nalazi može doći do daljnje fragmentacije.

Fragmenti mogu putovati različitim putovima (rutama) od izvora do odredišta, postoji mogućnost gubitka paketa pa ih je potrebno ponovno poslati. Ponovno povezivanje fragmenata obavlja se isključivo na odredištu (Forouzan, 2010:193).

Kako bi se omogućio prijenos većih okvira, na gigabitnoj mrežnoj opremi (mrežne kartice, preklopnici, usmjerivači) moguće je povećati veličinu okvira do najviše 9.000 bajtova. Kako ne bi dolazilo do daljnje fragmentacije, sva korištena oprema unutar LAN mreže morala bi podržavati okvire ove veličine.

3. OPIS TESTNOG OKRUŽENJA

Testno okruženje sastoji se od tri osobna računala različitih tehničkih karakteristika. Temeljeno je na arhitekturi klijent-poslužitelj. Jedno od računala predstavlja poslužiteljsko računalo, dok ostala dva predstavljaju klijentska računala koja će se pomoću klijentskog softvera povezivati s poslužiteljem te prenositi testne datoteke.

Slika 1. Mrežna infrastruktura

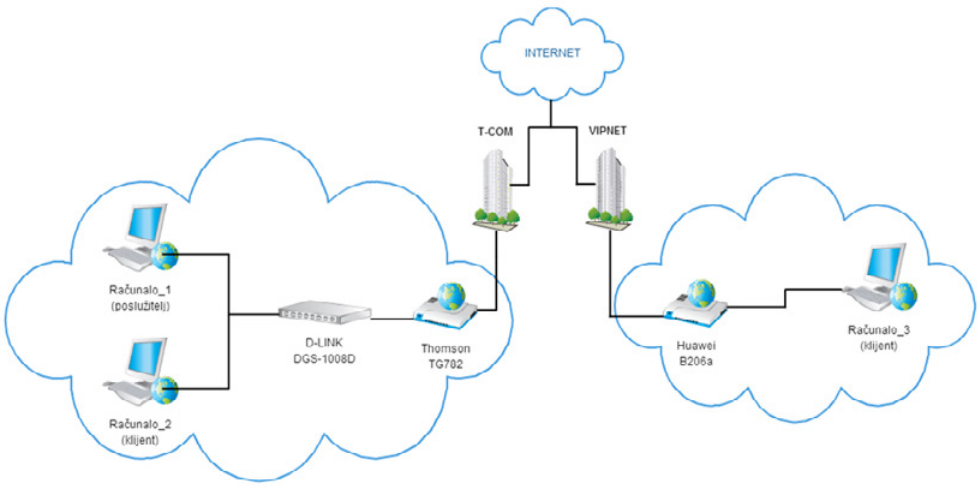

Izvor: obrada autora

Računalna mreža (slika 1) sastoji se od dviju geografski odvojenih LAN mreža. Lokacije imaju različitog pružatelja internetskih usluga. Na jednoj lokaciji poslužitelj internetskih usluga je T-COM, a na drugoj VIPNET. Obje lokacije imaju različite brzine pristupa. Jedna lokacija ima brzinu od 10 Mbps *download* i 640 kbps *upload*, dok na drugoj lokaciji, zbog ograničenja mobilnog operatera (kapacitet bazne stanice, broj aktivnih korisnika itd.) brzina varira od 1 Mbps - 2 Mbps za *download* i *upload*. Kako bi se ispitale brzine prijenosa datoteka pri različitim propusnostima LAN mreže (10/100/1000 Mbps), koristi se D-LINK DGS-1008D, gigabitni mrežni preklopnik (engl. *switch*). Za kreiranje VPN veze korišten je VPN softver koji je integralni dio Microsoft Windows operacijskog sustava, koji na podatkovnom sloju OSI modela koristi PPTP protokol (engl. *point-to-point tunneling protocol*), čime se ostvaruje sigurna veza između dviju udaljenih lokacija.

Na poslužiteljsko računalo instaliran je softver Serv-U[6]. To je komercijalni FTP poslužitelj koji podržava FTP, FTPS (TLS/SSL) i SFTP (SSH2) protokole za prijenos datoteka korištenjem klijentskih softvera, te HTTP/S za prijenos datoteka putem *web*-preglednika. Budući da se namjeravaju koristiti FTPS, HTTPS i SFTP protokoli, kreiran je certifikat i privatni ključ za FTPS i HTTPS protokole te privatni ključ za SFTP protokol.

Za pristup poslužitelju i prijenos datoteka korišten je WinSCP[7], besplatan klijentski softver otvorenog koda koji putem grafičkog korisničkog sučelja omogućuje FTP, FTPS i SFTP pristup poslužitelju ili udaljenom računalu, te osnovne funkcionalnosti za rad s datotekama (engl. *file manager*).

4. OPIS TESTNIH SLUČAJA

Prilikom izvođenja inicijalnih testova i provjera uočeno je da, neovisno o propusnosti mreže, brzina prijenosa nije konstantna. Tako je prilikom prijenosa datoteka uočena razlika u brzini prijenosa. Shodno tome, odabran je uzorak od deset kopiranja.

S obzirom na to da se provjeravala brzina prijenosa korištenjem različitih protokola te različitih propusnosti WAN i LAN mreže, pri manjim propusnostima mreže nisu se prenosile sve datoteke nego samo one čiji se prijenos obavio u prihvatljivom vremenskom razdoblju.

Tijekom izvođenja testova s udaljene lokacije (WAN mreža), zbog propusnosti koja varira od 1 Mbps (cca 125 KB/s) do 2 Mbps (cca 250 KB/s) nisu se vršili prijenosi datoteka većih od 10 MB.

Tijekom izvođenja testova unutar LAN mreže, pri propusnosti od 10 Mbps (cca 1,25 MB/s) nisu se vršili prijenosi datoteka većih od 100 MB.

Pri propusnosti od 100 Mbps (cca 12,5 MB/s) nisu se vršili prijenosi datoteka većih od 1 GB, dok su se pri propusnosti od 1 Gbps (cca 125 MB/s) vršili prijenosi svih datoteka.

Log datoteka Serv-U poslužitelja koristila se kao mjerni instrument. Zapisano je vrijeme početka i vrijeme završetka kopiranja svake datoteke. Vrijeme je zapisano u obliku „YYYYmmdd HH:mm:ss“. Dakle, mjerni instrument može izmjeriti prijenos datoteke koji će trajati više od jedne sekunde. To predstavlja točnost instrumenta mjerenja.

U postupku mjerenja provodila se sljedeća procedura:

[6] http://www.serv-u.com/
[7] http://winscp.net/eng/index.php

1. podešavanje propusnosti LAN mreže (10/100/1000 Mbps)
2. uspostava veze FTP/FTPS/SFTP/HTTP/HTTPS protokolom
3. kreiranje mape na poslužitelju ovisno o trenutno korištenom protokolu
4. kreiranje mape na poslužitelju ovisno o trenutnom rednom broju kopiranja
5. prijenos datoteka
6. prekid veze po završetku kopiranja svih datoteka
7. spremanje log datoteke poslužitelja.

5. REZULTATI MJERENJA

Prema prije definiranom postupku izvršeno je mjerenje brzine i trajanja prijenosa datoteka između dvaju računala. U tablici 1 prikazane su prosječne vrijednosti brzine prijenosa i prosječno vrijeme trajanja prijenosa datoteka po svim promatranim protokolima, u LAN mreži propusnosti od 10 Mbps.

Tablica 1. LAN mreža 10 Mbps, rezultati mjerenja

veličina datoteke	FTP vrijeme	FTP brzina (u KB/s)	FTP HTTP vrijeme	FTP HTTP brzina (u KB/s)	FTP HTTPS vrijeme	FTP HTTPS brzina (u KB/s)	FTPS vrijeme	FTPS brzina (u KB/s)	SFTP vrijeme	SFTP brzina (u KB/s)
112 KB	00:00	1.095,67	00:00	1.232,14	00:00	1.191,70	00:00	894,23	00:00	956,17
256 KB	00:00	1.148,62	00:00	1.161,07	00:00	1.177,88	00:00	1.004,56	00:00	1.014,35
349 KB	00:00	1.130,29	00:00	1.155,10	00:00	1.170,01	00:00	1.042,48	00:00	1.013,17
500 KB	00:01	1.144,95	00:01	1.161,52	00:00	1.168,34	00:01	1.069,11	00:00	1.021,29
651 KB	00:00	1.137,50	00:00	1.156,52	00:00	1.170,37	00:01	1.087,60	00:01	966,50
753 KB	00:01	1.146,88	00:01	1.162,08	00:01	1.161,47	00:01	1.099,76	00:01	1.031,40
825 KB	00:01	1.149,83	00:01	1.161,91	00:01	1.169,46	00:01	1.095,04	00:01	1.032,73
923 KB	00:01	1.151,12	00:01	1.156,74	00:01	1.161,20	00:01	1.105,92	00:01	982,15
1 MB	00:01	1.149,30	00:01	1.158,81	00:01	1.166,92	00:01	1.112,57	00:01	1.036,86
3 MB	00:03	1.156,33	00:03	1.156,78	00:03	1.158,06	00:03	1.137,64	00:03	1.042,46
5 MB	00:04	1.156,55	00:05	1.158,41	00:04	1.155,82	00:05	1.142,38	00:05	1.044,93
8 MB	00:07	1.157,70	00:07	1.158,26	00:07	1.156,46	00:07	1.145,32	00:08	1.046,28
10 MB	00:09	1.157,86	00:09	1.157,25	00:09	1.155,33	00:09	1.145,35	00:10	1.046,73
25 MB	00:22	1.158,50	00:22	1.157,91	00:22	1.154,86	00:22	1.148,94	00:24	1.048,11
84 MB	01:14	1.158,64	01:15	1.157,71	01:15	1.154,83	01:15	1.149,96	01:22	1.048,88
100 MB	01:28	1.158,66	01:28	1.157,70	01:29	1.154,86	01:29	1.150,13	01:37	1.049,68

Izvor: obrada autora

Propusnost takve mreže je cca 1,25 Mb/s, a kako je mjerni instrument ograničen na minimalno 1 s promjene, podaci datoteka koje su manje od 1 Mb ne mogu biti točni, pa se isključuju iz daljnje analize.

Prosječne brzine prijenosa datoteka većih od 1 Mb variraju od 1036,86 kB/s do 1.166,92 kB/s po svim promatranim protokolima. To pokazuje visoku podudarnost brzina prijenosa svih protokola.

Slika 2. LAN 10 Mbps, brzina prijenosa

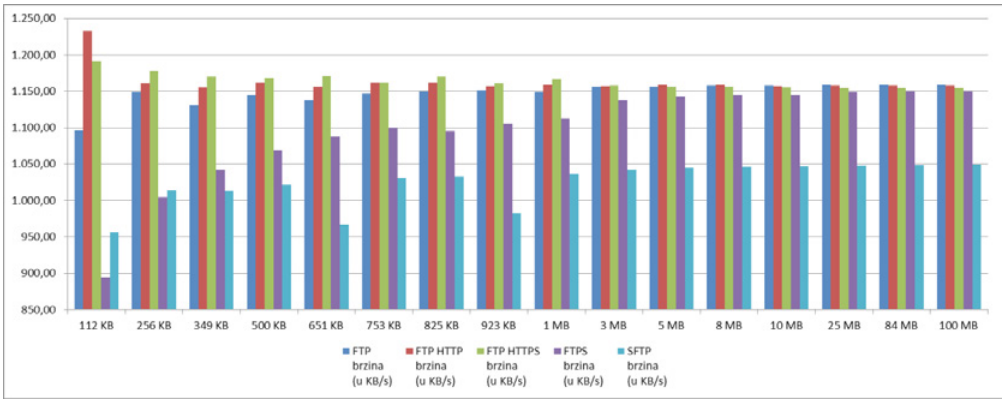

Izvor: obrada autora

Na slici 2 vidljivo je da kod prijenosa datoteka manjih od 1 MB, zbog kratkog vremena koje je potrebno za prijenos (oko jedne sekunde), dolazi do većih odstupanja u brzini prijenosa. Kod prijenosa datoteka većih od 1 MB zbog dužeg trajanja samog prijenosa, odstupanja u brzini prijenosa su unutar prihvatljivih ± 1% (cca 10 kB/s).

Prema slici 2, SFTP protokol je značajnije sporiji od ostalih. Najbrži protokoli su uglavnom nesigurni FTP i FTP-HTTP. Sigurni FTP HTTPS i FTPS su sporiji do 1 % (cca 10 kB/s). S obzirom na to da ne postoji značajna razlika u brzini prijenosa pomoću sigurnih protokola u odnosu na brzinu prijenosa pomoću nesigurnih protokola, optimalno rješenje je korištenje sigurnih FTP HTTPS i FTPS protokola, a pritom je veće brzine prijenosa ostvario FTP HTTPS protokol.

Drugo mjerenje brzine protokola izvršeno je u lokalnoj mreži na brzini od 100 Mbps. Tablica 2 pokazuje rezultate tog mjerenja.

Tablica 2. LAN mreža 100 Mbps, rezultati mjerenja

veličina datoteke	FTP vrijeme	FTP brzina (u KB/s)	FTP HTTP vrijeme	FTP HTTP brzina (u KB/s)	FTP HTTPS vrijeme	FTP HTTPS brzina (u KB/s)	FTPS vrijeme	FTPS brzina (u KB/s)	SFTP vrijeme	SFTP brzina (u KB/s)
112 KB	00:00	1.238,08	00:00	1.133,62	00:00	6.442,48	00:00	803,04	00:00	6.077,20
256 KB	00:00	11.435,70	00:00	9.690,41	00:00	13.839,06	00:00	5.061,22	00:00	5.739,78
349 KB	00:00	10.874,81	00:00	11.823,38	00:00	12.235,30	00:00	5.684,28	00:00	5.477,82
500 KB	00:00	10.684,55	00:00	14.944,11	00:00	11.608,35	00:00	6.562,89	00:00	5.663,64
651 KB	00:00	10.938,16	00:00	11.673,89	00:00	11.437,93	00:00	8.150,24	00:00	4.842,37
753 KB	00:00	11.052,25	00:00	11.616,68	00:00	11.516,24	00:00	7.742,62	00:00	5.561,80
825 KB	00:00	10.849,87	00:00	10.754,18	00:00	11.413,77	00:00	8.485,51	00:00	5.465,60
923 KB	00:00	11.048,77	00:00	10.976,62	00:00	10.777,79	00:00	8.479,23	00:00	5.047,76
1 MB	00:00	10.940,47	00:00	11.878,02	00:00	10.203,41	00:00	8.961,48	00:00	5.464,29
3 MB	00:00	11.517,73	00:01	9.977,79	00:00	9.705,55	00:00	10.478,82	00:00	5.455,74
5 MB	00:00	11.522,21	00:00	10.037,55	00:01	9.691,66	00:01	10.802,45	00:01	5.517,65
8 MB	00:01	11.416,38	00:01	11.407,74	00:01	11.077,80	00:00	11.011,40	00:01	5.432,62
10 MB	00:01	11.494,31	00:01	11.485,61	00:01	11.145,34	00:01	11.146,59	00:03	3.415,49
25 MB	00:02	11.540,46	00:02	11.501,22	00:02	11.217,47	00:03	11.348,76	00:06	4.458,31
84 MB	00:08	11.557,26	00:08	11.487,56	00:08	11.236,93	00:07	11.429,96	00:22	3.892,61
100 MB	00:09	11.554,46	00:09	11.519,33	00:09	11.290,01	00:09	11.437,65	00:29	3.547,12
550 MB	00:49	11.506,36	00:49	11.534,67	00:50	11.322,33	00:49	11.456,78	-	-
650 MB	00:58	11.552,66	00:58	11.522,78	00:59	11.330,32	00:58	11.449,59	-	-
900 MB	01:20	11.548,32	01:20	11.543,10	01:21	11.336,92	01:21	11.447,86	-	-
1 GB	01:30	11.550,55	01:31	11.553,78	01:33	11.322,90	01:33	11.277,73	-	-

Izvor: obrada autora

Tablica 2 pokazuje prosječno vrijeme i prosječnu brzinu prijenosa datoteka po promatranim protokolima u LAN mreži na brzini od 100 Mbps. Propusnost mreže je cca 12,5 Mb/s, a kako je mjerni instrument ograničen na minimalno 1 s promjene, podaci datoteka koje su manje od 12 Mb ne mogu biti točni, pa se isključuju iz daljnje analize.

Može se uočiti da je prosječna brzina prijenosa korištenjem SFTP protokola nekoliko puta manja u odnosu na prosječne brzine prijenosa prilikom korištenja ostalih protokola. Razlika pogotovo dolazi do izražaja tijekom prijenosa većih datoteka (10 MB i više) kada se prosječno vrijeme prijenosa povećalo za tri puta u odnosu na prosječna vremena prilikom korištenja ostalih protokola. Brzina prijenosa datoteka SFTP protokolom je cca 3 puta manja od ostalih protokola, pa se SFTP protokol isključuje iz daljnje analize. Tijekom daljnjih testiranja korištenjem SFTP protokola nisu se prenosile datoteke veće od 100 MB.

Prosječne brzine prijenosa datoteka većih od 10 MB variraju od 11.217,47 kB/s do 11.557,26 kB/s na preostala 4 protokola, što pokazuje visoku podudarnost brzina prijenosa datoteka pomoću njih.

Slika 3. LAN 100 Mbps, brzina prijenosa

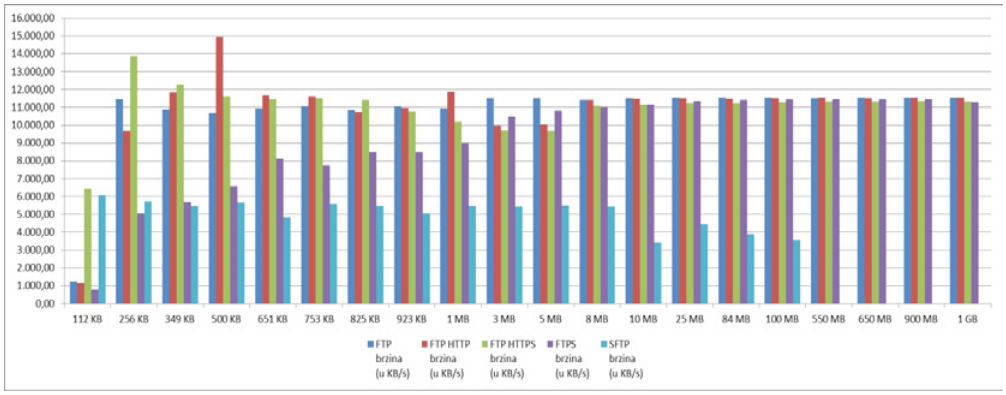

Izvor: obrada autora

Na slici 3 vidljivo je da kod prijenosa datoteka manjih od 10 MB, zbog kratkog vremena koje je potrebno za prijenos (oko jedne sekunde), dolazi do većih odstupanja u brzini prijenosa. Kod prijenosa datoteka većih od 10 MB zbog dužeg trajanja samog prijenosa, odstupanja u brzini prijenosa su unutar prihvatljivih ± 1,5% (cca 150 kB/s).

Prema slici 3, SFTP protokol značajnije je sporiji od ostalih. Najbrži protokoli su uglavnom nesigurni FTP i FTP-HTTP. Sigurni FTP HTTPS i FTPS sporiji su do 2 % (cca 200 kB/s).

S obzirom na to da i u ovom slučaju ne postoji značajna razlika u brzini prijenosa pomoću sigurnih protokola u odnosu na brzinu prijenosa pomoću nesigurnih protokola, kao u sporijoj LAN 10 Mbps mreži, optimalno rješenje je korištenje sigurnih FTP HTTPS i FTPS protokola, a pritom ipak nešto veće brzine prijenosa ostvario je FTPS protokol.

Treće mjerenje brzine protokola izvršeno je u lokalnoj mreži na brzini od 1 Gbps. Tablica 3 pokazuje rezultate tog mjerenja.

Tablica 3. LAN mreža 1000 Mbps, rezultati mjerenja

veličina datoteke	FTP vrijeme	FTP brzina (u KB/s)	FTP HTTP vrijeme	FTP HTTP brzina (u KB/s)	FTP HTTPS vrijeme	FTP HTTPS brzina (u KB/s)	FTPS vrijeme	FTPS brzina (u KB/s)	SFTP vrijeme	SFTP brzina (u KB/s)
112 KB	00:00	999,86	00:00	2.866,80	00:00	1.938,43	00:00	772,13	00:00	4.783,02
256 KB	00:00	13.758,28	00:00	5.012,92	00:00	13.518,36	00:00	7.723,32	00:00	5.470,49
349 KB	00:00	19.047,24	00:00	11.188,18	00:00	21.955,21	00:00	9.771,18	00:00	5.172,46
500 KB	00:00	22.284,95	00:00	22.843,67	00:00	29.945,12	00:00	12.130,23	00:00	5.026,66
651 KB	00:00	22.489,59	00:00	19.151,09	00:00	24.292,89	00:00	11.868,44	00:00	5.001,19
753 KB	00:00	26.653,57	00:00	4.252,71	00:00	44.569,48	00:00	14.497,08	00:00	4.664,09
825 KB	00:00	29.368,45	00:00	19.312,84	00:00	40.253,53	00:00	15.015,44	00:00	4.579,84
923 KB	00:00	35.741,44	00:00	26.037,42	00:00	28.969,18	00:00	15.742,82	00:01	4.185,52
1 MB	00:00	26.847,92	00:00	44.800,40	00:00	29.950,88	00:00	14.860,01	00:00	5.338,22
3 MB	00:00	30.151,83	00:00	73.439,40	00:00	32.236,55	00:00	19.734,59	00:01	5.627,10
5 MB	00:00	34.916,15	00:00	77.340,55	00:00	35.618,43	00:00	21.524,14	00:01	5.659,96
8 MB	00:00	31.924,42	00:00	83.924,66	00:00	38.403,19	00:00	22.357,64	00:02	5.344,72
10 MB	00:00	37.586,44	00:00	68.534,16	00:00	40.616,92	00:00	23.385,10	00:03	3.447,65
25 MB	00:01	36.671,92	00:01	77.878,24	00:01	46.491,99	00:01	23.992,29	00:06	4.434,52
84 MB	00:01	80.508,84	00:01	66.488,91	00:02	42.387,52	00:04	24.446,33	00:22	3.840,04
100 MB	00:01	76.663,58	00:01	68.652,86	00:02	42.226,60	00:04	24.377,09	00:29	3.566,48
550 MB	00:05	105.866,55	00:09	61.251,70	00:14	40.236,55	00:23	24.631,74	-	-
650 MB	00:07	98.933,60	00:11	61.200,33	00:17	40.508,19	00:27	24.680,79	-	-
900 MB	00:09	105.014,02	00:15	60.578,79	00:23	40.079,50	00:37	24.902,19	-	-
1 GB	00:10	104.724,06	00:17	61.364,86	00:26	40.231,50	00:43	24.753,84	-	-
4.8 GB	00:42	110.738,77	-	-	-	-	-	-	-	-
8.5 GB	01:15	110.705,22	-	-	-	-	-	-	-	-
10 GB	01:35	111.270,94	-	-	-	-	-	-	-	-

Izvor: obrada autora

Tablica 3 pokazuje prosječno vrijeme i prosječnu brzinu prijenosa datoteka po promatranim protokolima u LAN mreži na brzini od 1 Gbps. Propusnost mreže veća je od 100 Mb/s, a kako je mjerni instrument ograničen na minimalno 1 s promjene, podaci datoteka koje su manje od 100 Mb ne mogu biti točni, pa se isključuju iz daljnje analize.

Prilikom korištenja FTP protokola postiže se skoro maksimalna brzina prijenosa (preko 100 MB/s).

SFTP protokol je na sporijoj LAN mreži isključen iz analize, pa se i u ovoj analizi isključuje.

Prosječna brzina prijenosa korištenjem FTP preko HTTP je skoro 40 % manja u odnosu na prosječnu brzinu prijenosa prilikom korištenja FTP protokola.

Prosječna brzina prijenosa korištenjem FTP-a preko HTTPS protokola je skoro 60 % manja u odnosu na prosječnu brzinu prijenosa prilikom korištenja FTP protokola.

Prosječna brzina prijenosa korištenjem FTPS protokola je skoro 80 % manja u odnosu na prosječnu brzinu prijenosa prilikom korištenja FTP protokola.

S obzirom na neočekivano velike razlike prosječnih brzina prijenosa, u nastavku testiranja korištenjem FTP-a preko HTTP-a, FTP preko HTTPS-a te FTPS protokola nisu se prenosile datoteke veće od 1 GB, dok se prilikom testiranja korištenjem SFTP protokola nisu prenosile datoteke veće od 100 MB.

Kod prijenosa datoteka većih od 100 MB zbog dužeg trajanja samog prijenosa, odstupanja u brzini prijenosa su unutar prihvatljivih ± 1 % (< 1 MB/s) za protokole FTP HTTP, FTP HTTPS i FTPS te 5,54 % za FTP protokol.

Slika 4. LAN 1000 Mbps, brzina prijenosa

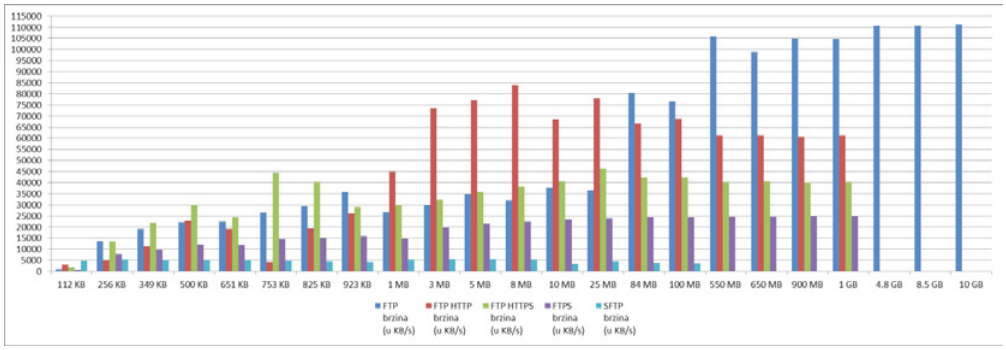

Izvor: obrada autora

Na slici 4 vidljivo je da kod prijenosa datoteka manjih od 100 MB, zbog kratkog vremena koje je potrebno za prijenos (oko jedne sekunde), dolazi do većih odstupanja u brzini prijenosa. Prema slici 3 FTP protokol je najbrži. FTP HTTP i FTP HTTPS značajnije su sporiji od FTP protokola. FTPS protokol je do 4 puta sporiji od FTP protokola.

Postoji značajna razlika u brzini prijenosa pomoću sigurnih protokola u odnosu na brzinu prijenosa pomoću nesigurnih protokola. Brzine prijenosa su visoke (sve iznad 20 Mbps), a datoteke koje su se prenosile su veće od 100 MB.

Ovakva brzina mreže može se ostvariti isključivo u LAN uvjetima. Najčešće se takve brzine postavljaju kao tzv. „LAN backbone" između poslužitelja, a rjeđe u komunikaciji između klijenta i poslužitelja, pa u tom slučaju postoji manja potreba za korištenjem sigurnih protokola. Kako su brzine koje su ostvarene korištenjem sigurnih protokola (bez SFTP protokola) iznad 20 Mbps, a rijetki su slučajevi prijenosa toliko velikih datoteka (> 100 MB) i pritom se takvi prijenosi odvijaju u razumnom vremenu od nekoliko sekundi, korištenje sigurnih protokola ne bi trebalo značajnije utjecati na performanse sustava.

Sljedeća mjerenja izvršena su na WAN mreži i to u dva oblika:

- nezaštićeni (otvoreni),
- zaštićeni (osiguran VPN na mrežnoj razini).

Tablica 4 pokazuje rezultate mjerenja prijenosa datoteka u nezaštićenoj WAN mreži.

Tablica 4. Nezaštićena WAN mreža, rezultati mjerenja

veličina datoteke	FTP vrijeme	FTP brzina (u KB/s)	FTP HTTP vrijeme	FTP HTTP brzina (u KB/s)	FTP HTTPS vrijeme	FTP HTTPS brzina (u KB/s)	FTPS vrijeme	FTPS brzina (u KB/s)	SFTP vrijeme	SFTP brzina (u KB/s)
112 KB	00:02	81,78	00:01	93,68	00:01	155,83	00:02	66,12	00:01	88,68
256 KB	00:04	75,36	00:03	119,58	00:02	190,20	00:04	75,37	00:02	105,20
349 KB	00:05	77,71	00:05	89,02	00:02	193,96	00:07	63,64	00:03	120,54
500 KB	00:06	102,42	00:04	127,80	00:02	209,79	00:08	71,26	00:05	109,36
651 KB	00:07	107,28	00:06	121,84	00:03	219,06	00:09	88,25	00:06	109,48
753 KB	00:07	113,79	00:08	138,79	00:04	235,53	00:13	73,12	00:07	119,48
825 KB	00:08	119,74	00:08	133,68	00:05	227,27	00:12	90,86	00:06	146,77
923 KB	00:08	123,02	00:10	127,04	00:04	243,48	00:12	88,57	00:08	127,82
1 MB	00:10	123,38	00:11	119,07	00:04	252,08	00:15	76,52	00:09	124,34
3 MB	00:30	104,00	00:27	135,43	00:12	254,48	00:45	76,76	00:23	142,23
5 MB	00:52	106,43	00:45	132,27	00:21	251,30	01:09	84,76	00:41	127,19
8 MB	01:07	129,84	01:26	107,59	00:35	248,28	01:50	81,68	01:19	111,70
10 MB	01:46	100,48	01:33	124,81	00:43	246,56	01:57	92,94	01:37	118,34

Izvor: obrada autora

Tablica 4 pokazuje prosječno vrijeme i prosječnu brzinu prijenosa datoteka po promatranim protokolima u nezaštićenoj WAN mreži. Vidljivo je da je prosječno vrijeme prijenosa datoteka manjih od 1 MB po svim protokolima u prihvatljivim granicama od nekoliko sekundi. Kod prijenosa datoteka većih od 1 MB dolazi do većih odstupanja koja u pojedinim slučajevima iznose i do pola minute. Iz tablice je također vidljivo da po svim protokolima dolazi do većih odstupanja u brzini prijenosa, pogotovo kod FTP HTTPS protokola, gdje je brzina prijenosa čak i dvostruko veća od ostalih protokola. Razlog tome može biti stoga **što je korišten posljednji**, pri čemu postoji mogućnost da je došlo do rasterećenja mobilne mreže internetskog pružatelja usluge.

Slika 5. Nezaštićena WAN mreža, brzina prijenosa

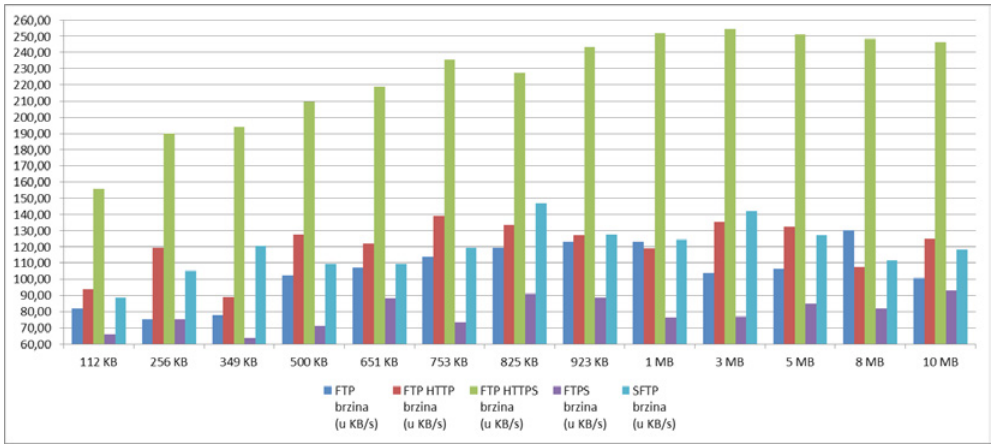

Izvor: obrada autora

Na slici 5 vidi se da je brzina prijenosa FTP HTTPS protokolom u svim prijenosima više nego dvostruko veća od izmjerenih brzina prijenosa ostalim protokolima. Nadalje, brzina prijenosa FTP protokolom uglavnom je manja od brzine prijenosa FTP HTTP protokolom. Brzina prijenosa FTPS protokolom više je nego dvostruko manja od brzine prijenosa FTP HTTP protokolom. Brzine prijenosa SFTP protokolom uglavnom se podudaraju s brzinama prijenosa FTP HTTP protokolom.

Posljednje mjerenje brzine protokola izvršeno je u WAN zaštićenoj mreži. Tablica 5 pokazuje rezultate tog mjerenja.

Tablica 5. Zaštićena WAN mreža, rezultati mjerenja

veličina datoteke	FTP vrijeme	FTP brzina (u KB/s)	FTP HTTP vrijeme	FTP HTTP brzina (u KB/s)	FTP HTTPS vrijeme	FTP HTTPS brzina (u KB/s)	FTPS vrijeme	FTPS brzina (u KB/s)	SFTP vrijeme	SFTP brzina (u KB/s)
112 KB	00:01	98,81	00:01	95,93	00:02	78,15	00:02	75,08	00:01	84,45
256 KB	00:03	104,52	00:03	120,83	00:04	96,73	00:03	81,17	00:02	112,75
349 KB	00:04	115,45	00:05	104,20	00:04	106,89	00:04	91,33	00:03	114,33
500 KB	00:05	111,34	00:05	121,87	00:05	118,13	00:05	97,87	00:04	121,9
651 KB	00:05	135,89	00:06	125,87	00:08	115,50	00:06	113,17	00:05	118,65
753 KB	00:06	133,43	00:07	140,80	00:07	132,07	00:07	115,21	00:06	112,57
825 KB	00:06	142,74	00:07	139,44	00:07	130,14	00:08	105,27	00:06	116,64
923 KB	00:07	139,39	00:08	142,78	00:08	142,24	00:09	106,02	00:07	114,35
1 MB	00:08	134,22	00:09	156,15	00:10	131,61	00:10	111,45	00:08	116,75
3 MB	00:23	144,53	00:27	133,38	00:30	124,04	00:27	117,53	00:24	123,08
5 MB	00:37	150,37	00:45	128,40	01:02	98,34	00:43	122,18	00:40	125,56
8 MB	01:01	136,65	01:19	113,71	01:19	110,43	01:05	128,34	01:05	125,19
10 MB	01:14	139,56	01:37	118,65	01:51	100,50	01:26	121,22	01:23	123,58

Izvor: obrada autora

Tablica 5 pokazuje prosječno vrijeme i prosječnu brzinu prijenosa datoteka po promatranim protokolima u zaštićenoj WAN mreži.

Propusnost testne mreže za prijenos datoteka od klijenta Računalo 3 do poslužitelja Računalo 1 (slika 1) je minimalno 1 Mbps (128 kBps), a točnost mjernog instrumenta je vremenski period od 1 s. Zbog toga se prijenosi datoteke od 112 kB isključuju iz daljnje analize.

Vidljivo je da, neovisno o korištenom protokolu, ne postoji velika razlika u prosječnom vremenu prijenosa datoteka. Sva odstupanja su unutar prihvatljivih granica od nekoliko sekundi. Prilikom prijenosa većih datoteka (5 MB, 8 MB, 10 MB) primijeti se da je prosječno vrijeme prijenosa datoteka korištenjem FTP HTTPS protokola osjetno duže, pa razlika iznosi i do pola minute u odnosu na prosječno vrijeme prijenosa prilikom korištenja ostalih protokola.

Slika 6. Zaštićena WAN mreža, brzina prijenosa

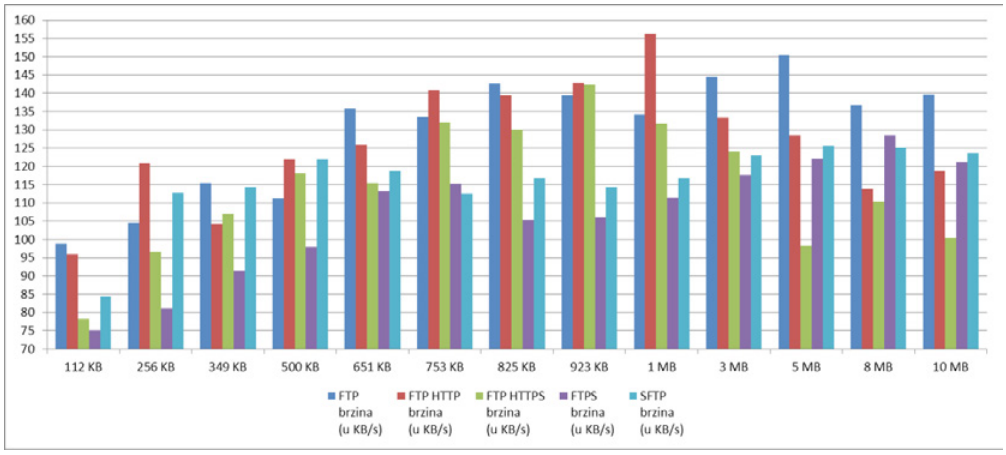

Izvor: obrada autora

Na slici 6 vidi se da su FTP, FTP HTTP i FTP HTTPS protokoli uglavnom najbrži, a posebno u prijenosu datoteka između 300 kB i 3 MB. Prijenosi datoteka sa SFTP protokolom su uglavnom ujednačenih brzina s prosječnim odstupanjem 8,07 %. Brzine prijenosa datoteka s FTPS protokolom uglavnom se podudaraju brzinama prijenosa sa SFTP protokolom.

Tablica 6 prikazuje najveće i prosječne brzine prijenosa za sve promatrane protokole po svim obavljenim prijenosima.

Tablica 6. Usporedni prikaz brzina prijenosa

Tip i propusnost mreže	Protokol	Najveća brzina prijenosa (u KB/s)	Prosječna brzina prijenosa (u KB/s)
Nezaštićena WAN	FTP	223,15	105,02
	FTP HTTP	263,76	120,81
	FTP HTTPS	334,04	225,26
	FTPS	190,06	79,22
	SFTP	302,20	119,32
Zaštićena WAN (VPN)	FTP	274,29	129,76
	FTP HTTP	267,08	126,31
	FTP HTTPS	249,58	114,21
	FTPS	144,98	106,60
	SFTP	132,23	116,14
LAN 10 Mbps	FTP	1.204,30	1.147,40
	FTP HTTP	1.351,39	1.163,12
	FTP HTTPS	1.233,20	1.164,22
	FTPS	1.168,95	1.095,69
	SFTP	1.064,02	1.023,85
LAN 100 Mbps	FTP	17.066,67	10.791,17
	FTP HTTP	21.187,74	10.903,10
	FTP HTTPS	23.269,21	11.007,58
	FTPS	11.592,45	9.160,91
	SFTP	8.258,06	5.066,24
LAN 1000 Mbps	FTP	113.655,69	55.342,07
	FTP HTTP	111.305,18	45.806,02
	FTP HTTPS	52.319,60	33.721,50
	FTPS	31.250,00	18.058,32
	SFTP	7.466,67	4.758,87

Izvor: obrada autora

S obzirom na različite čimbenike koji su uključeni u sam proces prijenos datoteka (propusnost mreže, propusnost sabirnice računala, veličina datoteke, sučelje i brzina zapisivanja čvrstog diska, sigurnosni mehanizmi pojedinih protokola) očekivalo se da će biti odstupanja u brzini prijenosa. U tablici 6 odstupanje najveće brzine prijenosa od prosječne po svim testiranim protokolima je od 3,77 % (LAN 10 Mbps, SFTP) do 60,51 % (nezaštićeni WAN, SFTP), a prosječno odstupanje je 36,5%.

Slika 7. Usporedni prikaz brzina prijenosa, propusnost manja od 100 Mbps

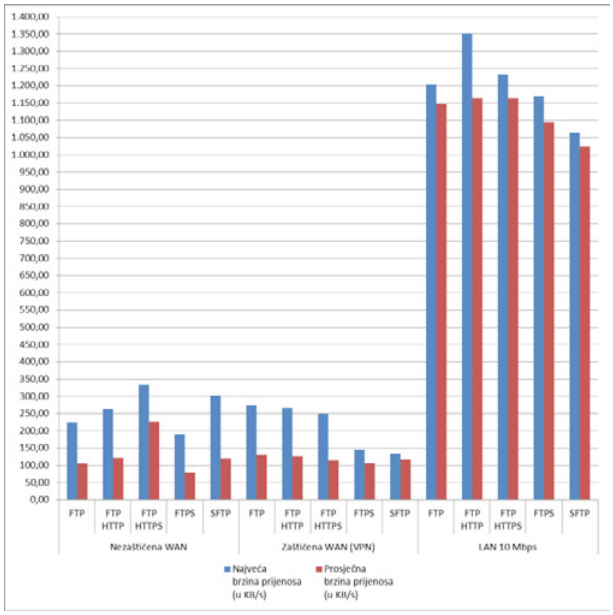

Izvor: obrada autora

Slika 8. Usporedni prikaz brzina prijenosa, propusnost veća od 100 Mbps

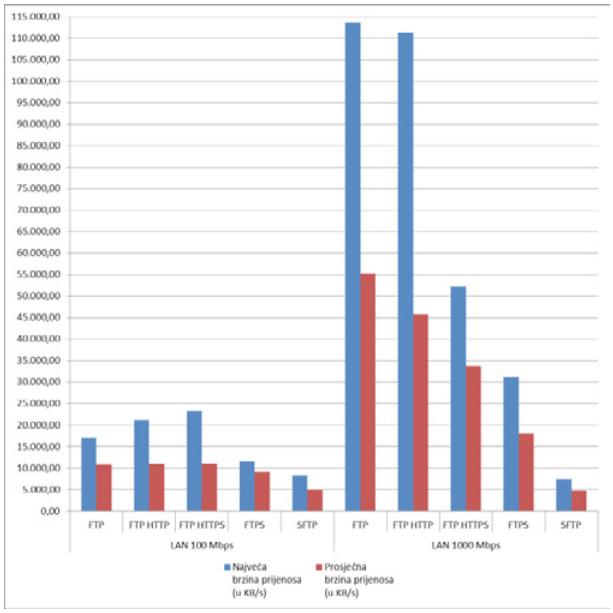

Izvor: obrada autora

Slike 7 i 8 pokazuju odnos maksimalne i prosječne brzine prijenosa po svim protokolima i mrežama. Pri manjim propusnostima mreže, svi su protokoli ostvarili uglavnom ujednačene brzine prijenosa. Veća razlika u prosječnim brzinama po protokolima vidi se u slučajevima: nezaštićena WAN mreža i LAN 1 Gbps mreža.

Prethodno je pokazano (slike 2 i 3) da na LAN mrežama s propusnostima 10 Mbps i 100 Mbps ne postoji značajna razlika u prosječnoj brzini prijenosa datoteka pomoću sigurnih protokola FTP HTTPS i FTPS u odnosu na nesigurne protokole. Brzina prijenosa datoteka u LAN mreži na brzini od 1 Gbps s protokolima FTP HTTPS i FTPS je značajnije manja od brzine prijenosa s nesigurnim protokolima (slika 4), ali kako se pri takvoj brzini mreže rijetko prenose velike datoteke iznad 100 MB, korištenje sigurnih sporijih protokola FTP HTTP i FTP HTTPS ne bi trebalo previše utjecati na performanse sustava. Ako se LAN 1 Gbps koristi u komunikaciji između poslužitelja, tada sigurnost može biti riješena drugim mehanizmima LAN mreže, pomoću nesigurnog FTP protokola ostvarit će se najveće brzine prijenosa datoteka.

Kod nezaštićene WAN mreže najveće brzine prijenosa (slika 5) ostvarene su pomoću FTP HTTPS protokola. U daljnjim istraživanjima potrebno je ispitati različite WAN mreže (pružatelje usluga), čime će se provjeriti točnost rezultata.

Najbrži prijenosi podataka u zaštićenoj WAN mreži (slika 6) ostvareni su uglavnom pomoću FTP, FTP HTTP i FTP HTTPS protokola. Isti protokoli ostvarili su uglavnom najbolje rezultate na svim nepromjenjivim mrežama (LAN 10 Mbps, 100 Mbps i 1 Gbps).

Kako se prema mjerenjima u nepromjenjivim mrežama (LAN 10 Mbps, 100 Mbps i 1 Gbps) protokol FTP HTTPS pokazao optimalnim u svim slučajevima, a istim je protokolom ostvarena apsolutno najveća brzina prijenosa na nezaštićenoj WAN mreži, i zaštićena WAN mreža ima uglavnom sličan odnos brzina (po protokolima) s nepromjenjivim LAN mrežama, FTTP HTTPS protokol predstavlja optimalno rješenje u svim slučajevima prijenosa datoteka.

Kod korištenja LAN ili WAN računalnih mreža čija je propusnost 10 Mbps ili manja, temeljem dobivenih rezultata preporučuje se korištenje nekog od sigurnijih protokola za prijenos datoteka (SFTP, FTPS ili FTP preko HTTPS). Razlika u prosječnom vremenu prijenosa datoteka od nekoliko sekundi je zanemariva, a korištenjem navedenih protokola ostvaruje se sigurnija veza između klijenta i poslužitelja.

Postoji li potreba za razmjenom povjerljivih podataka na geografski udaljenim lokacijama (izdvojeni uredi, poslovnice i sl.), zbog nedovoljne sigurnosti javnih mreža preporučuje se povezivanje u VPN mrežu. VPN omogućuje „siguran" prijenos podataka.

Kod korištenja LAN računalne mreže čija je propusnost veća od 100 Mbps, razlike u prosječnoj brzini prijenosa datoteka su izraženije. Kada se radi o računalnoj mreži koja je zaštićena od neovlaštenog upada (hardverski i/ili softverski vatrozid i sl.) s pretpostavkom da nitko od korisnika ili zaposlenika neće pratiti mrežni promet i presretati pakete, mogu se koristiti nesigurni protokoli za prijenos datoteka, a posebice FTP s kojim se ostvaruju najveće brzine prijenosa.

S obzirom na drastične razlike u brzini prijenosa pri većim propusnostima računalne mreže, u budućim istraživanjima mogu se ispitati uzroci koji mogu biti:

- zaštitni mehanizmi u vidu dodatnih protokola
- postavke računalne mreže
- interne računalne komponente.

Zbog upitne točnosti rezultata mjerenja na nezaštićenoj WAN mreži potrebno je izvršiti mjerenje na različitim WAN mrežama u nezaštićenom i zaštićenom (VPN) obliku.

6. ZAKLJUČAK

Ovim su radom uspoređeni različiti protokoli koji se na aplikacijskom sloju OSI modela koriste za prijenos podataka. Neki od korištenih protokola (FTP, FTP HTTP) ne posjeduju nikakve zaštitne mehanizme, tj. podatke koji se prenose moguće je presresti i pročitati njihov sadržaj.

Na osnovi jasnih sigurnosnih propusta kreirani su zaštitni mehanizmi u obliku dodatnih protokola (SSL/TLS, SSH itd.). Takvi protokoli dijele zajednički cilj (osiguranje povjerljivosti i integriteta podataka), ali ih ostvaruju na različite načine.

Odabir najprikladnijeg protokola trebao bi ovisiti o namjeni i tipu sustava unutar kojega će se koristiti (prijenos datoteka unutar poslovne ili privatne mreže, *stream* multimedijskog sadržaja, pristup sadržaju internetom i sl.), što bi moglo biti predmet nekih budućih istraživanja.

Kada se govori o računalnim mrežama poznato je da ne postoji apsolutna sigurnost i zaštita od zlonamjernih napada. Korištenjem sigurnosnih mehanizama i protokola potencijalne napadače može se odvratiti od napada ili im se barem može uvelike otežati pristup.

Radom je pokazano da na lokalnoj mrežnoj infrastrukturi prosječnih brzina (10 Mbps i 100 Mbps) ne postoji značajna razlika u brzini prijenosa datoteka korištenjem FTP, FTP HTTP, FTP HTTPS i FTPS protokola.

U lokalnoj mreži na brzini od 1 Gbps zbog rjeđih potreba za prijenosom velikih datoteka, kada korištenje sigurnih protokola neće značajnije utjecati na performanse sustava, treba koristiti siguran protokol FTP HTTPS. Ako se mrežna komunikacija ostvaruje između poslužitelja i sigurnost je riješena drugim sustavnim mehanizmima, treba koristiti FTP protokol.

Prijenos datoteka u WAN mreži treba biti siguran. Mjerenja su pokazala da je FTP HTTPS protokolom ostvarena najveća brzina prijenosa u nezaštićenoj WAN mreži, a zaštićena WAN mreža ima sličan omjer brzina kao i nepromjenjiva LAN mreža, pa prema tome FTP HTTPS protokol predstavlja najbolje rješenje.

LITERATURA

Allman, M., Ostermann, S. (1999) *FTP Security Considerations*, IETF RFC 2577, http://tools.ietf.org/html/rfc2577 (pristupano 22 . 12 . 2013.)

Barrett, D. (2005) *SSH, The Secure Shell: The Definitive Guide*, drugo izdanje, SAD: O'Rilley Media

Dulaney, E., Harwood, M. (2012) *CompTIA Network+ N10-005 Authorized Exam Cram*, četvrto izdanje, SAD: Pearson

Ford-Hutchinson, P. (2005) *Securing FTP with TLS*, IETF RFC 4217, http://tools.ietf.org/html/rfc4217 (pristupano 22 . 12 . 2013.)

Forouzan, B. (2010) *TCP/IP Protocol Suite*, četvrto izdanje, SAD: McGraw-Hill

Galbraith, J., Saarenmaa, O. (2006) *SSH File Transfer Protocol*, IETF SECSH Draft, http://tools.ietf.org/html/draft-ietf-secsh-filexfer-13 (pristupano 22 . 12 . 2013.)

McKinley, H., SSL and TLS: A Beginners Guide, SANS Institute, 2003.http://www.sans.org/reading-room/whitepapers/protocols/ssl-tls-beginners-guide-1029 (pristupano 22 . 12 . 2013.)

Ylonen, T., Lonvick, C. (2006) *The Secure Shell (SSH) Protocol Architecture*, IETF RFC 4251, http://tools.ietf.org/html/rfc4251 (pristupano 22 . 12 . 2013.)

Silvano Čulinović[1]
Marin Kaluža[2]
Dijana Liverić[3]

Review article
UDC 004.772.057.4

COMPARISON OF FILE TRANSFER PROTOCOLS[4]

ABSTRACT

To access the system data (file) resources, specially built software is used at the user level. This software can be run locally on the user computer and remotely on the remote application server. In both cases, communication with the database server (file server) takes place using network resources. Network resources are the slowest component in the system. Software that communicates with the file server can use different network protocols.

This paper analyzes different file transfer protocols at the application layer of the OSI model. Security mechanisms used in the analyzed protocols are explained. Timing and speed of transferring files in the LAN at the speeds of 10Mbps, 100Mbps and 1Gbps, and the unprotected and protected (VPN), WAN network were measured and noted.

It is shown that the protocols that use security mechanisms are slower than those that do not use security mechanisms. It is also shown that the use of FTP HTTPS secure protocol is an optimal solution - high level of security and non-significantly lower speed.

***Key words**: file transfer protocol, safety, network, transfer speed*

[1] Bacc. inf., Police technician for EOP equipment maintenance, Ministry of the Interior of the Republic of Croatia, Police Directorate Primorsko-Goranska, Ulica žrtava fašizma 3, Rijeka, Croatia. E-mail: silvano.culinovic@gmail.com
[2] MSc, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: mkaluza@veleri.hr
[3] Assistant, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: dliveric@veleri.hr
[4] Received: 16. 2. 2014.; accepted: 5. 5. 2014.

Ivana Bujan[1]
Marija Vugrinec[2]

Stručni rad
UDK 658.14:334.012.63/.64 (497.5)

SPECIFIČNOSTI FINANCIRANJA SME SEKTORA U HRVATSKOJ U ODNOSU NA ZEMLJE EUROPSKE UNIJE[3]

SAŽETAK

U ovome radu prikazani su načini klasifikacije SME sektora u Hrvatskoj u odnosu na zemlje Europske unije. Cilj istraživanja bio je utvrditi klasifikaciju SME sektora u Hrvatskoj u odnosu na zemlje EU-a. Kvalitativnim znanstvenim metodama indukcije i dedukcije utvrđeno je da se udio SME sektora u Hrvatskoj ne razlikuje od zemalja Europske unije. Tipični kriteriji klasifikacije kod većine zemalja su broj zaposlenih, veličina prihoda i aktive. Pregledom literature, a osobito istraživanja koja su provela državna tijela zadužena za SME sektor, utvrđeni su udjeli SME sektora u ukupnom gospodarstvu Hrvatske te je potom izvršena usporedba sa zemljama Europske unije. I u ovome dijelu istraživanja vidljivo je da se Hrvatska uklapa u europski prosjek. Na razini Europske unije udio SME sektora veći je od 90 %, a Hrvatska se s gotovo 98 % uklapa u navedeni prosjek. U radu se dolazi do specifičnog cilja, a to je utvrđivanje tipičnih izvora financiranja SME sektora. Temeljem cilja istraživanja postavljena je i hipoteza da se tipični izvori financiranja SME sektora u Hrvatskoj ne razlikuju od Europske unije. Hipoteza je dokazana metodama indukcije i dedukcije sekundardnih podataka. U posljednjem dijelu rada navode se rezultati istraživanja i specifični načini financiranja. Uz tipične oblike financiranja kao što su bankarski krediti i ostali zajmovi navode se i financijske potpore koje su odobrili fondovi Europske unije.

Ključne riječi: *SME sektor, financiranje, bankarski krediti, mjere potpore*

1. UVOD

U ovome radu prikazane su specifičnosti financiranja SME sektora, tj. sektora srednjih i malih poduzeća u Republici Hrvatskoj. Kratica SME definirana je u službenom glasniku Europske unije iz 2003. godine (EU SMEs in 2012: at the crossroads, 2012) te se koristi nadalje kao takva i u ovom radu. Na početku rada, analizom Hrvatskog zakonskog okvira utvrđeno je na koji način se razvrstavaju gospodarski subjeki te je izvršena komparacija s nekim drugim pravnim sustavima i načinima na koji oni klasificiraju gospodarske subjekte. Prema istraživanjima SME sektor čini više od 90 % udjela u ukupnom broju poduzeća u Hrvatskoj (Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2012), a niti u drugim državama nije znatno drugačija situacija (Deželjin et al., 2002). Primjerice

[1] Univ. spec. philol., predavač, Međimursko veleučilište u Čakovcu, B. J. Jelačića 22a, Čakovec, Hrvatska. *E-mail:* ibujan@mev.hr

[2] Bacc. oec., student.

[3] Datum primitka rada: 29. 12. 2013.; datum prihvaćanja rada: 5. 5. 2014.

u Austriji, trend podupiranja SME sektora izuzetno je razvijen i ima dugu tradiciju (Škrtić, Mikić, 2011). U radu je izvršena usporedba SME sektora Hrvatske u odnosu na SME sektor Europske unije.

Kako je glavni cilj rada utvrđivanje tipičnih izvora financiranja SME sektora u Hrvatskoj i Europskoj uniji, postavljena je hipoteza da se tipični izvori financiranja SME sektora u Hrvatskoj ne razlikuju značajno od tipičnih izvora financiranja SME sektora u Europskoj uniji. Znanstvene metode korištene u ovome radu kako bi se dokazala hipoteza su metode indukcije i dedukcije sekundarnih izvora podataka. Polje interesa dokazivanja hipoteza u ovome radu ogleda se u dokazivanju važnosti SME sektora u zemljama Europske unije, ali isto tako i utvrđivanju stanja za Hrvatsku. U 2013. godini u Hrvatskoj su bili raspisani mnogi natječaji, ali i otvoreni programi poticanja poduzetništva u sklopu Ministarstva poduzetništva i obrta, poticanja SME sektora preko mjera Hrvatskog zavoda za zapošljavanje. Za Europsku uniju 2011. i 2012. bile su izuzetno zahtjevne godine upravo zbog ekonomskih uvjeta - dužničke krize, recesije s dvostrukim dnom za neke zemlje unutar Unije i slabog rasta čak i u razvijenijim dijelovima. SME sektor Europske unije usprkos krizi uspio je zadržati svoju čvrstu ulogu, a kada govorimo o brojevima, udio SME sektora u ukupnoj ekonomiji je 20,7 milijuna, tj. 98 % poduzeća s manje od 10 zaposlenika (*EU SMEs in 2012: at the crossroads, 2012)*. Iz navedenih razloga istraživanja i analize financijskog stanja SME sektora nisu važna samo u znanstvenim i stručnim radovima nego su i od izuzetnog interesa za proučavanja od strane državnih tijela, financijskih institucija, udruženja itd. Europska unija posljednjih godina potiče mnoge programe razvoja poduzetništva te su ti programi upravo usmjereni na SME sektor. Nadalje će u radu biti spomenuti neki specifični programi financiranja.

Nakon uvodnog dijela i obrade kriterija za definiranje SME sektora prikazani su načini financiranja SME sektora, što je i opći cilj ovoga rada. Prikazana je problematika financiranja SME sektora u Hrvatskoj, a istraživačkom metodom dedukcije utvrđena je ponuda kreditnih oblika financiranja za SME sektor. Kako je hrvatski financijski sustav bankocentrično orijentiran (Škrtić, Mikić, 2011), najčešći oblik financiranja koji se koristi su bankarski krediti. Istraživanje koje je proveo HUB – Hrvatska udruga banaka 2008. godine o visini financijske poluge, tj. o udjelu kapitala u ukupnoj pasivi, govori da je poluga stabilna kroz čitav period. Što se tiče mikropoduzeća, udio kratkoročnih obveza u ukupnoj pasivi veći je od vlastitog kapitala (HUB analize, 2010). Mala poduzeća su stoga često prezadužena kratkoročnim kreditima koji su im potrebni za održavanje tekuće likvidnosti. Prema navedenom struktura kapitala malih poduzeća razlikuje se od velikih poduzeća. Da kratkoročne obveze prevladavaju u ukupnoj pasivi malih poduzeća definirali su još 1997. godine u svom istraživanju Cressy i Olofsson (Cressy, Olofsson, 1997). Razlozi zašto SME sektor ima otežan pristup financiranju, kao što je slučaj i u Hrvatskoj, navode razni autori u svojim istraživanjima. Berger i Udell 1995. godine u svojim su istraživanjima došli do podatka da su mala poduzeća zbog nedostatka kolaterala osuđena na kratkoročne kredite manjih vrijednosti, kada plaćaju veću kamatu (Berger, Udell, 1995). Peel i Wilson su 1996. godine u svojem radu utvrdili da problem pristupu financiranja leži u asimetričnim informacijama između novih i malih poduzeća u odnosu na načine financiranja (Peel, Wilson, 1996). Navedene studije su napravljene za zapadne zemlje, ali se navedeni podaci ne razlikuju od Hrvatske.

2. KOMPARACIJA KRITERIJA ZA DEFINIRANJE SEKTORA MALIH I SREDNJIH PODUZEĆA U RH I EU

Zakon o računovodstvu i Zakon o poticanju razvoja malog gospodarstva definiraju kriterije za razvrstavanje na mala i srednja poduzeća u Hrvatskoj. Mali poduzetnici su oni koji ne prelaze dva od sljedećih uvjeta: ukupna aktiva 32.500.000 kuna, prihod 65.000.000 kuna te prosječan broj radnika tijekom poslovne godine 50. Srednji poduzetnici su oni koji prelaze barem dva od tri uvjeta za male poduzetnike, ali ne prelaze dva od sljedećih uvjeta: ukupna aktiva 130.000.000 kuna, prihod 260.000.000 kuna te prosječan broj radnika tijekom poslovne godine 250. Veliki poduzetnici su oni koji prelaze dva uvjeta iz definicije srednjih poduzetnika (Zakon o računovodstvu, 2007).

Zakon o poticanju razvoja malog gospodarstva s obzirom na veličinu razlikuje mikrosubjekte, male subjekte te srednje subjekte. Mikrosubjekti su pravne i fizičke osobe koje prosječno godišnje imaju manje od 10 zaposlenika i ostvaruju ukupni godišnji prihod u protuvrijednosti do 2.000.000 eura, odnosno imaju vrijednost dugotrajne imovine u protuvrijednosti do istog iznosa. Mali subjekti su pravne i fizičke osobe koje prosječno godišnje imaju manje od 50 zaposlenika i ostvaruju ukupni godišnji prihod u protuvrijednosti do 10,000.000 eura (ili imaju zbroj bilance ako su obveznici poreza na dobit), odnosno imaju dugotrajnu imovinu ako su obveznici poreza na dohodak, u protuvrijednosti do istog iznosa. Srednji subjekti su fizičke i pravne osobe koje prosječno godišnje imaju više od 50, ali manje od 250 zaposlenika te ostvaruju ukupni godišnji prihod u protuvrijednosti od 10.000.000 eura do 50.000.000 eura (ili imaju zbroj bilance ako su obveznici poreza na dobit), odnosno imaju dugotrajnu imovinu ako su obveznici poreza na dohodak, u protuvrijednosti od 10.000.000 eura do 43.000.000 eura.

U Zakonu o poticanju razvoja malog gospodarstva izmjenama i dopunama usklađena je kategorizacija veličine poduzetnika s kriterijima koje primjenjuje Europska unija, a time je omogućena kvalitetnija analiza i usporedba sektora malih i srednjih poduzeća u Hrvatskoj i zemljama EU-a, te bolje iskorištavanje mehanizama potpora namijenjenih malim i srednjim poduzećima kroz programe EU-a (Zakon o poticanju razvoja malog gospodarstva). Uobičajeni naziv sektora malog i srednjeg poduzeća je na svjetskoj razini SME sektor – *Small and Medium-Sized Entreprises.* Navedeni naziv naveden je i u Preporuci Komisije od 6. 5. 2003. godine (Preporuka Komisije od 6. 5. 2003. o definiranju mikro, malih i srednjih poduzeća, 2003).

Kriteriji za razvrstavanje subjekata malog i srednjeg gospodarstva dani su u tablici 1. Navedeni kriteriji – broj zaposlenika, godišnji prihod i imovina, brojčano su prikazani te se odnose na EU i Hrvatsku. Iz tablice 1 vidljivo je da se kriteriji klasifikacije između Hrvatske i Europske unije podudaraju.

Tablica 1. Kriteriji razvrstavanja subjekata malog i srednjeg gospodarstva

	Broj zaposlenika	**Godišnji prihod (u milijunima eura)**	**Imovina (u milijunima eura)**
	EU / RH	**EU / RH**	**EU / RH**
Mikro	0 – 9	2	2
Mali	10 – 49	10	10
Srednji	50 – 249	50	43

Izvor: Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2012., str. 12.

Nadalje u tablici 2 dan je prikaz udjela SME sektora u ukupnom gospodarstvu Hrvatske. Na temelju predstavljenih podataka hrvatskim gospodarstvom dominira SME sektor s 99,6 % udjela u ukupnom gospodarstvu 2011. godine, a promatrajući prethodne godine, počevši od 2001. godine, vidljivo je da se postotak povećavao. Iz navedenoga bi se svakako moglo zaključiti da je hrvatsko gospodarstvo mikro gospodarstvo. Također, u SME sektoru zaposleno je 34,4 % osoba (Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2012). Ako se promotri broj malih poduzeća, vidljivo je također da se njihov udio znatno povećao, točnije povećao se za 75,24 % 2010. godine u odnosu na 2001. godinu. Ipak promjena u broju poduzeća 2011. godine u odnosu na 2010. godinu je negativna, pa vidimo pad broja poduzeća od 5,76 %. S druge strane broj srednjih poduzeća od 2001. godine do 2010. godine ne bilježi tako velike promjene kao kod malih poduzeća. Broj srednjih poduzeća se od 2001. godine do 2010. godine povećao za 59,75 % što je također prilično velik broj, uz napomenu da se ovdje radi o značajno manjem broju poduzeća u odnosu na mala poduzeća – 2.203 u odnosu na 54.213.

Tablica 2. Udio SME sektora u gospodarstvu Hrvatske

	2001.		2010.		2011.	
	Broj subjekata	%	Broj subjekata	%	Broj subjekata	%
SME sektor	56 416	99	96 383	99.5	90 831	99.6
Mala poduzeća	54 213		95 004		89 539	
Srednja poduzeća	2 203		1 379		1 292	
Valika poduzeća	571	1	375	0.5	359	0.4
Ukupno	56 987	100	96 758	100	91 190	100

Izvor: HGK, Centar za poduzetništvo, inovacije i tehnološki razvoj, 2012.

Navedene podatke zanimljivo je usporediti sa stanjem SME sektora u Europskoj uniji. Tijekom 2011. i 2012. godine SME sektor u EU-u zadržao je stabilan položaj, gdje SME poduzeća čine 20,7 milijuna poduzeća ili 98 % udjela u ukupnim poduzećim, gdje je 92,2 % poduzeća u ukupnoj strukturi s manje od 10 zaposlenih. Procjenjuje se da je 2012. godine SME sektor zapošljavao više od 67 % osoba u ukupnoj zaposlenosti (EU SMEs in 2012: at the crossroads, Godišnji izvještaj o malim i srednjim poduzećima u EU, 2011/12).

Tablica 3. Udio SME sektora u gospodarstvu u EU-u u 2012. godini

	Mikro	Mala	Srednja	SME ukupno	Velika	Ukupno
Broj poduzeća						
Broj	19 143 521	1 357 533	226 573	20 727 627	43 654	20 771 281
%	92,2	6,50	1,10	99,8	0,2	100
Zapošljavanje						
Broj	38 395 819	26 771 287	22 310 205	87 477 311	42 318 854	129 796 165
%	29,6	20,6	17,2	67,4	32,6	100

Izvor: EU SMEs in 2012: at the crossroads, Godišnji izvještaj o malim i srednjim poduzećima u EU, 2011/12., str. 17

Ako se usporede podaci za EU s Hrvatskom, vidljivo je da se Hrvatska uklapa u podatke EU-a vezano uz broj malih i srednjih poduzeća i udjelom u ukupnoj strukturi. U Hrvatskoj je ukupni udio SME sektora 99,6 % u 2011. godini, a u EU-u 99.8 % 2012. godine. Prema nekim autorima, udio SME sektora u istočnim zemljama manji je u odnosu na zapadne zemlje (Klapper et al., 2002).

3. REZULTATI ISTRAŽIVANJA

U teoriji financiranja, izvore financiranja moguće je odrediti prema roku dospijeća i s obzirom na izvore (Vidučić, 2011). Tako postoje trajni, dugoročni, srednjoročni i kratkoročni izvori financiranja s obzirom na rok, a s obzirom na izvore financiranja postoji unutarnje i vanjsko financiranje. Neki od unutarnjih načina financiranja su uplate vlasnika, amortizacija, akumulirana dobit, naplata glavnice dugoročnih plasmana. S druge strane, vanjski načini financiranja su krediti, izdavanje obveznica, faktoring, lizing i financijska sredstva odobrena na temelju raznih projekata, bilo raznih ministarstva u Hrvatskoj ili projekata EU-a.

Najzastupljeniji oblik financiranja SME sektora su bankarski krediti, jer su neki oblici financiranja, kao što su izdavanje obveznica, dionica zakonski nedostupni. Osnovne izvore financijske podrške razvoja malih i srednjih poduzeća u Hrvatskoj čine: bankarski sektor, kreditne unije, fondovi rizičnog kapitala, neformalni oblici financiranja (poslovni anđeli) i Vladini programi poticaja i subvencioniranih kreditnih linija (Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2012). Prema CEPORU mala i srednja poduzeća su značajnije usmjerena na tradicionalne izvore financiranja (bankarske kredite). Slabija usmjerenost na netradicionalne izvore financiranja (fondovi rizičnog kapitala i poslovni anđeli) povezana je i s ograničenosti ponude takvih izvora na hrvatskom financijskom tržištu.

Za neke oblike financiranja mali poduzetnici ne posjeduju dovoljno znanja, niti su upućeni u mogućnost financiranja. Prema rezultatima istraživanja GEM Hrvatska 2002. – 2011. utvrđeno je da je pristup financijskim sredstvima vrlo ograničen, a slab interes može se pripisati i slabom ponudom samih fondova rizičnog kapitala i poslovnih anđela (Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2012). Mala i srednja poduzeća koja se nalaze u Hrvatskoj obično koriste unutarnje izvore financiranja (kroz uplate od strane vlasnika kapitala) (Škrtić, Mikić, 2011). Bankarski krediti su najzastupljeniji vanjski izvor financiranja (Škrtić, Mikić, 2011), no zastupljeni su također i neki drugi vanjski oblici financiranja, kao što su lizing ili faktoring. Da se Hrvatska ne razlikuje u načinu financiranja od Eurozone pokazuje i istraživanje Europske središnje banke, u kome je vidljivo da su izvori financiranja SME sektora unutarnji izvori, bankarski krediti, kreditne linije, lizing i faktoring (Europska središnja banka, 2012.-2013.)

Osim institucija na Europskoj razini financiranjem SME sektora bave se razni autori u svojim empirijskim istraživanjima. U svojem članku Helmut Kraemer-Eis i Frank Lang (2012) navode problem teške dostupnosti financijskim sredstvima malih poduzeća koji se podudara i s ostalim istraživanjima autora navedenima u ovome članku te se osvrće na ulogu lizinga u financiranju SME sektora (Kraemer-Eis, Lang, 2012). Prema navedenim autorima, lizing predstavlja važan vanjski izvor financiranja. Prema istraživanju Oxford Economics a koje je obuhvatilo zemlje članice EU-a iz 2010. lizing je bio najpopularniji oblik

financiranja za 40 % anketiranih SME poduzeća. Prema istom istraživanju drugi najveći izvor financiranja bio je bankarski kredit.

Navedeni podaci korespondiraju i sa situacijom u Hrvatskoj. Lizing je najatraktivniji financijski instrument u Hrvatskoj dostupan malim i srednjim poduzećima kada govorimo o financiranju prijevoznih sredstava te se osim prijevoznih sredstava odobrava za strojeve, plovila i sl., dok najveći dio odobrenih lizinga opada na osobne automobile. Kod lizinga su početni troškovi i mjesečna plaćanja niski. On omogućuje srednjoročno i dugoročno financiranje. Faktoring je posao kratkoročnog financiranja izvoznog ili uvoznog posla preko faktora kao posebne organizacije (Vidučić, 2011). U pravilu se otkupljuju kratkoročna potraživanja s rokom dospijeća do 180 dana. Najveća je prednost faktoringa poboljšanje likvidnosti jer se na taj način brzo dolazi do novca. Dolazi do uravnoteženja odnosa između kratkoročnih potraživanja i kratkoročnih obveza te povećanja kreditne sposobnosti i boniteta. Rizik je smanjen te postoji mogućnost ekspanzije poslovanja, povećanja prodaje i veće konkurentnosti. Neki autori navode da u Hrvatskoj faktoring postaje sve prihvatljiviji i učestaliji način financiranja (Pešić, 2011). Tablica 4 prikazuje ponude bankovnih kredita za SME sektor. U ovome radu analizom ponude hrvatskog bankarskog sektora dobivena je ponuda kredita najvećih banaka u Hrvatskoj.

Tablica 4. Uvjeti financiranja malih i srednjih poduzeća prema ponudi kredita najvećih banaka u Hrvatskoj

Ime banke	Program	Iznos	Godišnja kamatna stopa (%)	Trajanje	Namjena kredita
Zagrebačka banka	Kratkoročni kredit za poslovno financiranje namijenjen poduzetnicima	najmanje 5.000 eura do 250.000 eura u kunskoj protuvrijednosti	Promjenjiva sukladno odluci banke	do 12 mjeseci	- financiranje sezonskih poslova - financiranje ugovorenih poslova za isporuku robe i/ili usluga - financiranje ulaganja u poljoprivredu
	Program početnik dugoročni kredit poduzetnicima u odabranim profesijama	ovisno o kreditnoj sposobnosti korisnika kredita	Promjenjiva sukladno odluci banke	do 25 godina	- kupnja zemljišta i uređenje infrastrukture - nabava opreme ili pojedinih dijelova opreme - nabava prijevoznih sredstava, osobnih vozila, informatičke i telekomunikacijske opreme

Privredna banka Zagreb	Krediti za poticanje razvitka malog i srednjeg privatnog poduzetništva	do 75 % vrijednosti investicije, najviši iznos kredita može biti 8,000.000 kn po projektu	godišnja fiksna, 2 %, 4 %, 4 % , 6 % (ovisno o kategoriji klijenta)	do 10 godina uključujući poček do 2 godine	za ulaganja u osnovna sredstva (kupnja građevinskog zemljišta, pogonskih zgrada i poslovnog prostora, troškovi gradnje, kupnja strojeva, opreme, vozila, osnovnog stada i dugogodišnji nasadi)
Hypo Alpe Adria	Krediti za financiranje investicijskih projekata, trajnih obrtnih sredstava, proizvodnje, opreme i investicijskih radova u zemlji i inozemstvu	do 70 % ukupne vrijednosti investicije	ovisno o anuitetima/ ratama	do 10 godina, a iznimno i 15 godina	- za izgradnju poslovnog objekta - za moderniziranje poslovanje - za financiranje izvođenja investicijskih radova na duži rok
Erste Steiermarkische Bank	Investicijski krediti	ovisi o visini investicije i vlastitog učešća	-	do 10 godina	- namijenjeni su za srednjoročno i dugoročno financiranje investicijskih projekata/ programa u cilju kreiranja, modernizacije

Izvor: mrežne stranice banaka – Zagrebačka banka d. d., Privredna banka d. d., Erste Steiermarkische Bank d. d. i Hypo Alpe Adria Bank d.d., 10. 7. 2013.

Iz tablice 4 vidljivo je da su u ponudi za SME sektor krediti koji su namijenjeni poduzetnicima početnicima, ali i investicijski krediti. Prema ovome istraživanju krediti za SME sektor namijenjeni su investicijama, modernizaciji poslovanja, ulaganju u osnovna sredstva te financiranju ugovorenih poslova.

4. POSEBNI INSTRUMENTI POTPORE NAMIJENJENI SME SEKTORU

Osim klasičnih vanjskih i unutarnjih oblika financiranja postoji i mogućnost financiranja preko projekata uz potpore. Europska komisija (Glavna uprava za regionalnu politiku) je u suradnji sa skupinom Europske investicijske banke i ostalim financijskim institucijama unutar programskog razdoblja 2007. – 2013. godine razvila četiri zajedničke inicijative kako bi kohezijska politika bila učinkovitija i održivija. Svrha dviju inicijativa promicanje je instrumenata financijskog inženjeringa (JEREMIE i JESSICA), a ostale dvije (JASPERS i JASMINE) služe kao instrumenti tehničke pomoći. JEREMIE je inicijativa Europske komisije koju je razvila zajedno s Europskim investicijskim fondom. To je inicijativa koja se razvila unutar programskog razdoblja 2007. - 2013. godine zajedno s još četiri. Potiče uporabu instrumenata financijskog inženjeringa kako bi se malim i srednjim poduzetnicima

olakšao pristup financiranju intervencijama strukturnih fondova. Države koje su članice EU-a mogu koristiti dio sredstava iz europskih strukturnih fondova koji je njima dodijeljen za ulaganje u obnovljive instrumente, poput fondova poduzetničkog kapitala te jamstvenih i kreditnih fondova (http://ec.europa.eu). Ta sredstva iz europskih strukturnih fondova namijenjena su modernizaciji tehnologije proizvodnih struktura kako bi se postigla gospodarstva s niskim emisijama ugljika, zaštiti i stvaranju održivih radnih mjesta pomoću ulaganja u proizvodnju, stvaranju i širenju postojećih poduzeća. Namijenjena su i pristupu poduzeća ulagačkom kapitalu (da bi modernizirali svoje djelatnosti, razvili nove proizvode, proširili i osigurali pristup tržištu) te inovacijama, prijenosu tehnologija, poslovno usmjerenom istraživanju i razvoju te poduzetništvu.

Prednosti inicijative JEREMIE su (http://ec.europa.eu):

- održivost - instrumenti financijskog inženjeringa temelje se na pružanju povratne pomoći za ulaganja iz strukturnih fondova čime se ostvaruju prinosi i isplaćuju ulagači; time se nudi održivija alternativa pomoći koja se obično pruža u obliku nepovratnih sredstava
- financijska poluga – kombinacijom strukturnih fondova i dodatnih izvora ulaganja povećat će se sredstva te će se većem broju poduzeća pružiti potpora
- fleksibilnost – inicijativom JEREMIE nudi se fleksibilnost strukture i uporabe sredstava koja se mogu dodijeliti za ulaganja u obliku vlasničkog kapitala, zajmova ili jamstva koja se mogu prilagoditi specifičnim potrebama određenih zemalja i regija
- stručno znanje – inicijativom JEREMIE omogućuje se tijelima koja upravljaju strukturnim fondovima da iskoriste stručno znanje bankarskog i privatnog sektora i time povećaju učinkovitost svojih ulaganja u poduzeća
- partnerstva – partnerstvo Komisije, Europskog investicijskog fonda i Europske investicijske banke u okviru inicijative JEREMIE može biti i snažan katalizator za suradnju među zemljama, regijama, Europskog investicijskog fonda, Europske investicijske banke, ostalim bankama i ulagačima kako bi poduzeća, u prvom redu mali i srednji poduzetnici, dobila pristup financiranju.

Doprinosi iz Europskog fonda za regionalni razvoj (EFRR) dodjeljuju se fondovima poduzetničkog kapitala za ulaganja u poduzeća te jamstvenim i kreditnim fondovima. Ta ulaganja mogu biti zajmovi, jamstva ili vlasnički kapital. Prinosi od ulaganja opet se ulažu u poduzeća. Skup sredstava može se nekoliko puta koristiti na taj način – povećava se kapital, javna sredstva se recikliraju te se povećava njihov učinak i održivost. Mjere poticaja navedene u ovome dijelu rada još nisu bile otvorene za Hrvatsku pa se stoga stupanj uporabe još ne može ocijeniti. Ulaskom Hrvatske u Europsku uniju otvorit će se mogućnost sudjelovanja u fondovima, no potrebno je određeno vrijeme zbog edukacije poduzetnika i pripreme državnih institucija za provođenje takvih programa. Dosadašnje mjere poticaja koje koristi SME sektor u Hrvatskoj su programi poticanja malog i srednjeg poduzetništva koje provodi Ministarstvo poduzetništva i obrta.

5. ZAKLJUČAK

Uspoređivanje raznih načina klasifikacije SME sektora u Hrvatskoj, ali i ostalim zemljama dovodi do zaključka su kriteriji za klasifikaciju uglavnom slični. Osnovni kriteriji su broj zaposlenih, veličina prihoda ili prometa, te veličina imovine koju poduzeće posjeduje. Nakon uvodnog dijela rada naglasak je stavljen na specifične i tipične načine financiranja SME sektora kao i udio SME sektora u gospodarstvima različitih zemalja. U Hrvatskoj prednjače mikropoduzeća koja imaju manje od 10 zaposlenih te je udio SME sektora veći od 90 %, jednako kao i kod zemalja Europske unije. U privredama tih zemalja je SME sektor također nositelj gospodarskih aktivnosti. Što se tiče načina i specifičnosti financiranja, i u Hrvatskoj i u drugim zemljama (EU), tipični načini financiranja su kreditiranje iz uglavnom kratkoročnih kredita. Prema izvješću o malim i srednjim poduzećima u Hrvatskoj (Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2012), najčešći oblik zaduživanja SME sektora su bankarski krediti, a navodi se i problematika loše zastupljenosti nekih alternativnih načina financiranja kao što su rizični fondovi i poslovni anđeli. U Hrvatskoj postoji jedno udruženje poslovnih anđela, CRANE, a u Europskoj uniji postoje 392 udruge poslovnih anđela, a njihova aktivnost je puno jača i intenzivnija ako se usporedi s Hrvatskom. Prema podacima Europskog investicijskog fonda, Izvješća o financijskom stanju SME sektora za 2012., u Europskoj uniji poslovni anđeli godišnje ulože oko 4 milijarde eura (*EU SMEs in 2012: at the crossroads*, 2012). Prema navedenome, financijska aktivnost SME sektora puno je intenzivnija u Europskoj uniji u odnosu na Hrvatsku. U radu je također izvršena analiza dostupnih bankarskih kredita na tržištu Republike Hrvatske. Na temelju analize je vidljivo da je dio kredita namijenjen održavanju tekućeg poslovanja, a drugi dio za održavanje poslovanja i ulaganje u nove pogone, kupnju prijevoznih sredstava, kupnju strojeva za rad.

Osim klasičnih načina financiranja, u radu su obuhvaćeni i specifični načini financiranja raznim potporama i odobravanjem sredstava kroz fondove. Kao specifični načini financiranja spomenute su mjere koje provodi Europska unija – JEREMIE i JESSICA. Financijska sredstva su dio europskih strukturnih fondova, a namijenjena su modernizaciji tehnologije proizvodnih struktura, kako bi se postigla gospodarstva s niskim emisijama ugljika, zaštiti i stvaranju održivih radnih mjesta pomoću ulaganja u proizvodnju, stvaranju i širenju postojećih poduzeća, dakle nastoji se uspostaviti ekološka i društvena održivost. Uslijed velikih problema likvidnosti SME sektora u Hrvatskoj poduzeća će se morati okrenuti na ove subvencionirane načine financiranja. Tu se vidi potreba dodatne edukacije poduzetnika za prijavu projekata i sastavljanje projektne dokumentacije, ali i provođenje projekata na temelju kojih će tražiti financijska sredstva iz navedenih fondova.

Može se ukazati na potrebu za provedbom daljnjeg istraživanja radi bolje obrade problematike izložene u ovom radu, kako bi se istražilo koji su najveći problemi povezani s likvidnošću poduzetnika u SME sektoru te s kojim su poteškoćama suočeni poduzetnici u SME sektoru kroz vremenski period od 2008. godine pa do nekog tekućeg razdoblja u kojem će se provoditi istraživanje.

LITERATURA

Deželjin J. et al. (2002) *Poduzetnički menadžment – Izazov, rizik, zadovoljstvo*, Zagreb: 2. izd., M.E.P. Consult

Škrtić, M. (2008) *Osnove poduzetništva i menadžmenta*, Karlovac: 2. izd., Veleučilište u Karlovcu

Škrtić, M, Mikić, M. (2011) *Poduzetništvo*, Zagreb: Sinergija

Vidučić, Lj. (2011) *Financijski menadžment*, Zagreb: VII. izdanje, RRIF Plus

Berger, A., Udell, G. (1995) *Relationship Lending and Lines of Credit in Small Firm Finance*, Journal of Business, str. 351-381

Cressy, R, Olfsson, C. (1997) *European SME financing: An Overview, Small Business Economics* 9, str. 87 - 96.

EU SMEs in 2012: at the crossroads, Godišnji izvještaj o malih i srednjim poduzećima u EU, 2011/12., Europska komisija, Ecorys, Rotterdam, 2012.

HUB analize, Hrvatska udruga banaka, broj 22., Zagreb, 2010.

Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2012., CEPOR – Centar za politiku razvoja malih i srednjih poduzeća i poduzetništva, ISSN 1848-3526, Zagreb, 2012.

Klapper, L. F., Sarria-Allende, V., Sulla, V. (2002) *Small-and Medium-size Entreprise financing in Eastern Europe*, The World Bank, Development Research Group

Kraemer-Eis, H., Lang, F. (2012) *The importance of leasing for SME sector*, European Investment Fund, Research and Market Analysis, Working Paper 2012/15 EIR, 2012

Peel, M.J., Wilson, N. (1996) *Working Capital and financial Management Practices in the Small Firms Sector*, International Small Business Journal, Vol. 14(2), July-March, str. 52-68.

Preporuka Komisije od 6. 5. 2003. o definiranju mikro, malih i srednjih poduzeća, Službeni glasnik Europske unije, br. L 124/36

Pešić, M. (2011) *Financiranje malog i srednjeg poduzetništva u Hrvatskoj*, Osijek: Ekonomski vjesnik, br. 2

http://ec.europa.eu/regional_policy/thefunds/instruments/jeremie_hr.cfm (15. 7. 2013.)

Zakon o računovodstvu, Razvrstavanje poduzetnika (Članak 3.), Klasa: 401-01/07-01/01, Zagreb, 5. 10. 2007.

Zakon o poticanju razvoja malog gospodarstva, NN 29/02, NN 56/13

Ivana Bujan [1]
Marija Vugrinec [2]

Professional paper
UDC 658.14:334.012.63/.64 (497.5)

SPECIFIC FEATURES OF SME FINANCING IN CROATIA COMPARED TO THE EUROPEAN COUNTRIES[3]

ABSTRACT

This paper analyzes the classification of the SME sector in Croatia compared to other EU countries. The main goal of this research was to define the SME classification in Croatia compared to other EU countries. The usual classification criteria are the number of employees, annual revenue and assets. On the basis of criteria analysis, similarities and differences in defining SMEs have been determined. Based on literature review, mainly research analyses conducted by public authorities in specific countries in charge of the SME sector, the SME share in the whole Croatian economy has been determined. The EU share of SME is more than 90%, and Croatia with the share of almost 98% definitely follows the trend. According to the main goal of this paper, the hypothesis has been put forward stating that typical financing types of the SME sector in Croatia do not significantly differ from the EU's ones. The hypothesis has been confirmed with scientific descriptive methods of induction and deduction on the basis of secondary data. The last part of the paper deals with the research result and outlines specific financing types. Along with typical financing types such as bank loans and other types of loans, some special financial aid programs financed by the EU have also been mentioned.

***Key words**: SME sector, financing, bank loans, grants*

[1] Univ. spec. philol., Lecturer, Polytecnic of Međimurje in Čakovec, B. J. Jelačića 22a, Čakovec, Croatia.
E-mail: ibujan@mev.hr
[2] Bacc. oec., Student.
[3] Received: 29. 12. 2013.; accepted: 5. 5. 2014.

Davor Širola[1]
Valentina Iskra[2]

Stručni rad
UDK 338.246.027:334.012.63/.64(4-67EU)

ANALIZA SUSTAVA POTICANJA PODUZETNIŠTVA NA EUROPSKOJ, HRVATSKOJ I LOKALNOJ RAZINI[3]

SAŽETAK

Razvoj malog i srednjeg poduzetništva jedno je od najvažnijih strateških opredjeljenja Europske unije; pretočeno je u jasne ciljeve krovnih, a posebno sektorskih strateških dokumenata. Hrvatska kao najmlađa članica Europske unije strukturom malih i srednjih poduzeća gotovo u potpunosti slijedi prosjek ostalih 27 članica, a time slijeđenje sustava poticanja poduzetništva Europske unije postaje imperativ za Hrvatsku. Upravo aktualna pozicija hrvatskog sustava poticanja poduzetništva u odnosu na ostale članice Europske unije predstavlja predmet istraživanja ovog rada. Rezultati istraživanja upućuju da je Hrvatska ugradila većinu prioriteta i ciljeva iz krovnih dokumenata na nacionalnoj, no znatno manje na lokalnoj razini (u gradu Rijeci). U pogledu sektorskih ciljeva Hrvatska je dosad usvojila jednu trećinu preporuka Europske unije, a u području praćenja učinkovitosti mjera poticanja poduzetništva sustav europskih pokazatelja nedavno je implementiran na nacionalnoj, ali ne i na lokalnoj razini, gdje nedostaju pretpostavke za formiranje lokalnih baza podataka koje će osigurati nadzor trošenja javnih sredstava gradova i općina, te državnih potpora koje se lokalno distribuiraju.

Ključne riječi: *malo i srednje poduzetništvo, poticanje poduzetništva, pokazatelji učinkovitosti*

1. UVOD

Mala i srednja poduzeća (u daljnjem tekstu: MSP[4]), predstavljaju okosnicu ekonomije Europske unije (u daljnjem tekstu: EU). U 2013. godini MSP čine 99,8 % europskih poduzeća i generiraju oko 58 % dodane vrijednosti, zapošljavajući ⅔ radnika (European Commission, 2013 a:7). EU je malom gospodarstvu povjerio ulogu osnovnog izvora inovacija, novog zapošljavanja, pokretača rasta, nositelja strukturnih promjena i napretka (Švaljek et al., 2007:71). Na pritiske ekonomske krize Europska unija je reagirala i kroz reviziju strateških dokumenata, ponajprije Lisabonske strategije, prema kojoj je EU do 2010. godine trebao postati najkonkurentnije i najdinamičnije gospodarstvo svijeta (European Commission, 2000:11). Revizija je rezultirala strategijom Europa 2020., kojom su postavljeni temelji za budući pametan, održiv i uključiv rast i konkurentnost, a kao jedna od sedam vodećih inicijativa postavljena je (European Commission, 2010 a:3)*:* industrijska politika za globalnu eru s ciljem poboljšanja poslovnog okruženja, posebno za MSP'. Nadalje, Akcijski plan

[1] Mr. oec. spec., predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* davor.sirola@veleri.hr

[2] Stručna prvostupnica ekonomije, studentica, stručni suradnik za podršku razvojnim projektima, Grad Rijeka, Korzo 16, Rijeka, Hrvatska. *E-mail:* valentina.iskra@rijeka.hr

[3] Datum primitka rada: 13. 2. 2014.; datum prihvaćanja rada: 15. 5. 2014.

[4] Definicija MSP-a dostupna na: http://ec.europa.eu/enterprise_policy/sme_definition/index_en.htm

za poduzetništvo 2020. prepoznao je nove i mlade poduzetnike kao ključan element u kreiranju oporavka Europe bogate radnim mjestima te istaknuo da je poduzetništvo moćan poticaj ekonomskog rasta i kreiranja radnih mjesta i poduzeća, otvaranja novih tržišta, koji istovremeno razvija nove vještine i sposobnosti. Akcijski plan za poduzetništvo 2020. osmišljen je kao temeljni plan za zajedničku akciju oslobađanja europskog poduzetničkog potencijala, uklanjanje postojećih prepreka i revoluciju u poduzetničkoj kulturi te definira tri prioritetna područja djelovanja (European Commission 2010 b:3): razvoj poduzetničkog obrazovanja, kreiranje povoljnog poslovnog okruženja, isticanje uzornih poduzetnika i dohvaćanje specifičnih skupina (npr. mladi, žene). Novim strateškim dokumentima EU planira smanjiti poduzetnički jaz koji je i dalje značajno izražen u odnosu na druge vodeće ekonomije svijeta, posebno Sjedinjene Američke Države (u daljnjem tekstu: SAD).

Svrha ovog rada je analizirati modalitete usvajanja sustava pružanja potpora malom i srednjem poduzetništvu koje promovira EU, na nacionalnoj – hrvatskoj i lokalnoj razini u gradu Rijeci. Cilj rada je temeljem rezultata istraživanja utvrditi poziciju koju sustav poticanja poduzetništva na nacionalnoj i lokalnoj razini ima u odnosu na europsku razinu. Ovaj rad je strukturiran tako da nakon uvoda slijedi pregled trendova u malom i srednjem poduzetništvu, te relevantnih istraživanja o ulozi i značaju malih i srednjih poduzeća i poduzetništva (uključujući i hipoteze rada), a zatim prikaz metodologije i rezultata istraživanja, te zaključak.

2. TRENDOVI, ULOGA I ZNAČAJ MALOG I SREDNJEG PODUZETNIŠTVA

2.1 Trendovi sektora malih i srednjih poduzeća u Europskoj uniji, Hrvatskoj i Rijeci

Istraživanje percepcija građana 27 država EU-a i građana SAD-a provedeno 2012. godine pokazalo je da 51 % ispitanika u SAD-u preferira samozapošljavanje, nasuprot samo 37 % građana EU-a, dok je pretkrizne 2007. godine taj odnos bio 61 % u SAD-u prema 45 % u EU-u (European Commission 2007:3 i 2012 a:2). U 2012. godini 54 % hrvatskih građana smatralo je samozapošljavanje poželjnim, no 80 % nije vjerovalo da je ono izvedivo, što upućuje da poduzetnički jaz postoji i u Hrvatskoj (Ministarstvo poduzetništva i obrta 2013 a:2). U nastavku je dat pregled i analiza dijela pokazatelja poduzetničke aktivnosti, strukture zastupljenosti zaposlenih, te udjela u BDP-u, prema veličini poduzeća u EU-u, Hrvatskoj i gradu Rijeci.

Tablica 1. Odabrani pokazatelji poduzetničke aktivnosti za Hrvatsku (RH) i EU-27 (prosjek)

Pokazatelji	**God.**	**RH**	**EU**
Stopa samozapošljavanja (% ukupne zaposlenosti)	2010.	**17**	14
Stopa poduzetništva (% osoba koje su pokrenule ili pokreću poslovanje)	2009.	10	12
Poduzetnička namjera (% osoba s namjerom pokretanja poslovanja u < 3 g.)	2011.	**18**	13
Sklonost samozapošljavanju (% osoba koje bi radije bile samozaposlene)	2009.	43	45
Izvedivost samozapošljavanja (% osoba za koje je izvedivo samozaposliti se)	2009.	21	28
% osoba za koje školsko obrazovanje pomaže razvoju poduzetničkog stava	2009.	**53**	49
% osoba za koje uspješni poduzetnici imaju visok društveni status	2011.	47	69
Zadovoljavajuća pozornost koju mediji pridaju poduzetništvu (u %)	2011.	41	50

Izvor: European Commission 2012 b:4

Iz tablice 1 vidljivo je da Hrvatska zaostaje za prosjekom EU-27 prema svim pokazateljima, izuzev stope samozapošljavanja, postotka osoba s namjerom pokretanja posla u sljedeće tri godine, te

postotka osoba koje smatraju da školsko obrazovanje pomaže u razvoju poduzetničkog stava (u tablici označeni **masnim** brojkama).

Tablica 2. Razina poduzetničke aktivnosti mjerene TEA pokazateljima tijekom recesije

Pokazatelj	Godina	Hrvatska	Najviši rezultat	Prosjek gospodarstava temeljenih na efikasnosti
TEA indeks	2008.	7,59 (rang 26/43)	29,82 Bolivija	Prosjek 11,30 (Peru 25,6)
	2011.	7,32 (rang 37/55)	35,0 Nigerija	Prosjek 13,97 (Kina 24,0)
TEA prilika	2008.	5,43 (rang 27/43)	/	Prosjek 7,38
	2011.	4,61 (rang 42/55)	/	Prosjek 9,71
TEA nužnost	2008.	2,16 (rang 23/43)	/	Prosjek 3,54
	2011.	2,59 (rang 28/55)	/	Prosjek 3,92
TEA prilika / TEA nužnost)	2008.	**2,52** (rang 25/43)	15,05 Island	Prosjek 2,50 (Meksiko 5,77)
	2011.	1,78 (rang 47/55)	20,0 Norveška	Prosjek 3,43 (Barbados 18,54)

Izvor: CEPOR, 2012 a:27-28

Prema rangiranju koje se provodi u sklopu istraživanja Global Entrepreneurship Monitora Hrvatska pripada skupini ekonomski srednje razvijenih država koje svoj razvoj temelje na efikasnosti, no i u toj skupini svi TEA pokazatelji[5] za Hrvatsku ispod su prosjeka skupine, izuzev tzv. 'motivacijskog indeksa', odnosno omjera TEA prilika i TEA nužnosti u 2008. godini (otisnuto **masno** u tablici 2). Zaostatak je još značajniji u odnosu na vodeće države skupine, a posebno u odnosu na sveukupno najbolje države (stupac 'Najviši rezultat' u tablici 2). Pritom prosjek TEA pokazatelja skupine gospodarstava temeljenih na efikasnosti raste u razdoblju recesije (2008. – 2011.), dok istovremeno u Hrvatskoj opada u svim kategorijama.

Oba prikaza (tablica 1 za europsku i tablica 2 za svjetsku razinu), ukazuju da Hrvatska zaostaje u većini pokazatelja poduzetničke aktivnosti.

Grafikon 1. Kretanje zaposlenosti u MSP-u i velikim poduzećima u EU-u tijekom recesije

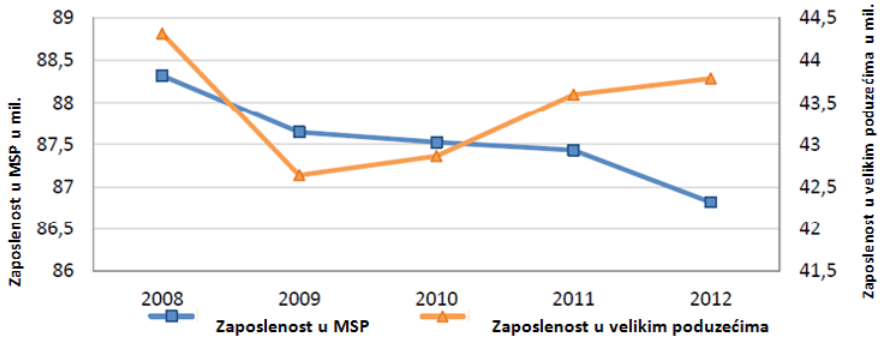

Izvor: European Commission, 2013:18

Iz prikaza kretanja zaposlenosti u EU-u na grafikonu 1 uočava se da je kriza snažnije utjecala na pad zaposlenosti u velikim poduzećima na početku krize (2008. – 2010.), no i

[5] Definicije TEA pokazatelja korištenih u ovom radu dostupne su na: http://www.gemconsortium.com

da se zaposlenost u velikim poduzećima brže oporavlja u odnosu na MSP (2010. – 2012.). Kretanja u pogledu zaposlenosti i udjela u BDP-u u Hrvatskoj u vrijeme ekspanzije (2002. – 2008.) i u vrijeme krize (2008. – 2011.) prikazana su u tablici 3.

Tablica 3. Kretanje strukture veličine poduzeća, udjela zaposlenosti i BDP-a u Hrvatskoj 2002., 2008. (2009.) i 2012. (2011.) godine

Pokazatelji	**Broj zaposlenih**				**BDP (udjel u %)**			
Vrste poduzeća	**2002.**	**2008.**	**2011.**	**11/08**	**2002.**	**2009.**	**2011.**	**11/09**
Ukupno MSP	**387.981**	**416.454**	**344.012**		**47,7**	**53,1**	**50,2**	
Indeks MSP	*100*	*107,3*	*88,7*	*82,6*	*100*	*111,3*	*105,2*	*94,5*
Mikro (0 - 9)	115.138	81.396	68.832		30,4	33,8	31,7	
Mala (10 - 49)	119.388	187.223	150.888					
Srednja (50 - 249)	153.455	147.835	124.292		17,3	19,3	18,5	
Indeks srednja	*100*	*96,3*	*81,0*	*84,1*	*100*	*111,6*	*106,9*	*95,9*
Velika (> 250)	350.382	281.365	244.211		52,3	46,8	49,8	
Indeks velika	*100*	*80,3*	*69,7*	*86,8*	*100*	*89,5*	*95,2*	*106,4*
Zadruge	3.440	2.766	2.272		/	/	/	/
Obrti	221.357	227.550	188.871		/	/	/	/
SVEUKUPNO	**963.160**	**928.135**	**779.366**		**100**	**100**	**100**	**/**
Indeks sveukupno	***100***	***96,4***	***80,9***	***84,0***	**/**	**/**	**/**	**/**
MSP u %	51,4	58,6	57,5	/	/	/	/	/
Zadruge i obrti %	2,1	1,8	1,6	/	/	/	/	/

Napomena: podaci u tablici nisu jednoznačni u svim izvorima zbog različitih metodologija Državnog statističkog zavoda Republike Hrvatske i FINA-e

Izvor: obrada autora prema - ACE International Consultants S. L. i partneri, 2012:7 i 53-54 i 2013:17; CEPOR, 2012 b:13; CEPOR, 2011:14; Singer, Lauc, 2004:2; Hrvatska obrtnička komora, 2012:18; 2009:8 i 15, te 2006:8 i 20

Podaci u tablici 3 ukazuju na rast zaposlenosti u MSP-u (posebno mala poduzeća), te rast udjela BDP-a MSP-a prije krize, u odnosu na pad u oba pokazatelja kod velikih poduzeća. U recesiji sva poduzeća smanjuju broj zaposlenih, no velika poduzeća iskazuju (indeksno) veću otpornost u pogledu pada zaposlenosti, što dijelom prati trend kretanja zaposlenosti u velikim poduzećima u EU-u prikazan na grafikonu 1.

Pored trendova vidljivih iz tablice 3, treba naglasiti i da su državne i lokalne potpore namijenjene razvoju MSP-a u Hrvatskoj u razdoblju od 2002. do 2010. godine iznosile 1,48 % sveukupnih potpora, dok su, primjerice, potpore za brodogradnju i promet/prijevoz (gdje su pretežno zastupljena velika poduzeća), imale udjel od čak 35,3 %, tj. MSP-u daju veći povrat po kuni dodijeljene potpore (ACE International Consultants S. L. i partneri, 2012:67). Istovremeno prosječna dodana vrijednost po zaposleniku u cijelom sektoru MSP-a iznosila je 11.861 eura u 2011. godini (od 9.824 eura u mikro, preko 13.829,5 eura u malim do 12.505. eura u srednjim poduzećima), dok u velikim poduzećima iznosi 17.715 eura. U sektoru MSP-a 10 novih članica Europske unije (iz 2004.) su uspješnije u odnosu na

Hrvatsku i ostvaruju prosječno 15.947 eura, dok 17 'starih' članica ostvaruje čak 50.958 eura dodane vrijednosti po zaposleniku. Prema podacima FINA-e sektor MSP-a u Hrvatskoj čini 44 % ukupnog izvoza za 2012. godinu u usporedbi s 40 % 2010. godine. Prema podacima FINA-e sektor MSP-a čini 44 % ukupnog izvoza za 2012. godinu (40 % u 2010. godini). Pritom mikropoduzeća čine 8 % ukupnog izvoza u Hrvatskoj (u 2012. godini), mala poduzeća 13 %, a srednja 23 % ukupnog hrvatskog izvoza (ACE International Consultants S. L. i partneri, 2013:8-9 i 15). U nastavku tablica 4 prikazuje promjene strukture poduzeća i zaposlenih u Hrvatskoj i EU-u.

Tablica 4. Dinamika kretanja strukture poduzeća u Hrvatskoj i Europi prema veličini i broju zaposlenih od 1990. do 2013.

Godina	1990.				2013.			
Pokazatelji	Udjel broja poduzeća u %		Udjel zaposlenih u %		Udjel broja poduzeća (u %)		Broj zaposlenih (u %)	
Vrste poduzeća po veličini	Hrvatska	Europa-16	Hrvatska	Europa-16	Hrvatska	EU27	Hrvatska	EU27
Mikro (0 - 9)	81,17	96	9,16	56	91,8	92,1	30,7	28,8
Mala (10 - 49)					6,7	6,6	19,2	20,4
Srednja (50 - 249)	13,3	2	30,24	15	1,2	1,1	19,1	17,4
Velika (> 250)	5,53	2	60,59	29	0,3	0,2	31,0	33,4
Sveukupno	100,0	100,0	100,0	100,0	100,0	100,0	100,0	100,0
Ukupno mala i srednja	94,47	98	39,49	71	99,7	99,8	69,0	66,6

Izvor: obrada autora prema - Singer, Lauc, 2004:3-4; European Commission, 1995:41; European Commission, 2013, *Report Croatia i EU27 (2008.-2013.)*

Disproporcije uočljive na tablici 4 u pogledu udjela broja poduzeća i broja zaposlenih u MSP-u između Hrvatske i Europe (16 članica) u 1990. godini, brzo su nestale nakon političkih promjena i prelaska Hrvatske na tržišno gospodarstvo, te se tijekom 1990-ih (već u 1995.) značajno približile strukturi u europskim državama, da bi danas (2013. godine), Hrvatska imala strukturu gotovo identičnu onoj u EU27, kako po udjelu broja poduzeća, tako i broju zaposlenih u pojedinoj kategoriji veličine poduzeća. Pritom treba naglasiti da sektor MSP-a ima različit utjecaj na zapošljavanje po pojedinim djelatnostima i državama EU-a. Tako u djelatnosti rudarstva i vađenja u EU-u sudjeluje s oko 30 %, a u djelatnosti građevinarstva i poslovanja nekretninama s preko 85 %, dok MSP čine od 52,3 % svih zaposlenih u Velikoj Britaniji, do 85,8 % u Grčkoj (European Commission, 2013:12-14). U tablici 5 slijedi analiza kretanja strukture prema veličini poduzeća, broju zaposlenih i veličini ukupnih prihoda u gradu Rijeci.

Tablica 5. Dinamika kretanja strukture poduzeća u gradu Rijeci prema osnovnim poslovnim pokazateljima od 1995. do 2012. godine

Veličina poduzeća	Mala poduzeća			Srednja poduzeća			Velika poduzeća			Ukupno		
Godina	1995.	2012.	12/95	1995.	2012.	12/95	1995.	2012.	12/95	1995.	2012.	12/95
Broj poduzetnika	2.645	3.992	150,9	46	33	71,7	31	11	35,5	2.722	4.036	148,3
Udjeli poduzeća %	97,2	98,9	/	1,7	0,8	/	1,1	0,3	/	100,0	100,0	/
Broj zaposlenih	8.669	16.062	185,3	6.397	4.157	65,0	19.622	11.383	58,0	34.688	31.602	91,1
Udjeli zaposlenih %	25,0	50,8	/	18,4	13,2	/	56,6	36,0	/	100,0	100,0	/
Uk. prihodi (u 000)	3.155.890	7.127.724	225,9	1.280.332	2.151.233	168,0	5.017.241	8.112.501	161,7	9.453.463	17.391.458	184,0
Udjeli prihoda u %	33,4	41,0	/	13,5	12,4	/	53,1	46,6	/	100,0	100,0	/
Uk. rashodi (u 000)	3.420.470	7.069.214	206,7	1.508.385	2.101.074	139,3	5.505.795	6.830.408	124,1	10.434.650	16.000.696	153,3
Uk. dobit (EBT) - uk. gubitak (u 000)	62.919	58.510	/	- 19.072	50.159	/	- 572.929	1.282.093	/	- 529.082	1.390.762	/

Napomena: podaci za ukupnu dobit i ukupni gubitak nisu dostupni (/) u prikazu za 2012. godinu i predstavljaju razliku ukupnih prihoda i rashoda

Izvor: obrada autora prema Iskra, 2011:9 i Grad Rijeka, 2013:54

Prikaz na tablici 5 ukazuje da riječko gospodarstvo strukturom prema veličini poduzeća slijedi hrvatske trendove, budući već u 1995. godini dosiže razinu udjela MSP-a koju imaju i europska gospodarstva, dok je iz udjela u broju zaposlenih još uvijek vidljiva tranzicija gospodarske strukture iz ranije prevladavajućih velikih poduzeća, čije je učešće u broju zaposlenih u 1995. godini (56,6 %) gotovo na razini europskog prosjeka iz 1990. godine (60,59 %). Udjel broja MSP-a (99,7 %), kao i broja zaposlenih u MSP-u (64 %) u 2012. godini u Rijeci nadmašuje nacionalnu razinu, što upućuje na još izraženiju prisutnost usitnjavanja velikih gospodarskih subjekata (u odnosu na ostatak Hrvatske), koji su početkom 1990-ih dominirali riječkim gospodarstvom. Zastupljenost pojedinih djelatnosti u riječkom gospodarstvu prikazana je tablicom 6.

Tablica 6. Ukupni prihodi poduzetnika Rijeke u 2002., 2007. i 2012. g. prema djelatnostima (u kn)

Djelatnosti	2002.	Udjel %	2007.	Udjel %	07/02	2012.	Udjel %	12/07	12/02
Trgovina na veliko i malo	6.763.362.417	46,4	9.879.928.196	45,7	146,1	6.724.400.600	38,7	68,1	99,4
Prerađivačka industrija	3.503.032.037	24,0	4.275.461.790	19,8	122,1	4.103.891.393	23,6	96	117,2
Prijevoz, skladištenje i veze	1.876.873.264	12,9	2.547.310.864	11,8	135,7	2.887.730.486	16,6	113,4	153,9
Građevinarstvo	680.485.705	4,7	1.071.587.167	5,0	157,5	665.342.267	3,8	62,1	97,8
Opskrba elek. energijom, plinom i vodom	215.154.686	1,5	255.103.882	1,2	118,6	510.101.624	2,9	200	237,1
Hoteli i restorani	137.663.041	0,9	266.910.360	1,2	193,9	268.603.105	1,5	100,6	195,1
Poslovanje nekretninama, iznajmljivanje	994.856.627	6,8	2.630.656.187	12,2	264,4	216.519.105	1,2	8,2	21,8
- - - - - - - -	- - - - - - - -	- - -	- - - - - - - -	- - -	- - -	- - - - - - - -	- - -	- - -	- - -
Ukupni prihodi	14.589.069.418	100	21.629.529.338	100	148,3	17.391.458.020	100	80,4	119,2

Izvor: obrada autora prema – Iskra, 2011:12 i Grad Rijeka, 2013:55

Podaci o ukupnim prihodima najznačajnijih djelatnosti na tablici 6 u desetogodišnjem razdoblju i to od 2002., preko posljednje pretkrizne 2007., do 2012. godine (najnoviji dostupni podaci), prikazani u obliku skraćene top-liste formirane temeljem podataka o ukupnim prihodima za 2012. godinu, jasno ocrtavaju utjecaj krize u djelatnostima građevinarstva i poslovanja nekretninama, kao i zadržavanje strukture djelatnosti u kojima prevladava: trgovina (od 46,4 % u 2002. do 38,7 % udjela u 2012. godini), prerađivačka industrija (od 24 % u 2002., preko 19,8 % u 2007. i 23,6 % u 2012. godini), te prijevoz, skladištenje i veze (od 12,9 % u 2002. godini do 16,6 % u 2012. godini). Nadalje, ovakva struktura ukazuje da su u Rijeci najzastupljenije djelatnosti u kojima na razini Hrvatskih MSP-a imaju najveći udjel ukupnog broja zaposlenih u MSP-u (ACE International Consultants S. L. i partneri, 2013:12 i 28): trgovina s 18,26 % i prerađivačka industrija s 18,15 % ukupno zaposlenih u MSP-u. Ovakva struktura dodatno naglašava važnost podupiranja razvoja MSP-a na lokalnoj razini.

2.2 Evolucija uloge malih i srednjih poduzeća

U eri dominacije velikih poduzeća u 1960-ima i 1970-im godinama studije provedene u SAD-u i zapadnoj Europi pokazale su da su mala i srednja poduzeća (Audretsch, 2003:6):

- općenito manje učinkovita u odnosu na velika poduzeća,
- osiguravala manju razinu kompenzacija zaposlenima
- samo marginalno uključena u inovativne aktivnosti (mjereno učešćem u R&D).

No od početka 1970-ih trendovi razvoja krenuli su u suprotnom smjeru. Velika poduzeća racionaliziraju poslovanje kroz restrukturiranje, *outsourcing* ili *downsizing*, a broj vlasnika samostalnih poduzeća raste u OECD državama od 29 milijuna 1972. godine do 45 milijuna u 1998. godini (European Commission, 2003:4). Od početka 70-ih godina 20. stoljeća započela je najveća ekspanzija MSP-a, koji dobivaju sve značajniju ulogu, a njihova razina konkurentnosti jača, kako u odnosu na velika poduzeća, tako i kroz uključivanje u suvremenu globalizaciju poslovanja. Kao četiri ključna doprinosa malih poduzeća tržišnom gospodarstvu izdvajaju se (Deželjin et al., 2002:232-233): otvaranje novih radnih mjesta, doprinos procesu tehnoloških promjena, doprinos regeneraciji zdrave konkurencije između poduzeća različitih veličina unutar grane nacionalnog gospodarstva i na međunarodnom planu, te bogatstvo ponudbenih sadržaja pogotovo na domaćem tržištu. Nove teorije industrijske evolucije (pretežno u prvoj polovici 1990-ih) osigurale su okvir koji poduzetništvo dovodi u pozitivnu vezu s generiranjem ekonomskog rasta, nasuprot tradicionalnim teorijama koje su zastupale stav da poduzetništvo usporava ekonomski rast. Naime, tradicionalni pristup zastupa stav da novo znanje nema važnu ulogu, već rast diktira statična učinkovitost temeljena na iskorištavanju ekonomije obujma. Suprotno tome nove dinamične teorije ističu ulogu znanja koje je neizvjesno, asimetrično i povezano s visokim transakcijskim troškovima, te divergencije nastaju u različitoj procjeni vrijednosti novih ideja. Fokus ovih teorija se prenosi na promjene kao središnji fenomen, uz inovativne aktivnosti kao glavnu manifestaciju promjena. Prevladavajuće mjere utjecaja poduzetništva na ekonomske performanse su: rast zaposlenosti i opstanak, a ostale: prihodi, izvoz, razina plaća, inovativnost i proizvodnost, te povremeno profitabilnost (zbog negativnog utjecaja primjene različitih računovodstvenih pristupa), zadovoljstvo vlasnika i zaposlenika. U 1980-ima i 1990-ima niz mjerenja osigurao je brojne dokaze o pozitivnoj i čvrstoj povezanosti poduzetništva i ekonomskih

performansi i to prema svim indikatorima u različitim razinama istraživanja, od individualaca do ustanova, poduzeća, industrija, geografskih klastera, regija, država pa i skupina država u Europi i SAD-u (Audretsch, 2003:10-13).

2.3 Značaj poduzetništva u ekonomskom razvoju Europske unije

Era dominacije MSP-a proširila se na EU te su do početka 1990-ih mala i srednja dosegla udio u broju poduzeća od preko 99 %. Prethodno spomenute teorije i znanstveno potvrđeni dokazi, kao i sve razvijenije baze statističkih podataka, predstavljali su podlogu koja je pretočena u strateške dokumente EU-a usmjerene k jačanju uloge poduzetništva u ekonomskom i društvenom razvoju. Pritom poduzetništvo kao „način razmišljanja i proces kreiranja i razvijanja ekonomskih aktivnosti stapanjem spremnosti na preuzimanje rizika, kreativnosti i/ili inovativnosti s razumnim upravljanjem, unutar nove ii postojeće organizacije", kako je definirano u Zelenoj knjizi o poduzetništvu u Europi (European Commission, 2003:6), svojom važnošću nadmašuje značenje koje ima sektor MSP-a, budući da (Škrtić, Mikić, 2006:200-202):

i. *Poduzetništvo potpomaže otvaranje novih radnih mjesta i gospodarski rast:* nova se radna mjesta sve više ostvaraju u novim malim poduzećima, a ne u velikim, što dokazuju primjeri tijekom 1990-ih godina u Nizozemskoj, SAD-u pa i Hrvatskoj kada su mala poduzeća kroz 12 godina (od 1994. do 2006.) osigurala oko 77.000 novih radnih mjesta, što je u uvjetima stope nezaposlenosti oko 18 % izuzetno značajno.

ii. *Poduzetništvo ima presudno značenje za konkurentnost:* nove poduzetničke inicijative, koje pokreću novo ili preusmjeravaju postojeće poduzeće, povećavaju proizvodnost i pritisak konkurentnosti te potiču druga poduzeća i jačaju konkurentnu snagu gospodarstva u cjelini, a potrošači dobivaju povećan izbor i niže cijene.

iii. *Poduzetništvo razvija osobne potencijale:* važne kriterije odabira karijere ne čine samo visoka primanja, već i: sigurnost, razina samostalnosti, raznolikost zadataka te zainteresiranost za posao, no visoka primanja potiču ljude da kroz poduzetništvo zadovolje 'više potrebe', poput samoispunjenja i samostalnosti.

iv. *Poduzetništvo razvija opće društvene interese:* poduzetnici su pokretačka snaga tržišno orijentiranog gospodarstva i njihovi rezultati donose nova radna mjesta, potrošačima bolju ponudu, a kroz formalne (u velikim poduzećima) i neformalne (u MSP-a), strategije socijalne odgovornosti i brigu za okoliš i održivi razvoj.

Jedinstveni pristup u promicanju politika i razvoju poduzetništva EU-a promovira i kroz Zakonik o malim poduzećima (*Small Business act for Europe*). Taj dokument predstavlja vodič i definira načela u koncipiranju i primjeni politika EU-a u državama članicama, s ciljem jačanja konkurentnosti, stvaranja veće dodane vrijednosti i izjednačene tržišne utakmice za MSP kroz unapređenje zakonskog i administrativnog okruženja širom EU-a. Između deset načela koje definira Zakonik o malim poduzećima važno mjesto zauzima načelo: stvoriti pravila prema principu 'prvo razmišljaj malo' (*engl. think small first*), tj. pri uvođenju novog propisa verificirati kako se on odražava na MSP (European Commission, 2008:4). Od 2010. godine Europska komisija

uključila je u svoja izvješća (*SBA Fact Sheet*) i Hrvatsku. Dio izvješća za područje poduzetništva prikazan je u sklopu točke 2.1. ovog rada, a nastavno i dinamika performansi prema (nevaganom) prosjeku agregiranih pokazatelja pojedinih načela.

Grafikon 2. Performanse prema SBA pokazateljima za Hrvatsku i EU u razdoblju od 2007. do 2012.

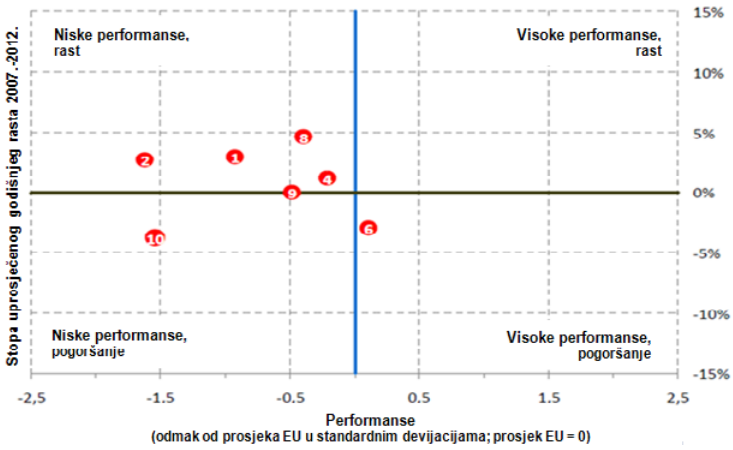

Izvor: European Commission, 2012 b:3

Prikaz dinamike performansi na grafikonu 2, kao i prikazi kretanja pokazatelja poduzetničke aktivnosti (tablice 1 i 2) ukazuju na značajno zaostajanje Hrvatske prema većini kriterija. Pored toga, iz prikaza trendova u pogledu kretanja strukture i broja zaposlenih u MSP-ima datih u točci 2.1. razvidno je da Hrvatska i grad Rijeka prate dinamiku i strukturu koja vrijedi za prosjek EU-a. Istovremeno je utvrđeno i da struktura gospodarskih grana u gradu Rijeci slijedi obrazac koji vrijedi za prosjek Hrvatske. Nadalje, u ovom radu je uvodno te u točkama 2.2. i 2.3. istaknut značaj koji EU pridaje razvoju sektora MSP-a, kao i opredjeljenju za uspostavu i jačanje sustava poticanja poduzetništva, te nadzoru učinaka poticaja, koje je iskazano i kroz dokumente o strateškim i taktičkim razinama EU-a. Slično opredjeljenje iskazala je i Hrvatska i to još desetak godina prije ulaska u Europsku uniju, kroz prihvaćanje Europske povelje o MSP-u iz 2000. godine (*Charter for Small Enterprises*), uz Lisabonsku strategiju i Akcijski plan za poduzetništvo iz 2004. (*Action Plan: The European agenda for Entrepreneurship*), tada jedan od ključnih strateških i akcijskih dokumenata kojima EU potiče razvoj MSP-a (Kutnjak, 2010:84). Time je Hrvatska preuzela obvezu da kroz napore ministarstava, agencija i drugih sudionika realizira i primijeni najvažnije principe koji trebaju biti integrirani u nacionalnu politiku za malo i srednje poduzetništvo.

Usvajanje elemenata sustava pružanja potpore malom i srednjem poduzetništvu koje promovira EU kroz svoje akte započelo je u Hrvatskoj 2002. godine kroz Zakon o poticanju razvoja malog gospodarstva (NN 29/2002), koji je izmijenjen i dopunjen 2007. godine (NN 63/2007), te 2012. i 2013. godine (NN 53/2012 i 56/2013). Programom razvoja malog gospodarstva utvrđene su smjernice razvoja, poticajne mjere, nositelji provedbe poticajnih mjera, provedbene aktivnosti, izvori sredstava, razdoblje provedbe pojedinih poticajnih mjera te metodologija praćenja

provedbe pojedinih mjera. Vlade Republike Hrvatske donosile su Programe za razdoblja od 2004. do 2008. i 2008. do 2012. godine. Danas Hrvatska regulira i potiče sektor MSP-a kroz niz politika i programa, a posebno posredstvom (prilagođeno prema: CEPOR, 2012 b:24):

- Strategije razvoja poduzetništva u Republici Hrvatskoj 2013. – 2020.,
- Strateških planova za razdoblje 2012. – 2014. i razdoblje 2014. – 2016.,
- Strategije razvoja klastera 2011. – 2020.,
- Strategije razvoja ženskog poduzetništva u Republici Hrvatskoj od 2010. do 2013.,
- Strategije učenja za poduzetništvo 2010. – 2014.,
- Strategije regionalnog razvoja Republike Hrvatske 2011. – 2013.,
- Poduzetničkog impulsa 2012., 2013. i 2014.

Pritom treba naglasiti da je dokument Strategija razvoja poduzetništva u Republici Hrvatskoj 2013. – 2020. dokument koji zamjenjuje sve druge politike i programe sustava potpora malom i srednjem poduzetništvu i obrtu, ujedno prvi takav strateški dokument u području poduzetništva od osnutka Hrvatske.

Slijedom navedenog vidljivo je da je Hrvatska prepoznala potrebu za usvajanjem dokumenata i tako pokazala namjeru slijeđenja opredjeljenja i preporuka EU-a u pogledu poticanja poduzetništva i sektora MSP-a. Radi usporedbe kompatibilnosti hrvatskog pristupa poticanju poduzetništva i sektora MSP-a, kao važnom čimbeniku sveukupnog gospodarskog, ali i društvenog rasta u EU-u i svijetu uopće, definirane su sljedeće podhipoteze rada:

- *H1a. U krovnim strateškim dokumentima na nacionalnoj – hrvatskoj i lokalnoj razini (u gradu Rijeci) usvojeni su prioriteti i ciljevi koje kroz sustav poticanja poduzetništva i MSP-a promovira EU, što pozitivno utječe na stavove prema poduzetništvu i jačanje uloge MSP-a u Hrvatskoj i gradu Rijeci;*
- *H1b. Strateški ciljevi poticanja poduzetništva usvojeni na sektorskoj nacionalnoj – hrvatskoj i lokalnoj razini (u gradu Rijeci) prate opredjeljenja koja zastupa EU, što pozitivno utječe na razvoj poduzetništva i MSP-a u Hrvatskoj i gradu Rijeci.*
- *H2. Na nacionalnoj – hrvatskoj i lokalnoj razini (u gradu Rijeci) način praćenja i kontrole utjecaja mjera poticanja MSP-a ima negativan utjecaj na konkurentnost i razvoj potencijala MSP-a i poduzetništva uopće.*

Podhipoteze determinirane na temelju prethodno prikazanih analiza i istraživanja mogu se sublimirati u hipotezu ovog rada: *Razina dokumentirane usvojenosti strategija i akcijskih planova poticanja malog i srednjeg poduzetništva koje promovira EU, na nacionalnoj i lokalnoj razini pozitivno, a pristup analizi i kontroli utjecaja mjera poticanja, negativno utječe na razvoj potencijala hrvatskog poduzetništva.*

3. METODOLOGIJA ISTRAŽIVANJA

U sklopu dokazivanja postavljene hipoteze rada, odnosno radi usporedbe kompatibilnosti hrvatskog pristupa poticanju poduzetništva, provedeno je istraživanje 'za stolom' za europsku, nacionalnu i lokalnu razinu. Istraživanje lokalne razine kompatibilnosti provedeno je kroz analizu poslovnog slučaja (engl. case-study) grada Rijeke koji je odabran budući zadovoljava postavljene kriterije: veličine grada i dostupnosti analiza. Naime, Rijeka je jedan od tzv. 'velikih' gradova u Hrvatskoj (više od 35.000 stanovnika), sukladno Zakonu o lokalnoj i područnoj - regionalnoj samoupravi (NN 109/07), te ima zakonska ovlaštenja i veće financijske mogućnosti za poticanje poduzetništva u odnosu na županije (izuzev Grada Zagreba), općine i ostale gradove. Nadalje, s obzirom da podaci o načinima i rezultatima analiza poticanja poduzetništva (što je područje istraživanja obuhvaćeno podhipotezom H2), nisu javno dostupni, odabran je grad Rijeka.

Kao relevantni dokumenti za komparaciju sustava poticanja poduzetništva, u sklopu istraživanja obuhvaćenog podhipotezama H1a i H1b, na razini EU-a odabrani su:

- Strategija Europa 2020. i
- Akcijski plan za poduzetništvo 2020.,
- na razini Hrvatske:
- Program Vlade za razdoblje 2011. – 2015. i
- Strategija razvoja poduzetništva u Republici Hrvatskoj 2013. – 2020.,
- a za razinu grada Rijeke:
- Strategija razvoja grada Rijeke 2014. – 2020.,
- Opći program mjera razvoja poduzetništva na području grada Rijeke i Poduzetnički impuls za 2013. (kao nacionalni dokument – program, koji se primjenjuje paralelno s lokalnim programima poticanja, na istom području).

Nadalje, u sklopu dokazivanja podhipoteze H2, korišteno je istraživanje korisnika potpora koje nudi Grad Rijeka prema Općem programu mjera razvoja poduzetništva na području Rijeke (u daljnjem tekstu: Opći program). Istraživanje je proveo Odjel gradske uprave za poduzetništvo Grada Rijeke anketnim upitnikom koji je osmislio autor ovog rada zaposlen u spomenutom odjelu. Upitnik s ukupno 6 pitanja (i više podpitanja) obuhvatio je ključna područja – projekte sufinanciranja, a distribuiran je poduzetnicima – korisnicima potpora u 2009. godini (N = 43), uz odaziv od 25,45 %.

4. REZULTATI ANALIZE SUSTAVA POTICANJA PODUZETNIŠTVA

4.1 Komparativna analiza prioriteta i ciljeva poticanja poduzetništva

Nastavno su prikazani rezultati komparacije ključnih razvojnih prioriteta i ciljeva (tablica 7), te ključnih odrednica strateških sektorskih dokumenata za razvoj poduzetništva na europskoj, nacionalnoj i lokalnoj razini (tablica 8), temeljem odabranih dokumenata.

Tablica 7. Usporedba ključnih razvojnih prioriteta i ciljeva u krovnim strateškim dokumentima na europskoj, nacionalnoj i lokalnoj razini

Razina	EU	Republika Hrvatska	Grad Rijeka
Dokument	Strategija Europa 2020.	Program Vlade za razdoblje 2011.-2015.	Strategija razvoja grada Rijeke 2014.-2020.
Strateški prioriteti	– pametan rast kroz razvijanje ekonomije utemeljene na znanju i inovaciji, – održiv rast kroz promicanje ekonomije koja učinkovitije iskorištava resurse, koja je zelenija i konkurentnija, – uključiv rast kroz njegovanje ekonomije s visokom stopom zaposlenosti koja donosi društvenu i teritorijalnu povezanost.	Sigurnost, solidarnost, ravnopravnost, pravednost i napredak svih hrvatskih građana kroz realizaciju tri osnovna stupa: – snažan gospodarski rast temeljen na stvaranju novih vrijednosti, – manja i učinkovitija državna potrošnja, – mijenjanje sustava društvenih vrijednosti.	– pametan rast (čime se potiču znanje, inovacije, obrazovanje i digitalno društvo) – održiv razvoj (čime će naša proizvodnja postati učinkovitija u iskorištavanju resursa, uz istovremeno povećanje konkurentnosti) – uključiv rast (povećanjem sudjelovanja na tržištu rada, stjecanjem vještina te borbom protiv siromaštva).
Strateški ciljevi	– 75 % populacije u dobi između 20 i 64 godine trebalo bi biti zaposleno, – 3 % BDP-a EU treba investirati u istraživanje i razvoj, – treba ispuniti klimatsko-energetske ciljeve "20/20/20" (uklj. i povećanje do 30 % manje emisije ako okolnosti dozvoljavaju), – postotak osoba koje rano napuste školovanje trebao bi biti ispod 10 %, a najmanje 40 % mlađe generacije trebalo bi završiti tercijarni stupanj obrazovanja, – 20 milijuna manje ljudi trebalo bi biti u opasnosti od siromaštva.	– rast BDP-a i zapošljavanje, – održivi rast proračunskih prihoda i usklađenje rashoda s kapacitetima, – snažno ulaganje u znanje i obrazovanje, – uklanjanje korupcije iz tijela javne vlasti, – reforma poreznoga sustava, – financijska i upravljačka decentralizacija, – zaštita radničkih prava i osiguranje jednakih šansi za najosjetljivije društvene skupine, – uspostava održivog mirovinskog i svima dostupnog zdravstvenog sustava.	– globalno pozicionirati Rijeku razvojem riječkoga prometnog pravca. – na temeljima društva znanja i novih tehnologija razviti konkurentno gospodarstvo. – osigurati dostojanstvo svih građana jačanjem socijalne uključenosti i razvojem projekata od zajedničkog interesa.

Izvor: obrada autora prema European Commission, 2010 a:3; Vlada Republike Hrvatske, 2011:3-4; Grad Rijeka, 2013:117-8.

Tablica 8. Usporedba ključnih odrednica strateških sektorskih dokumenata za razvoj poduzetništva na europskoj, nacionalnoj i lokalnoj razini

Razina	EU	Republika Hrvatska	Grad Rijeka
Dokument	Akcijski plan za poduzetništvo 2020.	Strategija razvoja poduzetništva u Republici Hrvatskoj 2013. – 2020.	Opći program mjera razvoja poduzetništva na području grada Rijeke
Strateški ciljevi	1. *Poduzetničko obrazovanje i trening koji podupire rast i kreiranje poslovnih pothvata* na novim temeljima: jačanje rasprostranjenosti i kvalitete učenja za poduzetništvo i na novim dostignućima: visoko obrazovanje za poduzetništvo. 2. *Kreiranje okruženja gdje poduzetnici mogu procvjetati i rasti kroz šest ključnih područja u kojima treba ukloniti barijere:* – olakšan pristup financiranju, – podupiranje poduzetnika u ključnim fazama poslovnog životnog ciklusa, – oslobađanje novih poslovnih prilika u digitalno doba, – olakšani transfer poslovanja, – pojednostavljene procedure stečaja i 'druga šansa' za poštene poduzetnike, – jednostavnija i jasnija regulativa. 3. *Stvaranje uzora* (kroz uspješne 'priče' poduzetnika) *i dosizanje specifičnih ciljnih skupina* (žene, seniori, migranti, nezaposleni, mladi).	*Opći cilj:* povećanje konkurentnosti maloga gospodarstva u Hrvatskoj *Strateški ciljevi:* 1. *Poboljšanje ekonomske uspješnosti* maloga gospodarstva u proizv. i uslužnim granama većim ulaganjem u istraživanje i razvoj, višim stupnjem inovacija, rastom izvoza i razvojem posl. mreža. 2. *Poboljšan pristup financiranju* i uklanjanje financijskog jaza za malo gospodarstvo. 3. *Promocija poduzetništva* radi pružanja potpore osnivanju novih poduzeća, rasta broja aktivnih poduzeća i jačanja potpornih institucija što će pridonijeti ravnomjernijem regionalnom razvoju. 4. *Poboljšanje poduzetničkih vještina* kroz jačanje upravljačkih kompetencija, jačanjem udjela visokokvalificiranih zaposlenika te podupiranjem cjeloživotnog učenja zaposlenih u subjektima maloga gospodarstva. 5. *Poboljšano poslovno okruženje* kroz nadgradnju ostvarenog napretka uklanjanjem preostalih administrativnih opterećenja i olakšavanjem poslovanja u Hrvatskoj.	1. Jačanje konkurentnog nastupa poduzetnika na tržištu. 2. Ostvarivanje praktičnog obrazovanja i boljeg informiranja u poduzetništvu. 3. Poboljšanje uvjeta raspoloživosti financijskih resursa. 4. Unapređenje korištenja poduzetničke prostorne i informativne infrastrukture za realizaciju poduzetničkih poduhvata. 5. Podizanje razine poduzetničke kulture. **Poduzetnički impuls 2013.** 1. Sustav potpora s mjerama: A. Mikropoduzetništvo, obrti i klasteri B. Jačanje poslovne konkurentnosti poduzetnika i obrtnika C. Razvoj poduzetničke infrastrukture i poslovnog okruženja D. Obrazovanje za poduzetništvo i obrte očuvanje tradicijskih i umjetničkih obrta 2. Financiranje MSP-a i obrta 3. Projekti EU-a 4. Institucijska podrška

Izvori: obrada autora prema European Commision, 2010 b:3,5-26; Ministarstvo poduzetništva i obrta, 2013 a:3; Grad Rijeka, 2008:1 i Ministarstvo poduzetništva i obrta, 2013b:13

Pregled strateških prioriteta i ciljeva na tri razine nije u potpunosti usporediv, budući da se za europsku i lokalnu razinu temelji na strateškim dokumentima koji dosljednije prate ključne elemente strateškog planiranja, dok za nacionalnu razinu u trenutku provođenja istraživanja takav dokument nije bio raspoloživ. No usprkos tome iz pregleda je uočljivo (podcrtani dijelovi teksta), da prioriteti i ciljevi definirani na nacionalnoj i lokalnoj razini u mnogome slijede odrednice date u krovnom europskom dokumentu, posebno u pogledu: jačanja konkurentnosti, rasta zapošljavanja, razvoju društva znanja i socijalno osjetljivom razvoju. To je svakako pozitivna pretpostavka uspješnoj realizaciji niza projekata, posebno onih koji su usmjereni ka potencijalnom iskorištavanju sredstava iz namjenskih europskih fondova. Iako na nacionalnoj i lokalnoj razini, ciljevi nisu kvantificirani, Hrvatska prihvaća ciljeve zacrtane na razini EU-a i od 2011. godine prati dostignute veličine prema jedinstvenim pokazateljima u sklopu Strategije Europa 2020. Pritom Hrvatska najviše zaostaje za prosjekom EU-a (EU-27) prema pokazateljima (Vlada Republike Hrvatske, 2013:33): udjela istraživanja i razvoja u BDP-u s 0,75 % prema 2,03 % u EU-27 i zastupljenosti tercijarno obrazovanih s 24,5 % prema 35,5 % u EU27, a prednjači u manjoj stopi mladih koji napuštaju školovanje, s 4,1 % prema prosjeku EU-27 od 12,9 %. Nastavno su analizirani strateški sektorski dokumenti za razvoj i poticanje poduzetništva na sve tri razine.

Kroz usporedbu strateških ciljeva definiranih u dokumentima orijentiranim na razvoj poduzetništva na europskoj, nacionalnoj i lokalnoj razini uočljivo je (podcrtani dijelovi teksta) da se u svim dokumentima ističe: važnost obrazovanja za poduzetništvo, olakšan pristup financiranju i podizanje poduzetničke kulture.

Uz dokumente analizirane u tablici 8, Hrvatska primjenjuje i druge dokumente koji također slijede preporuke Europske komisije, primjerice Strategiju za razvoj ženskog poduzetništva 2010. – 2013. koja je postavila sljedeće ciljeve (CEPOR, 2009:9):

- *dugoročni cilj:* kontinuirano raditi na promjenama vrijednosnog sustava, ponašanja i okoline o kojima ovisi jačanje poduzetničke aktivnosti žena,
- *srednjoročni cilj – do 2013. godine:* značajno povećati broj žena koje pokreću poslovni pothvat i broj žena – vlasnica rastućih poslovnih pothvata, kako bi se ostvarila razina poduzetničke aktivnosti žena na razini koja se ostvaruje u SAD (mjereno odnosom TEA indeksa žena i TEA indeksa muškaraca, stanje 2008. godine), što znači smanjiti jaz od 1 prema 2,41 na jaz od 1 prema 1,43.

4.2 Praćenje uspješnosti implementacije programa poticanja poduzetništva

Pored definiranja i provedbe ciljeva i programa vrlo je važno pratiti učinke poduzetih aktivnosti kako bi se procijenio doprinos pojedinih mjera, te osiguralo učinkovito trošenje u javnom sektoru. Za tu svrhu EU je odabrao ključne pokazatelje koji su dostupni i za razinu Hrvatske u izvješćima Europske komisije *SBA Fact Sheet Croatia* i sadrže podatke koji se prate od 2007. godine. Bogat izvor podataka i iznimno vrijedan alat u *ex post* evaluaciji mjera poticanja poduzetništva i MSP-a predstavlja i obnovljeno izdanje GEM brošure za Hrvatsku (sa značajnim dijelom posvećenim regionalnim pokazateljima – po

županijama i NUTS-2 regijama), te izvješća o MSP-u za 2012. i 2011. godinu u izdanju CEPOR-a. Vrlo korisna su i izvješća opservatorija za MSP za 2013. i za 2012. godinu (ACE International Consultants S. L. i partneri), te publikacije Obrtništvo u brojkama (podaci od 2003. do 2012. godine) u izdanju Hrvatske obrtničke komore. Sva spomenuta izvješća, kao i izvješća *Doing Business* (IFC) i izvješće Svjetske banke koriste se i pri analizi provedbe operativnog programa Poduzetnički impuls, kao i Strategije za razvoj poduzetništva 2013. – 2020. Značajnu podlogu predstavljaju i istraživanja administrativnih, pravnih i drugih prepreka na koja nailaze MSP i obrti, koja se periodično provode. Tako je u 2013. godini istraživanje proveo ACE International Consultants S. L. i partneri na uzorku od 502 MSP-a i 520 obrta.[6]

No iako su poduzetnicima i odgovornima za formuliranje politika i programa poticanja poduzetništva u posljednjim godinama dostupna sve brojnija i sveobuhvatnija domaća i međunarodna istraživanja i dalje nedostaju *ex ante* evaluacije, koje su posebno važne u pogledu primjene načela 'prvo razmišljaj malo' (engl. *Think Small First)* definiranog u Zakoniku o malim poduzećima (European Commission, 2008:7). Na lokalnoj razini, međutim, izrazit je nedostatak podataka i za *ex post* evaluacije, budući se većina pokazatelja iz spomenutih dokumenata, odnosi na nacionalnu, manjim dijelom na regionalnu, a vrlo malim za lokalnu razinu. Pritom vrijedi istaknuti napore koje ulaže Centar za lokalni ekonomski razvoj Ekonomskog fakulteta Rijeka kroz projekt EFRISTAT, u sklopu kojeg je utvrđena metodologija utvrđivanja veličine BDP-a za razinu gradova (kombinacijom statističkih i primarnih – anketnih izvora), no zasad bez šire i javno dostupne primjene (više na: www.cler.hr). Projekt Indeks konkurentnosti gradova (*City Index*), koji je razvio Razvojni forum Zagreb ugašen je nakon izdanja za 2009. godinu (za razdoblje od 2004. do 2009.).

Na razini dijela država članica EU-a i OECD-a dostupna su od 2011. godine i publikacije *Entrepreneurship at a Glance***,** u pripremi *OECD – Eurostat Entrepreneurship Indicators Programme* (EIP), koje se oslanjaju na relevantne smjernice politika poticanja poduzetništva. Set pokazatelja obuhvaća šest područja s ukupno 82 pokazatelja (OECD 2013:9-10 i 96-100) i to: regulatorni okvir, tržišni uvjeti, pristup financiranju, stvaranje i distribucija znanja, poduzetničke sposobnosti i poduzetnička kultura. Neki od tih pokazatelja navedeni su u pregledu na tablici 9, a u Hrvatskoj će biti dostupni ovisno o dinamici harmoniziranja podataka Državnog statističkog zavoda Republike Hrvatske s Europskim statističkim sustavom (ESS), što je i definirano Strategijom razvitka službene statistike 2013. – 2022. (Državni zavod za statistiku Republike Hrvatske, 2013:21).

[6] Skraćeno izvješće dostupno na: http://www.minpo.hr

Tablica 9. Usporedba ključnih ciljeva i pokazatelja rezultata poticanja poduzetništva na europskoj i nacionalnoj razini

EU		Republika Hrvatska	
Akcijski plan za poduzetništvo 2020.		Strategija razvoja poduzetništva u Republici Hrvatskoj 2013. – 2020.	
Ciljevi	Pokazatelji	Ciljevi	Pokazatelji
1. Poduzetničko obrazovanje i trening	– uloga poduzetničkog obrazovanja – stavovi prema neuspjehu, – preferencije i izvedivost samozapošljavanja	1. Poboljšanje poduzetničkih vještina Unapređenje znanja i kompetencija poduzetnika i njihovih zaposlenika za 10 %, te rast broja znanstvenika zaposlenih u poduzetništvu za 35 %	– % radne snage u izobrazbi (trenutačno – 2013. = 2,3 %) – % znanstvenika zaposlenih u poduzetništvu (19 % u 2010.)
2. Uklanjanje barijera u šest područja: – olakšan pristup financiranju	– stav prema pristupu financiranju i – zajedničkim ulaganjima	2. Poboljšanje pristupa financiranju Za 40 % više ponude fin. sredstava za MSP (u 2010. banke su samo 39,7 % plasirale gospodarstvu)	– % povećanja udjela mikro i malih podu-zetnika u kreditnom portfelju (2010 = 8 %) – % povećanje udjela ostalih financijskih instrumenata
– podupiranje poduzetnika u ključnim fazama poslovnog životnog ciklusa – pojednostavljenje procedure stečaja i davanje 'druge šanse' za poštene poduzetnike – olakšani transfer poslovanja – jednostavnija i jasnija regulativa.	– veličine zaposlenih, dodane vrijednosti, proizvodnosti i izvoza po veličini poduzeća – stope rađanja, umiranja i preživljavanja poduzeća, – broj novih poduzeća, – broj stečajeva.	3. Promocija poduzetništva Povećanje broja poduzetnički aktivnih ljudi (mjereno TEA indeksom) na > 8	– Rast vrijednosti TEA indeksa, odnosno rast broja poduzetnički aktivnih ljudi (TEA indeks 7,32 u 2011.)
– oslobađanje novih poslovnih prilika u digitalno doba	– razina samozapošljavanja, – udjel visokotehnoloških poduzeća, – udjel 'gazela' (brzorastućih poduzeća),	4. Poboljšanje ekonomske uspješnosti Povećanje udjela sektora maloga gospodarstva u BDP-u za 10 %.	– Udio MSP-a u BDP-u (51,6 % u 2010.)
3. Stvaranje uzora i dosizanje specifičnih ciljnih skupina (žene, seniori, migranti, nezaposleni, mladi).	– spolne razlike u samozapošljavanju, – samozapošljavanje među mladima, ženama, seniorima i migrantima	5. Poboljšanje poslovnog okruženja Podizanje Hrvatske u prvih 50 zemalja na rang-listi izvješća Svjetske banke „Doing Business" tijekom trajanja strategije.	– Položaj Hrvatske na godišnjoj rang listi prema istraživanju Svjetske banke "Doing Bussiness" (trenutačno 84. mjesto)

Napomena: Akcijski plan za poduzetništvo 2013.-2020., kao krovni dokument EU-a, ne kvantificira veličine pojedinih mjera, već je to u ingerenciji država članica
Izvori: obrada autora prema European Commission, 2010 b:5-26; OECD 2013:10; Ministarstvo poduzetništva i obrta, 2013 a:39

Iz pregleda pokazatelja vidljivo je da se u Hrvatskoj u aktualnim dokumentima pretežno koriste isti pokazatelji, kao i na razini EU-a, odnosno OECD-a. Pritom su malobrojniji potcrtani pokazatelji na nacionalnoj razini, no i šireg obuhvata – TEA indeksi. No ti pokazatelji definirani su tek u Strategiji razvoja poduzetništva 2013. – 2020., koja je usvojena polovinom 2013. godine, dok se ranije politika malog gospodarstva u Hrvatskoj nije dovoljno bavila mjerenjem utjecaja i opravdanosti instrumenata na kojima se ta politika temelji (Ministarstvo poduzetništva i obrta, 2013 a:6).

U pregledu na tablici 9 nije obuhvaćena lokalna razina, budući da Opći program mjera razvoja poduzetništva na području grada Rijeke (u daljnjem tekstu: Opći program), temeljem kojeg se dodjeljuju lokalno planirana sredstava za poticanje MSP-a i obrtnika (Grad Rijeka, 2008), dijelom prati mjere definirane u Strategiji razvoja poduzetništva u Republici Hrvatskoj 2013. – 2020., odnosno prethodno važećem Programu za razvoj malog gospodarstva 2008.-2012. (Ministarstvo gospodarstva, rada i poduzetništva, 2008), no ne i pokazatelje definirane za nacionalnu razinu, budući da su oni samo djelomično dostupni na lokalnoj razini (samo broj poduzeća, zaposlenih i ukupnih prihoda/rashoda prema veličini poduzeća). Zbog toga se i rezultati mjera poticanja poduzetništva u sklopu Općeg programa prate samo kroz godišnje usporedbe broja, ukupnog i prosječnog iznosa dodijeljenih potpora po pojedinim vrstama potpora, te povremena istraživanja zadovoljstva korisnika lokalnih poticaja. Istraživanje koje je radi kontrole uspješnosti primjene poticajnih mjera, ali i dobivanja podloga za eventualne korekcije Općeg programa proveo Odjel gradske uprave za poduzetništvo Grada Rijeke 2009. godine kroz istraživanje korisnika potpora Grada Rijeke u prethodnoj godini, pokazalo je rezultate prikazane u tablici 10.

Tablica 10. Rezultati ispitivanja zadovoljstva korisnika potpora Općeg programa

Pitanja		Odgovori
1.	U kojoj mjeri smatrate korisnim učinak bespovratne potpore na svoje poslovanje?	– ocjena 5 (raspon od 1 – najmanje koristan do 5 - najkorisniji)
2.	Od koga ste dobili prve informacije o mjerama jačanja konkurentnosti poduzetnika na području grada Rijeke?	– od prijatelja/ poslovnih partnera (44,45 %) – iz novina (33,34 %) – SMS servisom Grada Rijeke (11,12 %) – na web-stranici Grada Rijeke (11,12 %).
3.	Smatrate li da je visina dobivene potpore odgovarajuća Vašim potrebama?	– zadovoljno (77,78 %) – nije zadovoljno (22,22 %) – kao razlog nezadovoljstva visinom potpore dio ispitanika je naveo je da bi adekvatna potpora bila 50 % ili više od ostvarenih troškova bez limitiranja iznosa
4.	Koliko ste zadovoljni komunikacijom s Odjelom za poduzetništvo Grada Rijeke?	– potpuno zadovoljavajuća (55,56 %) – zadovoljavajuća (44,45 %)
5.	U kojem bi segmentu Vašeg budućeg poslovanja bespovratne potpore bile najkorisnije?	– potpore za sudjelovanje na domaćim sajmovima (11,12 %) – školovanje – edukacija zaposlenika (11,12 %) – marketinške aktivnosti (33,34 %) – razvoj i unapređenje postojećih projekta (11,12 %) – troškovi najamnine (11,12 %) – potpora za recertificiranje standarda kvalitete (11,12 %) – izrada web-stranice (22,23 %) – razvoj i uvođenje novih tehnologija (22,23 %) – obrada stranog tržišta (11,12 %)
6.	Navedite Vaše prijedloge aktivnosti i mjera kojima bi Odjel gradske uprave za poduzetništvo Grada Rijeke pripomogao Vašem poslovanju	– promocija riječkih proizvoda na domaćem i inozemnim tržištima – obrazovanje i usavršavanje zaposlenika – subvencije za uvođenje novih tehnologija – povoljniji uvjeti najma/kupnje gradskih poslovnih prostora

Izvor: obrada autora prema podacima Odjela gradske uprave za poduzetništvo Grada Rijeke, 2009.

Rezultati ankete sveukupno upućuju na zadovoljstvo korisnika primljenim potporama i potrebu razvoja novih potpora koje su i uvedene već od 2010. godine: subvencioniranje troškova implementacije industrijskog dizajna, troškova obrazovanja, stručnog osposobljavanja i usavršavanja zaposlenika te poticanje udruživanja gospodarskih subjekata, a za razdoblja koja slijede dogovorene su i mjere jačanja konkurentnosti u dijelu promocije proizvoda i nastupa poduzeća na inozemnim tržištima. Nadalje, temeljem rezultata o kanalima informiranja poduzetnika (samo 11 % poduzetnika saznalo je za mjere na gradskim *web*-stranicama), utvrđena je potreba za širim korištenjem javnih medija, uz naglasak na uvođenje novih oblika komuniciranja (prvenstveno društvenih mreža).

5. ZAKLJUČAK

Svrha ovog rada bila je analizirati modalitete usvajanja sustava pružanju potpora malom i srednjem poduzetništvu koje promovira EU, na nacionalnoj – hrvatskoj i lokalnoj razini u gradu Rijeci.

Metodama komparacije i analize strateških prioriteta i ciljeva dostupnih strateških dokumenata (pritom je za nacionalnu razinu uspoređivan dokument koji najbliže odgovara obuhvatu dokumenata na europskoj i lokalnoj razini), utvrđeno je da se na lokalnoj razini prate svi strateški europski prioriteti, dok opredjeljenja na nacionalnoj razini djelomično prate dva od ukupno tri prioriteta. U pogledu strateških ciljeva, nacionalna razina slijedi europske odrednice u 60 % definiranih područja (3/5), a na lokalnoj razini sljedljivost se prepoznaje na razini 40 % ciljeva (2/5). Sumarno, komparacija strateških prioriteta i ciljeva pokazala je da na nacionalnoj i lokalnoj razini postoji usvojenost strateških odrednica razvoja od 62,5 %, iako s različitom strukturom prema prioritetima i ciljevima. Zbog toga se može ustvrditi da je podhipoteza H1a dokazana, tj. da razina usvojenosti prioriteta i ciljeva koje kroz sustav poticanja poduzetništva i MSP-a promovira EU, u krovnim strateškim dokumentima na nacionalnoj – hrvatskoj i lokalnoj razini (u gradu Rijeci), pozitivno utječe na stavove prema poduzetništvu i jačanje uloge MSP-a.

Kroz analizu i komparaciju sektorskih dokumenata provjeravana je usvojenost strateških ciljeva u pogledu implementacije sustava poticanja poduzetništva i MSP-a u praksi, s europskim polazištima – preporukama. Istraživanjem je utvrđeno da je na nacionalnoj razini (kroz Strategiju razvoja poduzetništva u Republici Hrvatskoj 2013. - 2020.) usvojeno 44,4 % preporuka, a na lokalnoj razini kroz Opći program trećina preporuka, te kroz Poduzetnički impuls 2013. 22,2 % preporuka, no ukupno i dalje na razini jedne trećine. Pritom je važnost obrazovanja za poduzetništvo i olakšan pristup financiranju usvojen u sektorskom dokumentu nacionalne razine, te u oba dokumenta koji se primjenjuju na lokalnoj razini u gradu Rijeci. Ovi zaključci upućuju da je podhipoteza H1b djelomično dokazana, budući da su *strateški ciljevi poticanja poduzetništva koje zastupa EU, na sektorskoj nacionalnoj i razini grada Rijeke, usvojeni na prosječnoj razini od 29,6 % (prosječno je usvojeno 2,7 od ukupno 9 europskih preporuka), pa je moguće očekivati slab, no pozitivan utjecaj na razvoj poduzetništva i MSP-a.*

U pogledu kvalitete praćenja uspješnosti implementacije programa poticanja poduzetništva, komparirani su ciljevi i pripadajući pokazatelji nacionalne – hrvatske i europske razine, budući da u dokumentima koji su usvojeni na lokalnoj razini nisu definirani odgovarajući usporedivi pokazatelji. Istovremeno je dio pokazatelja definiranih na nacionalnoj razini dostupan za niže

prostorne razine – regije i županije (NUTS-2 i NUTS-3 razine), ali ne i za razinu gradova (LAU 1 i 2 razine). Komparacijom raspoloživosti pokazatelja utjecaja mjera poticanja poduzetništva utvrđeno je da je u posljednje dvije-tri godine dostupno niz istraživanja koja se provode prema metodologiji koju je usvojila Europska komisija, OECD ili GEM konzorcij, što jamči usporedivost podataka s ostalim članicama na razini EU-a i šire (OECD članice i države obuhvaćene GEM istraživanjima), te daje kvalitetne podloge za procjenu postojećih i formuliranje budućih politika i programa poticanja poduzetništva na nacionalnoj razini. No pri analizi provedbe nacionalnih programa poticanja poduzetništva i obrta (npr. Poduzetnički impuls), pokazatelji su samo dijelom primjenjivi na lokalnoj razini, budući da je samo dio podataka koje priprema FINA dostupan za razinu gradova (pritom i ograničene pouzdanosti). Istraživanjem koje je proveo Odjel gradske uprave za poduzetništvo Grada Rijeke izvršena je *ex post* evaluacija mjera poticanja MSP-a u prethodnom razdoblju, no zbog svog obuhvata ne može poslužiti kao zamjena za pokazatelje koji se koriste na razini EU-a i nacionalnoj razini. Temeljem istraživanja slijedi da treba odbaciti podhipotezu H2 u dijelu koji se odnosi na nacionalnu razinu, a prihvatiti na lokalnoj razini, tj. da način praćenja i kontrole utjecaja mjera poticanja MSP-a ima negativan utjecaj na konkurentnost i razvoj potencijala MSP-a i poduzetništva uopće, na lokalnoj razini.

Radi dostizanja više razine usvojenosti preporuka EU-a, no još važnije, radi postizanja boljeg nadzora i bolje učinkovitosti trošenja javnih sredstava putem mjera iz sustava poticanja poduzetništva, MSP-a, obrta i zadruga, potrebno je i dalje inzistirati na uspostavljanju javno dostupne baze podataka za lokalne razine, na temelju kojih bi se mogle utvrditi promjene veličina pokazatelja koji se već univerzalno koriste na višim prostornim razinama.

LITERATURA

ACE International Consultants S. L. i partneri (2012) *Izvješće opservatorija malog i srednjeg poduzetništva u Republici Hrvatskoj*, Zagreb, www.minpo.hr, 10. 6. 2013.

ACE International Consultants S. L. i partneri (2013) *Izvješće opservatorija malog i srednjeg poduzetništva u Republici Hrvatskoj*, Zagreb, www.minpo.hr, 20. 12. 2013.

Audretsch, D. B. (2003) *Entrepreneurship: A survey of the literature*, Brussels, D-G European Commission, http://ec.europa.eu/enterprise/newsroom/document.htm, 27. 12. 2013.

CEPOR (2012 a) *Što čini Hrvatsku (ne)poduzetničkom zemljom?*, www.cepor.hr, 19. 6. 2013.

CEPOR (2012 b) *Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2012.*, www.cepor.hr, 4. 1. 2014.

CEPOR (2011) *Izvješće o malim i srednjim poduzećima u Hrvatskoj – 2011.*, www.cepor.hr, 27. 9. 2013.

CEPOR (2009) *Strategija razvoja ženskog poduzetništva u Republici Hrvatskoj*, www.cepor.hr, 21. 9. 2011.

Deželjin J. et al. (2002) *Poduzetnički menadžment*, Zagreb: M.E.P. Consult

Državni zavod za statistiku Republike Hrvatske (2013) *Strategija razvitka službene statistike 2013. – 2022.*, www.dzs.hr, 23. 12. 2013.

European Commission (2013) *Annual report on European SMEs 2012/2013*, Report Croatia i EU27 2008.-2013., http://ec.europa.eu/enterprise/policies/sme/facts-figures-analysis/summarypaper_en.pdf, 4. 1. 2014.

European Commission (2012 a) *Flash Eurobarometer 354*, Brussels, http://www.ec.europa.eu, 3. 1. 2014.

European Commission (2012 b) *SBA Fact Sheet 2012 Croatia*, Brussels, http://www.ec.europa.eu, 3. 1. 2014.

European Commission (2010 a) *Europe 2020, A European strategy for smart, sustainable and inclusive growth*, Brussels, http://europa.eu/pdf/complet_en_barroso_007_-_europe_2020_-en_version.pdf**,** 18. 7. 2011.

European Commision (2010 b) *Entrepreneurship 2020 Action Plan*, Brussels, http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2012:0795:FIN:en:PDF, 25. 12. 2013.

European Commission (2008) *Small Business act for Europe*, Brussels, http://ec.europa.eu/enterprise/policies/sme/small-business-act/index_en.htm, 4. 1. 2014.

European Commission (2007) *Flash Eurobarometer 192*, Brussels, http://www.ec.europa.eu, 2. 1. 2014.

European Commission (2003) *Green Paper Entrepreneurship in Europe*, Brussels, http://eur-lex.europa.eu/LexUriServ/site/en/com/2003/com2003_0027en01.pdf, 4. 1. 2008.

European Commission (2000) Lisbon *Strategy, 2000-2010, Analysis and evaluation of the methods used and results achieved*, Brussels, http://www.europarl.europa.eu/activities/do?language=EN, 12. 4. 2009.

European Commission (1995) *European Observatory for SMEs*, 3rd Annual Report, Brussels, http://aei.pitt.edu/34780/1/A27.pdf, 23. 12. 2013.

Grad Rijeka (2013) *Strategija razvoja Grada Rijeke 2014. – 2020.*, www.rijeka.hr, 26. 10. 2013.

Grad Rijeka (2008) *Opći program mjera razvoja poduzetništva na području Rijeke*, www.rijeka.hr, 28. 5. 2011.

Hrvatska obrtnička komora (2012) *Obrtništvo u brojkama*, Zagreb, HOK, www.hok.hr, 14. 1. 2014.

Hrvatska obrtnička komora (2009) *Obrtništvo u brojkama 2009*, Zagreb, HOK, www.hok.hr, 19. 9. 2012.

Hrvatska obrtnička komora (2006) *Obrtništvo u brojkama 2003. – 2005.*, Zagreb, HOK, www.hok.hr, 8. 3. 2010.

Iskra, V. (2011) *Analiza potpora malim i srednjim poduzećima u Gradu Rijeci*, stručni završni rad, Rijeka: Veleučilište u Rijeci

Kutnjak G. (2010) *Europska unija u funkciji poticanja malog i srednjeg poduzetništva*, Rijeka: Sveučilište u Rijeci, Ekonomski fakultet Rijeka, Poslovna izvrsnost, Vol.4 no.2, listopad

Ministarstvo gospodarstva, rada i poduzetništva (2008) *Program poticanja malog i srednjeg poduzetništva 2008.-2012.*, Zagreb, www.mingorp.hr, 5. 7. 2010.

Ministarstvo poduzetništva i obrta (2013 a) *Strategija razvoja poduzetništva 2013. – 2020.*, Zagreb, www.minpo.hr, 2. 1. 2014.

Ministarstvo poduzetništva i obrta (2013b) *Poduzetnički impuls za 2013.*, Zagreb, www.minpo.hr, 12. 12. 2013.

OECD (2013) *Entrepreneurship at a Glance 2013*, Brussels, http://www.oecd.org/std/business-stats/entrepreneurshipataglance.htm, 2. 1. 2014.

Singer, S., Lauc, B. (2004) *Razvoj sektora malih i srednjih poduzeća*, www.cepor.hr, 22. 12. 2013.

Škrtić, Mikić (2006) *Gospodarsko značenje hrvatskoga poduzetništva – šanse i zamke*, Zagreb: Zbornik Ekonomskog fakulteta u Zagrebu, godina 4,

Švaljek et al (2007) *Pristupanje Europskoj uniji: Očekivani ekonomski učinci*, Zagreb: Ekonomski institut, www.eizg.hr, 14. 3. 2009.

Vlada Republike Hrvatske (2013) *Ekonomski program Republike Hrvatske 2013*, www.vlada.hr, 25. 11. 2013.

Vlada Republike Hrvatske (2011) *Program Vlade za razdoblje 2011. – 2015.*, www.vlada.hr, 12. 2. 2012.

Davor Širola[1]
Valentina Iskra[2]

Professional paper
UDK 338.246.027:334.012.63/.64(4-67EU)

THE ANALYSIS OF ENTREPRENEURSHIP SUPPORT SYSTEM ON EUROPEAN, CROATIAN AND LOCAL LEVEL[3]

ABSTRACT

Small and medium entrepreneurship development is one of the most important commitments of the European Union, already transposed into clear targets embedded in strategic and operational planning documents. The structure of small and medium enterprises in Croatia, the newest member of the European Union, mostly follows the average structures of the other 27 members, which means that the adoption of the European entrepreneurship support system is becoming an imperative for Croatia. Therefore, the objective of this research is to determine the actual status of the Croatian entrepreneurship support system, in comparison with other member states of the European Union. The results of the research suggest that Croatia has implemented the majority of priorities and targets defined in strategic European documents on the national level, but considerably less on the local one (the City of Rijeka). The analysis of operational targets shows that Croatia has adopted one-third of the EU recommendations. In the field of monitoring the efficiency of entrepreneurship support measures, the system of European indicators has recently been implemented on the national level, but not on the local one where there are still no preconditions for establishing local databases which would ensure control over public spending of cities and municipalities on entrepreneurship support, as well as control over spending of national funds distributed to entrepreneurs locally.

Key words: *small and medium entrepreneurship, entrepreneurship support system, efficiency indicators*

[1] Master of marketing management, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: davor.sirola@veleri.hr

[2] Bachelor of economics, Student, Associate for development projects support, City of Rijeka, Korzo 16, Rijeka, Croatia. E-mail: valentina.iskra@rijeka.hr

[3] Received: 13. 2. 2014.; accepted: 15. 5. 2014.

Aleksandar Skendžić[1]

Stručni rad
UDK 004.7.056

SIGURNOST INFRASTRUKTURNOG NAČINA RADA BEŽIČNE MREŽE STANDARDA IEEE 802.11[2]

SAŽETAK

Bežične mreže sve se češće koriste i danas su postale standard u povezivanju računala nudeći pritom jednostavnu implementaciju uz smanjene troškove, zadovoljavajuće brzine mrežne propusnosti (eng. Bandwith) te veću mobilnost korisnika. Bežična komunikacija korisniku daje veću mobilnost, a samim time brži i lakši pristup izvoru informacija. Kada se govori o bežičnim lokalnim mrežama, kao posebno se važno nameće pitanje sigurnosti. Također, bežične mreže predstavljaju najnesigurniji dio u lokalnoj žičanoj mreži (LAN) zato što im je medij - nosioc zrak, čime mreža postaje dostupna i izvan organizacije u kojoj se koristi. Sigurnosni algoritmi (enkripcije) sprečavaju mogućnost neovlaštenog korištenja mreže, ali ne nude potpunu sigurnost. Ovaj rad dat će pregled sigurnosnih tehnologija infrastrukturnog načina rada bežične mreže (eng. wlan) i dati preporuke sigurnijeg načina rada. Rad nudi pregled metoda infrastrukturne sigurnosti wlan standarda IEEE 802.11.

Ključne riječi: *bežične mreže, IEEE 802.11, sigurnost, infrastrukturni način rada*

1. UVOD

Pojavom IEEE 802.11 mrežnog standarda, problem sigurnosti ostaje prioritetni zadatak administratora bežične mreže. Istraživanje iz 2008. provela je tvrtka RSA Security (http://www.emc.com) otkrivši kako veliki broj mreža koristi enkripcijski sustav integriran u bežične mrežne uređaje i bilježi porast u odnosu na ranija istraživanja. Istraživanjem je također utvrđeno kako razne organizacije, unatoč čestom i negativnom pisanju o sigurnosti bežičnih mreža, ipak koriste bežične mreže. Korištenje bežičnih mreža u Velikoj Britaniji se u 12 mjeseci povećalo za 235 %. Istraživanja sigurnosti bežičnih mreža u Hrvatskoj provele su nezavisne udruge korisnika bežičnih mreža, kao i Centar za prevenciju i otklanjanje problema vezanih uz sigurnost računalnih mreža u suradnji s laboratorijem za sustave i signale Fakulteta elektrotehnike i računarstva Sveučilišta u Zagrebu. Rezultat istraživanja jest objava javnog dokumenta pod nazivom CCERT-PUBDOC-2003-05-22 čija je svrha poboljšanje sigurnosti bežičnih mrežnih sustava ustanova članica Hrvatske akademske i istraživačke mreže. Enkripcijski algoritmi ne nude potpunu sigurnost od neovlaštenog korištenja te ih se može zlorabiti. Upravo je stoga nužno iskoristiti dodatne mogućnosti infrastrukturnog načina rada u procesima autentikacije korisnika bežične mreže, kako bi se povećala razina sigurnosti.

[1] Mag. edu. inf. est. hist., viši predavač, Veleučilište Nikola Tesla u Gospiću, Bana Ivana Karlovića 16, Gospić, Hrvatska. *E-mail:* wireless82@gmail.com

[2] Datum primitka rada: 19. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

2. INFRASTRUKTURNI NAČIN RADA IEEE 802.11

Infrastrukturni način rada sastoji se od najmanje jedne pristupne točke ili usmjerivača povezanih sa žičanom mrežnom infrastrukturom ili nizom bežičnih krajnjih stanica. Ovakva konfiguracija mrežnih elemenata naziva se osnovna skupina (engl. *Basic Service Set - BSS*[3]). Dvije ili više BSS grupa čine podmrežu ili proširenu uslužnu grupu (engl. *Extended Service Set -* ESS[4], Hamidović, 2009). Krajnje stanice u infrastrukturnom načinu rada komuniciraju preko više pristupnih točaka. Infrastrukturni način rada bežičnih mreža podrazumijeva i specifična okruženja koja tvore pristupne točke ili usmjerivače. Postoji nekoliko načina rada bežičnih krajnjih stanica ovisnih o proizvođaču mrežne opreme:

- „*Master*" način rada jest standardni način rada gdje klijent komunicira s pristupnom točkom ili usmjerivačem.
- „*Bridge*" način rada djeluje kao „most" između dvije pristupne točke ili usmjerivača, ali ne dozvoljava spajanje klijenata na uređaje.
- Repetitorski način rada dozvoljava premošćivanje poput „*bridge*" načina rada, ali uz mogućnost istovremenog spajanja klijenata na svaku pojedinu pristupnu točku ili usmjerivač.
- *Wireless Distribution System -* WDS način rada, a označava tehniku povezivanja više pristupnih točaka (AP-ova). WDS je prisutan u obliku raznih *Point-to-Point*/*Multipoint Bridge* implementacija, kao i u obliku nadogradnji standardnih pristupnih točaka.

Slika 1. 802.11 arhitektura a) Infrastrukturni WLAN, b) neovisni WLAN

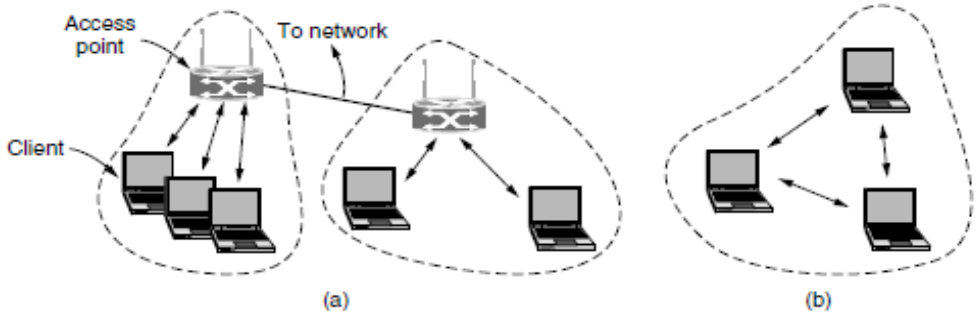

Izvor: Tanenbaum, A. S., Wetherall, D. J. (2011)

[3] *Basic Service Set (BSS)* je skup svih pristupnih stanica koje međusobno komuniciraju. Svaka stanica posjeduje jedinstveni ID zvan BSSD koja označava MAC adresu pristupne točke u infrastrukturnoj komunikaciji.

[4] *Extended Service Set (ESS)* je proširen skup pristupnih stanica koje međusobno komuniciraju.

Sigurnosna razina infrastrukturnog načina rada je visoka zbog korištenja odgovarajućih enkripcijskih algoritama i protokola. Sigurnosni mehanizmi zaštite bežične mreže u infrastrukturnom načinu rada su:

1. MAC filtriranje
2. IP filtriranje
3. Uporaba enkripcijskog ključa
4. RADIUS
5. LDAP imenički servis i protokol
6. Uporaba sigurnosne zaštitne stijene
7. TKIP
8. AES
9. CCMP
10. IEEE 802.1X

2.1 MAC filtriranje

MAC adresa (engl. *Media Access Control*) je adresa kodirana u ROM (*Read Only Memory*) svakog mrežnog uređaja. Sastoji se od 48 bita i jedinstvena je za svaki uređaj. Koristi se za adresiranje na razini podatkovne veze ISO/OSI referentnog modela. MAC filtriranje je najjednostavniji oblik zaštitnog mehanizama bežične mreže. Temeljem liste dopuštenih/zabranjenih MAC adresa, tj. hardverskih adresa pristupne točke, usmjerivači i klijenti međusobno komuniciraju. Ukoliko MAC adresa nije zapisana u uređaju na kojemu se vrši postupak autentikacije, klijent nema odobrenje za korištenje mrežnih resursa niti se može spojiti na pristupnu točku ili usmjerivač. Nedostatak navedenog sigurnosnog mehanizma jest mogućnosti lakog zaobilaženja jer većina mrežnih adaptera ima mogućnost (privremenog) mijenjanja MAC adrese putem specijaliziranog softvera.

2.2 IP filtriranje

IP filtriranje, kao sigurnosni mehanizam, temelji se na deklariranju pravila IP filtriranja i dodjeljivanja ili uskraćivanja pristupa na određenu IP adresu ili skup adresa. IP filtriranje je dodatni sigurnosni mehanizam zaštite bežičnih mreža. Napadaču je teško odrediti koji se deklarirani raspon IP adresa koristi u pristupnoj točki/usmjerivaču kako bi se na njega prijavio. S obzirom na navedeno, sigurnosna preporuka jest koristiti IP filtriranje.

2.3 Uporaba enkripcijskog ključa

U okviru bežičnog mrežnog standarda 802.11 koriste se tri tipa algoritama za sigurnu komunikaciju. Algoritmi su definirani sljedećim standardima:

a) *Wired Equivalent Privacy* - WEP

b) *Wi-Fi Protected Access* - WPA

c) *Wi-Fi Protected Access II* – WPA2

Svi navedeni algoritmi nastoje ispuniti unutar 802.11 standarda sljedeće pretpostavke:

- Povjerljivost: temeljna svrha algoritama za sigurnu komunikaciju je spriječiti prisluškivanje mrežnog prometa;
- Kontrola pristupa: također ima ulogu kontrole pristupa jer pristupne točke imaju mogućnost zabrane prometa klijentima koji ne prođu uspješno proces autentikacije.

Algoritami se međusobno razlikuju po metodama enkripcije komunikacije i autentikacije korisnika. Slijedi pregled enkripcijskih algoritama koji se koriste kao sigurnosni mehanizmi bežičnih mreža:

1. WEP - 802.11 standard navodi WEP kao algoritam koji omogućava siguran prijenos podataka preko bežičnih lokalnih mreža čija sigurnost je ekvivalentna fizičkim sigurnosnim elementima u ožičenim medijima. Unutar WEP-u su se tijekom vremena otkrili nedostaci u njegovoj izradi. WEP se koristi na podatkovnom sloju OSI modela kako bi zaštitio podatke tijekom prijenosa. WEP algoritam se oslanja na tajnosti ključa koji se koristi između pristupne točke i klijenta i pomoću njega enkriptira tijela okvira poruke (Tanenbaum, Wetherall, 2011). Enkripcija se vrši u sljedećim koracima:

   a. Zaštitno kodiranje *(checksumming)*

   Kako bi zaštitili integritet poruke, nad njom se vrši operacija zaštitnog kodiranja s CRC32 polinomom, a zaštita se zapisuje na kraj podatka koji se želi zaštititi. Dakle, čisti tekst (P) dobivamo sljedećim izrazom:

   $$P=\{M,c(M)\}$$

   M predstavlja originalni podatak. c(M) i P ne ovisi o dijeljenom ključu k. Čisti tekst P je ulaz za drugi korak.

   b. Enkripcija

   U drugom koraku enkriptira se čisti tekst iz prethodnog koraka pomoću algoritma RC4. Slučajnim odabirom bira se inicijalizacijski vektor IV koji uz ključ k služi kao ulaz u RC4 algoritam. Algoritam generira veliki broj pseudo-slučajnih bitova kao funkciju ključa k i inicijalizacijskog vektora IV. Ovaj niz bitova označava se s RC(IV,k). Nakon toga se vrši operacija ekskluzivno ili nad bitovima čistog teksta i dobivenim nizom pseudo-slučajnih bitova da bi se dobio šifrirani tekst (*ciphertext*).

   Aktivno probijanje zaštitnog mehanizma WEP algoritma može se prikazati dostupnim programskim alatima poput *Aircracka* francuskog autora Chistophe Devina (http://os2.zemris.fer.hr).

Slika 2. Proces WEP enkripcije

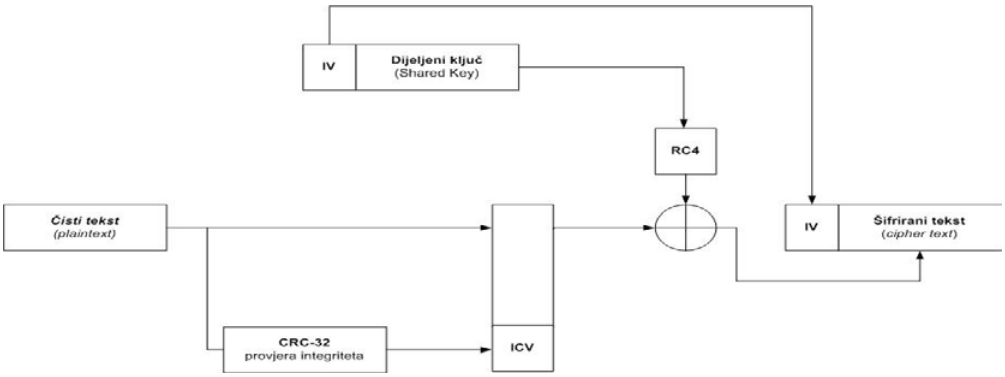

Izvor**:** FER, http://os2.zemris.fer.hr/ns/wireless/2004_maric/wep.htm (7. 7. 2013.)

2. WPA – WPA predstavlja certifikaciju, a ne protokol, odnosno sigurnosni standard. WPA uključuje samo jedan sigurnosni protokol TKIP. WPA je nastao prvenstveno zbog sigurnosnih nedostataka WEP enkripcije, odnosno nedostataka korištenjem inicijalizacijskog vektora. U kolovozu 2001. godine objavljena je kriptoanaliza WEP protokola i načina na koji se koriste RC4 tok za šifriranje i inicijalizacijski vektor (ACM digital library, http://dl.acm.org/citation.cfm?id=694759). Navedena analiza je pokazala da je WPA enkripcijski protokol ranjiv na pasivne napade. Pasivni napadi imaju cilj otkrivanja RC4 ključa iz prikupljenih paketa podataka (ACM digital library, http://dl.acm.org/citation.cfm?id=694759). Ovisno o količini prometa na mreži, odnosno broja uhvaćenih paketa dostupnih za analizu, za uspješno otkrivanje RC4 ključa može biti potrebno i samo nekoliko minuta. WPA i dalje koriste RC4 i CRC32 algoritmi. Uvedeni su TKIP (*Temporal key integrity protocol*), MIC (*Message integrity code*, izračunava se algoritmom Michael[5]) te 802.1x autentikacija. Kombinacijom dugačkog inicijalizacijskog vektora (IV) i TKIP protokola, sustav se može obraniti od napada kakvi se koriste za otkrivanje ključa kod primjene WEP protokola (Tanenbaum, Wetherall, 2011). Naime, slabosti prethodnih sustava ležale su u premalom broju mogućih inicijalizacijskih vektora koji su uz isti tajni ključ davali nesigurne nizove podataka. To znači da je analizom tih nizova bilo moguće otkriti vrijednosti ključa. Na ovaj način opisani algoritam napada gotovo je nemoguće iskoristiti.

2.3.1 Ranjivost WPA certifikacije

2008. godine otkriven je sigurnosni propust TKIP komponente. TKIP komponenta je korištena kako bi se osigurala kompatibilnost sa starijim mrežnim adapterima, odnosno mrežnom opremom koja je podržavala isključivo stariji WEP enkripcijski algoritam. Da

[5] Algoritam koji u WPA uključuje brojač okvira čime se isključuje mogućnost promjene sastava poruka u komunikacijskom kanalu. Michael algoritam dovoljno je siguran i moguće ga je koristiti na starijim mrežnim adapterima.

bi napadač mogao izvesti aktivni napad na bežičnu mrežu zaštićenu WPA TKIP načinom rada, mrežna oprema mora ispunjavati sljedeće uvijete:

- Pristupna točka mora podržavati tzv. višestruke struje (eng. *multiple streams*) podataka o kvaliteti usluge (*Quality of Service* - QoS) uključene u IEEE 802.11e standardu i podržane u većini današnjih uređaja;
- Napadač mora poznati raspon IP adresa mreže na koju izvodi napad ;
- Interval obnove privremenog ključa (eng. *Temporary Key*) mora biti veći od 2000 sekundi.

Na slici 3 dan je prikaz napada na bežičnu mrežu zaštićenom WPA TKIP certifikacijom s uključenim QOS uslugom na pristupnoj točki.

Slika 3. Prikaz napada na bežičnu mrežu zaštićenom WPA TKIP certifikacijom [7].

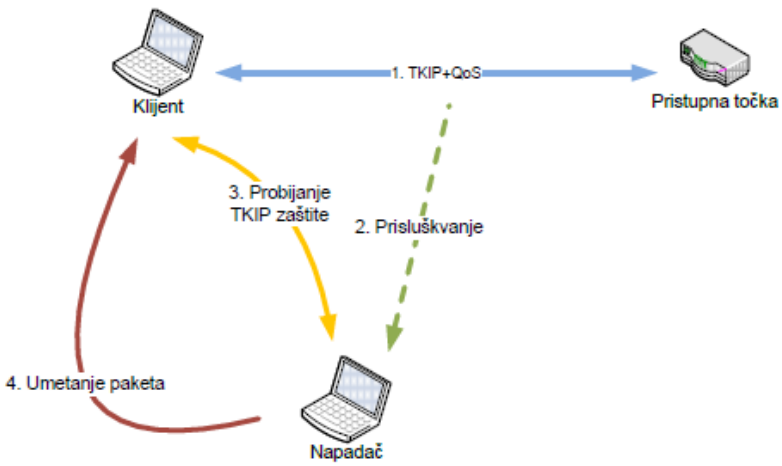

Izvor: CERT, http://www.cert.hr/sites/default/files/NCERT-PUBDOC-2010-12-001_0.pdf (26. 8. 2013)

WPA2 - WPA2 (802.11i standard (http://os2.zemris.fer.hr/) također predstavlja certifikaciju, a ne sigurnosni standard kako se često navodi. Osnovna razlika između 802.11i i WPA je upotreba AES-CCMP algoritma enkripcije (http://os2.zemris.fer.hr/). Izveden je iz WPA certifikata s mogućnošću korištenja dva sigurnosna standarda TKIP te, noviji, CCMP[6] (Cole, 2007). Iako predstavlja sigurniju alternativu u odnosu na WEP standard, WPA2 certifikacija također je ranjiva u određenim načinima rada.

2.3.2 Ranjivost WPA2 certifikacije

Ranjivost WPA2 certifikacije ogleda se u korištenju WPA2+PSK[7] načinu rada. PSK pruža mogućnosti jednostavnijeg postavljanja sustava bez autentifikacijskog poslužitelja. PSK je niz znakova od 256 bita ili riječ od 8 do 63 slova preko kojega se izračunava ključ (http://www.cert.

[6] *Counter Cipher Message Protocol* - CCMP je poboljšani kriptografski mehanizam zaštite bežičnih mreža po standardu IEEE 802.11.

[7] *Pre Shared Key* – ključ s dijeljenom tajnom jedan je od načina rada WPA2 certifikata u sigurnosti bežičnih mreža. Nije se pokazao pouzdanim jer ga je moguće zaobići putem dostupnih programskih alata poput Aircracka.

hr). Ovaj način osiguravanja sigurnosti bežične mreže je korisnicima „najpraktičniji" jer se u praksi uglavnom koriste razne fraze ili izrazi. Napad na ključ podrazumijeva isprobavanje svih potencijalnih kombinacija od strane napadača. Eventualni problem takvih vrsta napada jest problem vremenskog trajanja i vrlo je često neizvediv u zadovoljavajućim vremenskim okvirima (http://www.cert.hr). Usporedni prikaz alata i vremensko trajanja probijanja WPA/WPA2 PSK certifikacije prikazan je u grafikonu 1. Nezavisni rezultati mjerenja od strane korisnika ukazuju da najduže trajanje probijanja WPA/WPA2+PSK certifikacije alatom Cowpatty traje približno 14 min, dok AirCrack isto čini za približno 4 min (http://blog.g0tmi1k.com).

Grafikon 1. Usporedni prikaz alata i vremena potrebnog za probijanje WPA/WPA2+PSK certifikacije

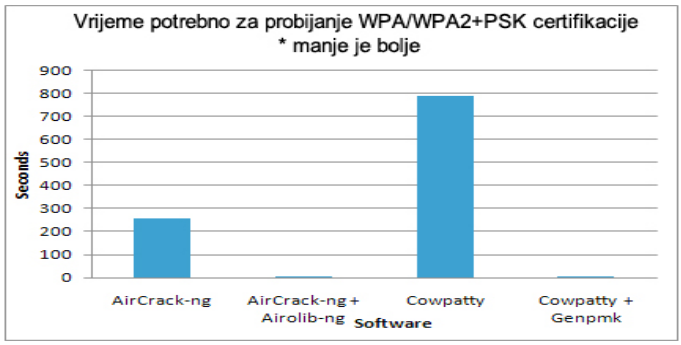

Izvor: http://blog.g0tmi1k.com

2.3.3 Usporedba WEP/WPA/WPA2 protokola

Osim razlike u primjeni CCMP kao sigurnijeg algoritma enkripcije u WPA2 protokolu, WPA i WPA2 protokoli su vrlo slični. WPA2 podržava TKIP protokol, tj. kompatibilan je s WPA protokolom. Nesigurnosti WPA zaštite proizašle su iz ograničenja nametnutih prilikom oblikovanja WPA protokola. Ograničenje WPA protokola je prisutno zbog zadržavanja kompatibilnosti s ranjivim WEP protokolom na starijim mrežnim adapterima. Bez obzira na manji broj otkrivenih ranjivosti, WPA se još uvijek smatra sigurnim protokolom. WPA2 je njegova napredna inačica koja se koristi na novijim sustavima (http://www.cert.hr). Usporedba WEP certifikacije te WPA/WPA2 protokla prikazana je u tablici 1.

Tablica 1. Usporedbe WEP i WPA/WPA2 protokola

Protocol	Encryption	Authentication	Key Management
WEP	• RC4 with 40 bit key/28 bit hash • Static keys	• Pre Shared keys • Open System (SSID)	• Manual key rotation, i.e., no key management
WPA	• TKIP with 128 bit key (over RC4) • Constant key rotation	• 802.1x with EAP and RADIUS • Pre-shared key	• Per packet key rotation
802.11i	• TKIP with 128 bit key (over RC4) • AES-CCMP • Constant key rotation	• 802.1x with EAP and RADIUS • Pre-shared key	• Per packet key rotation (TKIP) • Per session key rotation (AES-CCMP)

Izvor: http://www.fidis.net

2.4 RADIUS i funkcija „AAA"

RADIUS (eng. *Remote Authentication Dial In User Service*) je definiran kao mrežni protokol koji, prilikom spajanja računala na mrežu i korištenja mrežnih usluga, omogućava centralizirano upravljanje autentikacijom, autorizacijom i administracijom korisnika (eng. AAA – *Authentication, Authorization, Accounting*, http://www.cert.hr).

RADIUS je protokol koji radi na principu komunikacije klijent-poslužitelj. Komponenta RADIUS klijenta komunicira s RADIUS poslužiteljem te se izvršava kao pozadinski proces na računalu s UNIX/Linux ili Windows operacijskim sustavom.

RADIUS poslužitelj podrazumijeva tri funkcije (http://www.cert.hr):

1. autentikacija korisnika ili uređaja prije odobravanja pristupa mreži
2. autorizacija korisnika ili uređaja
3. praćenje aktivnosti korisnika usluga

1. Autentikacija je proces putem kojega korisnik mreže potvrđuje vlastiti digitalni identitet. Potvrda digitalnog identiteta obično se ostvaruje putem neke vrste identifikatora odnosno pripadnih podataka poput zaporke, tokena i digitalnih certifikata.

2. Autorizacija je proces putem kojega se utvrđuje je li određeni subjekt/korisnik ovlašten izvoditi određenu aktivnost. Autorizacija se može provoditi nizom ograničenja poput vremenskog, ograničenja fizičke lokacije ili ograničenja protiv višestrukih prijava istog entiteta ili korisnika. Primjeri tipova usluga su filtriranje IP adrese, dodjeljivanje adrese, dodjeljivanje puta usmjeravanja, kvaliteta usluge (*QoS*), diferencijalne usluge, kontrola pojasne širine, upravljanje prometom, obavezno tuneliranje do određene krajnje točke i enkripcija (http://www.cert.hr).

3. Administracija korisnika je proces praćenja korištenja mrežnih usluga, odnosno resursa. Administracija u realnom vremenu odnosi se na podatke koji se dostavljaju za vrijeme korištenja resursa. Skupna administracija (eng. *batch accounting*) odnosi se na podatke koji se čuvaju i kasnije dostavljaju pružatelju mrežne usluge za razna statistička izvješća te kontrolu resursa.

RADIUS protokol je doživio nekoliko izmjena i nadopuna od vremena kada je definiran kao standard 1997. godine. Prikaz kronologija razvoja RADIUS protokola dan je u tablici 2.

RADIUS protokol povećava sigurnost prilikom prijave i korištenja bežične mreže kakve nalazimo u IT infrastrukturi obrazovnih institucija u Hrvatskoj. Premda isti način podešavanja i izvedbe bežične mreže već uvelike koriste sistem-inženjeri obrazovnih institucija, treba ukazati na prednosti u sigurnosti bežične mreže. Prednost RADIUS protokola ogleda se u samom procesu prijave u mrežu. Važno je napomenuti kako RADIUS protokol, osim 802.11, podržava i žičani 802.3 ethernet standard.

Prilikom prijave u mrežu, korisnik šalje svoje podatke RADIUS klijentu koji potom izmjenjuje RADIUS poruke s RADIUS poslužiteljem. Svrha navedenih poruka upravo je ostvarivanje autentikacije, autorizacije i administracije korisnika, odnosno funkcije „AAA". Proces razmjene RADIUS poruke prikazan je na slici 5.

Tablica 2. Kronologija razvoja RADIUS protokola

Broj dokumenta	Naslov dokumenta	Datum izdavanja	Zamijenjen dokumentom
RFC 2058	*Remote Authentication Dial In User Service (RADIUS)*	siječanj 1997.	RFC 2138
RFC 2059	*RADIUS Accounting*	siječanj 1997.	RFC 2139
RFC 2138	*Remote Authentication Dial In User Service (RADIUS)*	travanj 1997.	RFC 2865
RFC 2139	*RADIUS Accounting*	travanj 1997.	RFC 2866
RFC 2548	*Microsoft Vendor-specific RADIUS Attributes*	ožujak 1999.	
RFC 2865	*Remote Authentication Dial In User Service (RADIUS)*	lipanj 2000.	Nadopunjavaju ga RFC 2868, 3575 i 5080
RFC 2866	*RADIUS Accounting*	lipanj 2000.	Nadopunjava ga RFC 2867
RFC 2867	*RADIUS Accounting Modifications for Tunnel Protocol Support*	lipanj 2000.	Nadopunjava RFC 2866

Izvor**:** CERT, http://www.cert.hr/sites/default/files/NCERT-PUBDOC-2010-07-306.pdf (10. 2. 2013.)

Slika 5. Proces razmjene RADIUS poruke

Izvor: CERT, http://www.cert.hr/sites/default/files/NCERT-PUBDOC-2010-07-306.pdf (10. 2. 2013.)

2.5 LDAP imenički servis i protokol

Lightweight Directory Access Protocol - LDAP je naziv za aplikacijski protokol, odnosno imenički servis koji omogućava pristup imeničkim servisima putem računalne mreže. Imenik LDAP-a predstavlja datoteka ili skupina organiziranih podataka koji sadrže podatke o korisnicima, datotekama i aplikacijama te sigurnosne postavke istih. U kontekstu sigurnosti bežičnih mreža LDAP u sprezi s RADIUS protokolom (RADIUS+LDAP) predstavlja jednu od najsigurnijih metoda, kako žičane, tako i zaštite bežične mreže.

2.6 Uporaba sigurnosne zaštitne stijene

Sigurnosna zaštitna stijena (eng. *Firewall*) je računalo ili neka nakupina komunikacijskih uređaja koje fizički odvajaju dvije mreže (Budin, 1998:364). Isto tako, sigurnosna zaštitna stijena ograničava pristup nekoj privatnoj lokalnoj mreži iz javne mreže. U kontekstu bežične mreže po standardu IEEE 802.11, sigurnosna zaštitna stijena može se koristiti kao dodatni sigurnosni mehanizam. Sigurnosna zaštitna stijena postavlja se između žičane mreže i mrežnih uređaja koji omogućavaju bežično spajanje na lokalnu mrežu (najčešće pristupne točke ili usmjerivači). Zaštitne stijene, podešene tako da zahtijevaju strogu autentikaciju i autorizaciju pristupa, vrlo su djelotvoran mehanizam u sigurnosti mreže. Sigurnosne stijene možemo podijeliti u tri skupine, s obzirom na djelovanje (Budin, 1998:365):

- stijene koje filtriraju komunikacijske pakete (engl. *packet filter*),
- stijene koje djeluju kao prividni poslužitelji (engl. *proxy server*),
- stijene koje djeluju kao stvarni poslužitelji (engl. *full server*).

Slika 6. Prikaz moguće pozicije sigurnosne stijene lokalne mreže

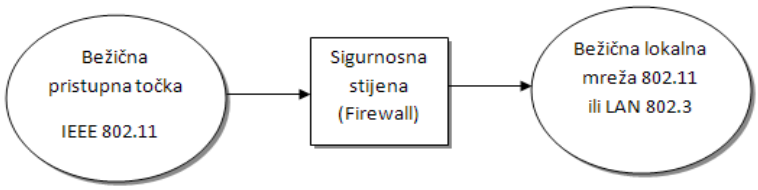

Izvor: autor

Stijene koje filtriraju komunikacijske pakete djeluju na nižim razinama komunikacijskih protokola. Na temelju adrese primatelja, pošiljatelja te smjera kretanja mrežnog paketa, stijena može neke pakete propustiti, a neke blokirati. Blokiranje se može realizirati i na aplikacijskoj razini.

Sigurnosne stijene koje djeluju kao prividni poslužitelji prihvaćaju zahtjeve za obavljanje određenih usluga, iste zahtjeve analiziraju i prosljeđuju stvarnom zaštićenom poslužitelju, ukoliko su prošli sigurnosnu provjeru.

Sigurnosne stijene koje djeluju kao stvarni poslužitelji obavljaju kontrolirane usluge prema vanjskim klijentima i ne dopuštaju neposredni kontakt vanjskih klijenata i unutarnjih korisnika.

Važno je napomenuti kako su sigurnosne stijene samo jedan dodatni mehanizam u sigurnosti bežičnih mreža, kako žičanih, tako i bežičnih, te ostvaruju zaštitu samo na granici mreže, dok na unutarnju sigurnost nemaju nikakav utjecaj.

2.7 Virtualne privatne mreže

Uporabom virtualnih privatnih mreža temeljnih na bežičnoj mrežnoj infrastrukturi (engl. *Virtual Private Network* – VPN) znatno se podiže sigurnosna razina rada u mrežnom okruženju. Iako VIN tehnologija nema izravan utjecaj na procese autentikacije

korisnika prilikom spajanja na bežičnu pristupnu točku, ona doprinosi unutarnjoj sigurnosti bežične mreže. Iz navedenog razloga tehnologija virtualnih privatnih mreža neće se podrobnije razmatrati s obzirom da se radi o unutarnjoj sigurnosnoj razini, a ne o zaštitnom mehanizmu od neovlaštenog pristupa korištenjem bežične mrežne tehnologije. VPN je tehnologija koja omogućava sigurno povezivanje računala u virtualne privatne mreže preko distribuirane ili javne mrežne infrastrukture. VPN podrazumijeva korištenje određenih sigurnosnih i upravljačkih pravila unutar lokalnih mreža. VPN veze mogu se uspostaviti preko različitih komunikacijskih kanala poput interneta, komunikacijske infrastrukture davatelja internetskih usluga i drugih. Važno je napomenuti kako virtualna privatna mreža preko javne mreže stvara sigurni kanal između dviju krajnjih točaka.

Slika 7. Mogućnost integracije bežične lokalne mreže i VPN-a.

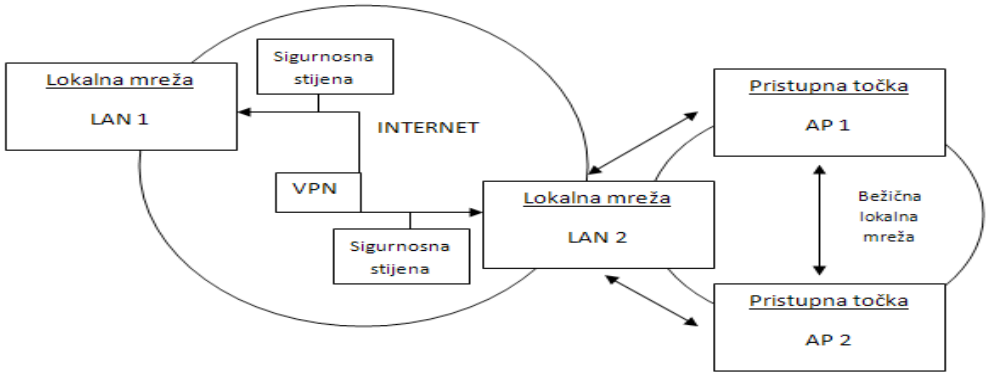

Izvor: autor

Prema konceptu VPN-a, osnovna zadaća tehnologije je kreiranje sigurnog komunikacijskog kanala između privatnih mreža putem javne mreže. Uobičajena je kombinacija sklopovskog i programskog pristupa u kreiranju medija za siguran prijenos podataka. Prilikom komunikacije, podaci iz lokalne mreže prolaze kroz *gateway* uređaj koji ima ulogu zaštite komunikacijkog medija. Isti postupak se primjenjuje kada podaci dolaze u lokalnu mrežu, također prolaze kroz gateway[8] uređaj. VPN štiti tako odaslane podatke automatskim šifriranjem prilikom slanja podataka između dviju udaljenih privatnih mreža i enkapsuliranjem u IP pakete, te automatskim dešifriranjem paketa na drugom kraju komunikacijskog kanala (http://www.cis.hr). Kada se govori o korištenju, implementaciji i sigurnosti VPN-a u mrežnom povezivanju, bežične mreže se u osnovi ne razlikuju od žičanih lokalnih mreža. Razlika je isključivo u pristupnom dijelu mreže (pristupni medij), dok se sa sigurnosnog aspekta u potpunosti podudaraju, odnosno ovise o upravljačkoj mrežnoj infrastrukturi. Korištenje VPN-a u bežičnoj mrežnoj infrastrukturi, bežičnoj lokalnoj mreži daje proširene pristupne mogućnosti (bežični pristup) uz optimalnu sigurnosnu razinu.

[8] Gateway je uređaj koji se nalazi u čvoru računalne mreže i služi za komuniciranje s nekom drugom mrežom. Gateway je i prevodilac mrežnih protokola te omogućava priključivanje na mrežu s drugom vrstom protokola.

3. ZAKLJUČAK

Bežične mreže izložene su sigurnosnim ugrozima jer se podaci neusmjereno i nekontrolirano odašilju u svim smjerovima u dometu odašiljača pa ih zbog takve karakteristike prijenosnog medija može bilo tko presresti. Budući da je danas WPA2 protokol najnaprednije sigurnosno rješenje za zaštitu WLAN-a i računala u njemu, ipak ne predstavlja maksimalnu zaštitu bežične mreže. Posebice je to WPA2+PSK konfiguracija zaštite koja se može probiti dostupnim alatima, poput *Aircracka* ili CommViewa. Zaključuje se kako sigurnost infrastrukturnog bežičnog LAN-a nije preporučljivo temeljiti isključivo na zaštitnim enkripcijskim protokolima (WEP/WPA/WPA2), već treba koristiti i druge mogućnosti infrastrukturnog bežičnog LAN-a (vatrozid, LDAP, RADIUS, MAC filtriranje i sl.), ovisno o dostupnoj mrežnoj infrastrukturi. Pri tome treba voditi računa o jednostavnosti autentikacije korisnika na sustav. U kontekstu sigurnosti bežičnih mreža, LDAP u sprezi s RADIUS protokolom predstavlja jednu od najsigurnijih metoda, kako žičane tako i zaštite bežične mreže koja se može preporučiti ukoliko postoje tehničke mogućnosti. Infrastrukturni bežični LAN zahtjeva korištenje dodatnog mrežnog hardvera (poslužitelji, usmjerivači, pristupne točke) što sa sigurnosnog aspekta predstavlja i proporcionalno veći financijski trošak. Navedene smjernice mogu biti temelj sigurnosne politike ustanove (organizacije) koja će predstavljati svojevrstan nacrt sigurnosti unutar određenog sustava s točno opisanim ciljevima i procedurama sigurnosti.

LITERATURA

Tanenbaum, A. S., Wetherall, D. J. (2011) *Computer networks, 5 edition* SAD, Prentice Hall

ACM digital library, http://dl.acm.org/citation.cfm?id=694759 (08. 02. 2013.)

CERT, http://www.cert.hr/sites/default/files/NCERT-PUBDOC-2010-07-306.pdf, (10. 2. 2013.)

http://blog.g0tmi1k.com/2010/02/video-cracking-wifi-wpawpa2-aircrack-ng.html (11. 2. 2013.)

CERT, http://www.cert.hr/sites/default/files/NCERT-PUBDOC-2010-12-001_0.pdf (26. 8. 2013)

Cole, T. (2007) IEEE *Std 802.11-2007, Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications*, New York, 2007.

Čerić, M., Birolla, H, Varga, M. (1998) *Poslovno računarstvo*, Zagreb: Znak, str 467.

CIS, http://www.cis.hr/www.edicija/LinkedDocuments/CCERT-PUBDOC-2003-02-05.pdf (11. 3. 2013.)

FER, http://os2.zemris.fer.hr/ns/wireless/2004_maric/wep.htm (7. 7. 2013)

Hamidović, H. (2009) *WLAN - Bežične lokalne računalne mreže*. Zagreb: Info press

EMC, http://www.emc.com/about/news/press/2008/20081027-03.htm (10. 2. 2013)

FER, http://os2.zemris.fer.hr/ns/wireless/2007_mercep/Seminar[2007]Mercep_Ljubo.htm (7. 7. 2013)

http://blog.g0tmi1k.com/2010/02/video-cracking-wifi-wpawpa2-aircrack-ng.html (7. 7. 2013)

http://www.cert.hr/sites/default/files/CCERT-PUBDOC-2009-06-267.pdf (7. 7. 2013)

http://www.fidis.net/resources/deliverables/hightechid/int-d37003/doc/12/ (7. 7. 2013)

Zbornik Veleučilišta u Rijeci, Vol. 2 (2014), No. 1, pp. 163-176

Aleksandar Skendžić [1]

Professional paper
UDC 004.7.056

SECURITY OF INFRASTRUCTURE MODE OF IEEE 802.11 WIRELESS NETWORK STANDARD[2]

ABSTRACT

Wireless networks are increasingly used today and have become the de facto standard for connecting computers while at the same time offering simple implementation with reduced costs, satisfactory bandwidth speeds and greater mobility of users. Wireless communication provides users with greater mobility, and therefore faster and easier access to sources of information. When talking about wireless local area networks, a particularly important issue is that of security. Wireless networks are the least secure part of the wired local area network (LAN) because they use air as the medium for transmission, and in so doing the network becomes available outside the organization in which it is used. Security algorithms (encryption) prevent the possibility of unauthorized use of the network, but they do not offer one hundred percent security. This paper will present an overview of security technologies regarding infrastructure mode of wireless network and make recommendations for secure mode. The paper provides an overview of the methods of infrastructure security with regard to the IEEE 802.11 WLAN standard.

Keywords: *wireless networks, IEEE 802.11, security, infrastructure mode*

[1] Mag. edu. inf. est. hist., Senior Lecturer, Polytechnic Nikola Tesla in Gospić, Bana Ivana Karlovića 16, Gospić, Croatia. E-mail: wireless82@gmail.com

[2] Received: 19. 2. 2014.; accepted: 5. 5. 2014.

Jasminka Tomljanović [1]
Marina Krsnik [2]
Mile Pavlić [3]

Stručni rad
UDK 007

SUSTAVI PITANJA I ODGOVORA[4]

SAŽETAK

Sustavi pitanja i odgovora su način pretraživanja informacija koji odgovara na pitanje postavljeno prirodnim jezikom. Sastoje se od triju glavnih komponenata: klasifikacija pitanja, pronalaženja informacija i izvlačenja odgovora. Uvođenjem velikih zajedničkih procjena, kao što je TREC konferencija, stvorene su snažne interesne zajednice i ubrzan napredak u istraživanju sustava pitanja i odgovora. U radu su prikazane domene problema odgovaranja na pitanja. Prikazan je povijesni razvoj sustava pitanja i odgovora od jednostavnijih, koji su bili usko specijalizirani, do današnjih, puno složenijih i kvalitetnijih sustava koji su sposobni dati nam kratke i sažete odgovore na pitanja iz raznih domena. Analizirani su sustavi prema namjeni. Dat je pregled dosadašnjih istraživanja o sustavima pitanja i odgovora. Definirana je opća arhitektura sustava pitanja i odgovora te analizirani aktualni pristupi u svakoj fazi arhitekture. Sustavi pitanja i odgovora još uvijek su u fazi razvoja i eksperimentiranja. Zaključeno je kako još uvijek najveći problem sustava pitanja i odgovora predstavlja odabir najtočnijeg i najsažetijeg odgovora s kojim će korisnik biti zadovoljan.

Ključne riječi: *sustavi pitanja i odgovora, TREC konferencija, arhitektura sustava pitanja i odgovora*

1. UVOD

Sustavi pitanja i odgovora ili tzv. *question – answering systems* (QAs) pronalaze točne i sažete odgovore na pitanja postavljena govornim jezikom (Hirschman et al., 2001). Izravno se odnose na pretraživanje informacija i obradu prirodnog jezika u okviru izgradnje sustava za automatsko odgovaranje na pitanja postavljena prirodnim jezikom. Za pronalaženje odgovora mogu koristiti strukturirane baze podataka, zbirke dokumenata na lokalnoj razini, interne dokumente poduzeća, mreže novinskih izvješća i internet. Glavni cilj jamstva kvalitete sustava je dati točne odgovore uz pomoć vlastite baze znanja. Istraživanja ovog područja bave se tipovima pitanja, uključujući činjenice, popise, definicije, semantička ograničenja i jezično neovisna pitanja.

[1] Mr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* jasminka.tomljanovic@veleri.hr
[2] Student, Odjel za informatiku, Sveučilište u Rijeci, Radmile Matejčić 2, Rijeka, Hrvatska. *E-mail:* marina.krsnik@inf.uniri.hr
[3] Dr. sc., redoviti profesor, Odjel za informatiku, Sveučilište u Rijeci, Radmile Matejčić 2, Rijeka, Hrvatska. *E-mail:* mile.pavlic@ris.hr
[4] Datum primitka rada: 16. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

Prvi QA sustavi razvijeni u 1960-ima su sustavi sa sučeljima na prirodnom jeziku za inteligentne sustave sa specifičnom domenom. Razvoj interneta obnovio je potrebu za istraživačkim tehnikama čiji je cilj smanjenje preopterećenosti informacijama. Tražilice vraćaju članke s fragmentima teksta svih dokumenata koji možda sadrže odgovor. Razvoj osiguranja kvalitete sustava nastaje kao pokušaj rješavanja preopterećenja s informacijama.

Zadaća ovog rada je analizirati razvoj QA sustava, a cilj je utvrditi njegov najveći problem.

Ostatak rada strukturiran je na sljedeći način. U točki 2. definiran je pojam QA sustava, dimenzije problema njihovog vrednovanja i metodologije konstruiranja odgovora. U točki 3. prikazan je povijesni razvoj QA sustava. Točka 4. daje pregled dosadašnjih istraživanja QA sustava. Prikaz generičke arhitekture QA sustava i analiziranje aktualnih pristupa u svakoj fazi je u točki 5. Rad završava zaključkom u točki 6.

2. POJAM QA SUSTAVA, DIMENZIJE PROBLEMA VREDNOVANJA QA SUSTAVA I METODOLOGIJA

Razvoj informacijskih tehnologija potiče potrebu korisnika za sustavima koji odgovaraju na pitanja. Raste potreba za sustavima koji omogućuju postavljanje pitanja koristeći svakodnevni govor ili tzv. *Natural Language (NL*) i dobivanje odgovora brzo i jezgrovito s najmanjom količinom konteksta. Današnji pretraživači mogu ponuditi liste dokumenata koji sadrže potencijalne odgovore, ali ne dostavljaju odgovore korisniku.

Rješenje tog problema su upravo QA sustavi. Oni su način pretraživanja informacija koji odgovara na pitanje postavljeno govornim jezikom. Pitanja mogu biti jednostavna poput činjenica, definicija i nabrajanja (*Koji je najviši vrh svijeta*?), ali isto tako mogu biti složena (*Kolika je učinkovitost antibiotika kod ljudi oboljelih od gnojne angine*?).

Uspjesi u ovom području postignuti su kao dio *Text Retrieval Conference* (TREC), tj. niza radionica čiji je zadatak prikupiti što više informacija iz različitih područja istraživanja te poduprijeti i potaknuti istraživanja na području QA sustava.

Za odgovor na pitanje sustav prvo mora analizirati problem koristeći kontekst. Pronalazi jedan ili više mogućih odgovora koje internetski izvor nudi i odgovor predstavlja u nekom odgovarajućem obliku. Najčešće je to popratni materijal koji korisniku odgovor čini razumljivim ili ga dodatno objašnjava.

Počevši 1999., TREC je započeo s ocjenjivanjem sustava koji odgovaraju na činjenična pitanja konzultirajući se s dokumentima TREC zbirke. Velik broj sustava uspješno je kombinirao pretraživanje informacija i obradu tehnike prirodnog jezika ili tzv. *Natural Language Processing (NLP)*.

Drugačiji pristup odgovaranju na pitanja omogućili su testovi za ocjenjivanje čitanja s razumijevanjem. Temelji se na sposobnosti sustava da odgovori na pitanje o određenom odlomku. Ti su testovi danas popularni za ocjenjivanje razumijevanja teksta učenika i

studenata, a kao rezultat daju osnovu za uspoređivanje performansi čovjeka i performansi sustava.

Konferencije (Seattle 2000), radionice i ocjene sustava prikazuju sve domene problema odgovaranja na pitanja. Dimenzije ovog problema mogu se promatrati s obzirom na: aplikacije, korisnike, vrste pitanja, vrste odgovora, ocjenjivanje i prezentiranje.

QA sustavi imaju brojne *aplikacije* koje možemo podijeliti s obzirom na izvor koji sadrži odgovore. To mogu biti strukturirane baze podataka, polustrukturirane baze (npr. polja za komentare u bazi) ili slobodan tekst.

QA aplikacije mogu se razlikovati i prema pretraživanju. Može biti pretraživanje nepromjenjivog skupa zbirki (koristi TREC za ocjenjivanje), pretraživanje *weba*, pretraživanje zbirke ili knjige (npr. enciklopedije) (Kupiec, 1993) ili pak pretraživanje samostalnog teksta, kao kod ocjenjivanja čitanja s razumijevanjem.

Te sustave možemo klasificirati kao neovisne i specijalizirane, s obzirom na njihovu domenu. Generalno gledajući, zbirke postaju sve veće i raznolikije i za očekivati je da pronalaženje odgovora postaje sve teže u takvim zbirkama. Istražitelji ovog područja smatraju kako je veća vjerojatnost da ćemo pronaći odgovor ako imamo više izvora iz kojih tražimo odgovore (Mann et al., 2001).

Korisnici mogu varirati od onih koji sustav koriste po prvi put do onih koji se sustavom koriste svakim danom. Različite skupine korisnika zahtijevaju različita sučelja, postavljaju različita pitanja i žele različite vrste odgovora. Za one koji se sustavom koriste prvi put važno je objasniti ograničenja sustava, kako bi znali kako interpretirati odgovore koje su dobili. Za stručne, ekspertne korisnike, poželjno je razviti i ažurirati model korisnika koji će korisnicima od velike količine informacija napraviti sažetak te im dostaviti točno one podatke koji ih zanimaju.

Još uvijek stručnjaci ne znaju kako predvidjeti što čini jedno pitanje težim od drugog. To je problem koji je osobito važan za testiranje obrazovne zajednice, gdje ispitivači moraju pripremiti i provjeriti standardizirane testove.

Pitanja možemo klasificirati na temelju tipa odgovora koji zahtijevaju. Postoje činjenična pitanja, subjektivna pitanja i sažetci.

Druga podjela pitanja odnosi se na da/ne pitanja, pitanja s upitnim riječima kao što su gdje, tko, što, kako, kada, koliko, zašto (*Tko je predsjednik Hrvatske? Koliko je težak slon?*), indirektni zahtjevi (*Htio bih posjetiti...*) i naredbe (*Nabroji sve hrvatske predsjednike*). Sve ih tretiramo kao pitanja, iako neka od njih prema formi zapravo to i nisu.

Neki sustavi ovise o pitanjima s upitnim riječima za traženje odgovora. Ako pitanje započinje upitnom riječi *tko*, sustav prepoznaje da odgovor zahtijeva osobu. Započinje li upitnom riječi *kada*, prepoznaje kako odgovor mora biti neko vrijeme. Takvi sustavi nerijetko nailaze na problem ako korisnik oblikuje pitanje kao naredbu (*Navedi ime prvog hrvatskog predsjednika*) (Pantel et al., 2012).

Postoje dokazi da su neke vrste pitanja teže od drugih. Npr. pitanja *kako* i *zašto* obično su teža jer zahtijevaju razumijevanje uzročno-posljedičnih veza i uglavnom se nalaze kao dijelovi rečenice ili čak kao samostalne rečenice (Hirschman, 1999).

Ako sustav dobro analizira vrstu odgovora koje očekuje, smanjit će količinu mogućih odgovora (Mann et al., 2001). Na određene vrste pitanja teže je odgovoriti ako vrsta odgovora nije dovoljno dobro definirana. Npr. pitanja koja započinju upitnom riječi *što* teška su jer daju vrlo malo ograničenje na vrstu odgovora (*Što se dogodilo? Što si vidio?*).

Odgovori mogu biti kratki, dugi ili čak popisi ili priče. Mijenjaju se ovisno o namjeni korištenja i namjeni korisnika. Ako korisnik želi objašnjenje odgovor će biti duži. Taj tip pitanja odmah implicira dug odgovor. Sukladno tome, ako korisnik postavi činjenično pitanje koje se odnosi na razumijevanje teksta (npr. *Tko je glavni lik u priči?*) odgovor će biti kratak, uglavnom jedna, dvije riječi ili kratka fraza.

Postoje različite metodologije koje konstruiraju odgovor. Jedna od njih je uz pomoć izlučivanja; rezanje i lijepljenje isječaka iz izvornog dokumenta koji sadrže odgovor. Druga metodologija odvija se putem generiranja. Tu se odgovor kombinira iz više rečenica ili više dokumenata. Međusobna povezanost izdvojenih dijelova odgovora može biti vrlo niska, što onda zahtijeva generiranje kako bi se ti dijelovi spojili u smislenu cjelinu.

Što čini odgovor dobrim? Je li dobar odgovor dug odgovor koji sadrži popratni tekst koji ga objašnjava? Kontekst je koristan ako sustav nudi više mogućih odgovora. Omogućava korisniku odabir najboljeg odgovora koji ne mora biti prvi ponuđen niti najbolje ocijenjen. U drugim slučajevima, kratki odgovori mogu biti puno bolji. Iskustva u *ocjenjivanju* odgovaranja na pitanja koja TREC iznosi pokazuju kako je lakše navesti duže dijelove koji sadrže odgovor u sebi nego samo navesti kratke segmente.

U stvarnim situacijama kada tražimo određene informacije postoji korisnik koji komunicira sa sustavom u stvarnom vremenu. Korisnik obično započinje općenitim pitanjem i sustav mu izbacuje odgovor direktno ili indirektno, vraćajući mu velik broj dokumenata. Korisnik tada sužava potragu, gdje se bavi nekom vrstom dijaloga sa sustavom. Olakšavanje takve komunikacije vjerojatno bi povećalo uporabljivost i zadovoljstvo korisnika. Ako sučelja imaju mogućnost za obradu govora i dijaloga, sustavi mogu koristiti govor kako bi pristupili određenim informacijama na internetu.

Do danas je malo toga napravljeno na sučeljima za odgovaranje na pitanja. Riječ je o malobrojnim sustavnim procjenama o tome kako najbolje *prezentirati* informaciju korisniku; koliko odgovora i koliko konteksta ponuditi te je li bolje ponuditi kompletan odgovor ili samo kratak odgovor s priloženim sažetkom ili naputkom.

3. POVIJESNI RAZVOJ QA SUSTAVA

U razdoblju od 1960. do 1965. razvoj QA sustava započinje i snažno se razvija (Simmons, 1965). Sustavi tog doba odgovaraju na razgovorna pitanja, pristupaju spremištu podataka te pokušavaju odgovoriti na pitanja iz tekstualnih izvora (enciklopedija).

Prvi najpoznatiji QA sustav je *Baseball* (Green et al., 1961). Odgovarao je na pitanja o utakmicama američke bejzbolske lige. Analizirao je pitanje koristeći lingvističko znanje u kanonskom obliku (korišteni za generiranje upita). Dobivenim upitom tražio je odgovor u bazi podataka o bejzbolu. S obzirom na način na koji se nosio sa sintaksom i semantikom pitanja imao je ograničenu domenu – odgovarao je samo na pitanja o bejzbolu. Bio je namijenjen prvenstveno kao sučelje strukturiranoj bazi podataka, a ne velikom skupu teksta i bio prvi od niza programa dizajniranih za pristup bazama koje sadržavaju tekst pisan u prirodnom jeziku. Cilj je bio omogućiti korisnicima komunikaciju sa sučeljem na njihovom vlastitom jeziku. Tako bi, umjesto korisnika, sučelje bilo zaduženo za pitanja, strukturu baze i sam prijevod.

Drugi je *Lunar*. Dizajniran je geolozima za postavljanje pitanja o mjesečevim stijenama i sastavu tla (Woods, 1973). Odgovarao je na pitanja tipa *Koja je prosječna koncentracija aluminija u stijenama*?. Uspješno je odgovorio na 90 % pitanja geologa koja su bila unutar njegove domene (Voorhees, Tice, 2000). Ograničen je na usko područje.

Zajednička karakteristika ovih sustava bila je baza podataka ili sustav znanja pisan ručno, a pisali su ih stručnjaci određenog područja. Koristili su tehnike slične tehnikama korištenim kod *Elize* i *Doctora*, prvih *chatterbot*[5] programa.

Slika 1. *Eliza*, *chatterbot* program

Izvor: https://www.google.hr/search?q=eliza+program&source=lnms&tbm=isch&sa=X&ei=xS7_UvnqCZTW4AS78oDwBA&ved=0CAcQ_AUoAQ&biw=1366&bih=572

Sljedeći je *SHRDLU*[6] (Winograd, 1972). Stimulirao je rad robota u svijetu igračaka i nudio je mogućnost postavljanja pitanja o stanju svijeta. Imao je ograničenu domenu i vrlo jednostavan svijet objašnjen kroz pravila fizike prenošena u računalni program.

[5] Program koji razgovara s korisnicima.

[6] Izvedeno od *etaoin shrdlu*; odnosi se na redoslijed 12 najčešće korištenih slova engleskog jezika koja su se nalazila u prva dva stupca pisaćih strojeva.

Slika 2. Demonstracija programa SHRDLU

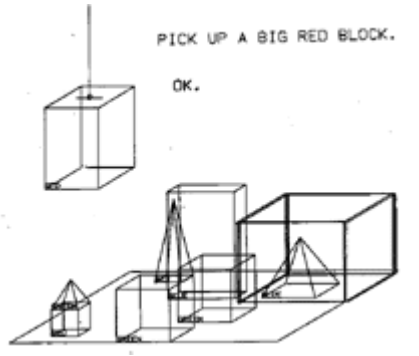

Izvor: http://hci.stanford.edu/~winograd/shrdlu/

Razvoj specijaliziranih baza znanja potiče QA sustave na razvoj sučelja ekspertnih sustava. Vrlo su slični današnjim modernim QA sustavima, s razlikom u arhitekturi. Oslanjaju se na stručno izgrađene i organizirane baze znanja, a moderni QA sustavi na statističke obrade velikih, nestrukturiranih tekstova prirodnog jezika.

Razvoj računalne lingvistike[7] donosi ambiciozne projekte na području tekstualnog razumijevanja i odgovaranja na pitanja, npr. *Unix Consultant;* spec. baza pod. *Unix OS* (Wilensky et al., 1984). Drugi je *LILOG*, sustav razumije tekst, radi s domenom turističkih informacija o njemačkom gradu. Nikad nisu dospjeli dalje od faze demonstracije, ali su pridonijeli razvoju teorija računalne lingvistike i zaključivanja.

3.1 Dijalog interaktivnih savjetodavnih sustava

Alan Turing predložio je testiranje inteligencije stroja kroz test razumijevanja razgovora (Turing, 1950). Test je zamislio s ispitivačem koji postavlja pitanja subjektu koji ne vidi, može biti osoba ili stroj. Ispitivač po odgovoru određuje je li odgovorio stroj ili osoba.

SHRDLU i *GUS* (Bobrow, 1977) razvijeni su za istraživanje razumijevanja problema u modeliranju ljudskog dijaloga. *SHRDLU* je stimulirao rad robota za pomicanje objekta, a *GUS* stimulirao savjetnika za putovanja. Jednostavni dijalozi bili su izazov i problemi rješavanja razvoja interaktivnog savjetodavnog sustava.

Rani QA interaktivni sustavi koriste strukturiranu bazu znanja koja im nije bila potrebna. Umjesto toga, bolje je koristiti zbirke tekstova, ali je važno naglasiti kako je odgovor u stvarnom vremenu neophodan za takve sustave. Npr. MIT-ev *Jupiter* sustav pruža telefonskim dijaloškim sučeljem informacije o vremenu. Sakuplja informacije o vremenu s različitih stranica na internetu. Ističe pragmatične probleme i probleme korisnika vidljive u izražavanju složenih zahtjeva i dobivanju točnih odgovora iz kompleksnog skupa podataka.

[7] Znanstvena disciplina koja se bavi razvojem kompjutorskih programa koji omogućavaju računalnu obradu prirodnog jezika.

3.2 Odgovaranje na pitanja i razumijevanje teksta

Najjednostavnija provjera razumijevanja teksta je postavljanje pitanja o tekstu. Odgovori li, tekst je shvatio, ne odgovori li, nije ga shvatio. Tehnika se već dugo koristi kod određivanja razine razumijevanja u učenju stranih jezika i otpočetka je prihvaćena kao prikladan način za testiranje sposobnosti sustava u razumijevanju prirodnog jezika.

U sustavu *QUALM* (Lehnert, 1977) ključna ideja je odmaknuti se od pristupa koji odgovaranje na pitanja shvaća kao ulaz u skroz odvojenu bazu ili proces vraćanja podataka, već kao proces koji odgovara i razumije pitanja. Razumijevanje i odgovaranje se oslanja na kontekst priče i pragmatični odabir prikladnog odgovora. Pitanje i tekst rastavljeni su s obzirom na konceptualnu ovisnost reprezentacije. Odgovaranje na pitanja nije samo proces usklađivanja tih reprezentacija. Interpretacija pitanja mora pripadati određenoj konceptualnoj kategoriji kao što su potvrda, zahtjev, uzročni prethodnik itd.

Takva klasifikacija pitanja nužna je za izbjegavanje odgovaranja na pitanja tipa *Znaš li koliko je sati*? s *Da*, ili *Kako je Marina napisala ispit*? s *Olovkom*. Daljnji zaključak treba biti donesen na temelju konteksta. Odgovaranja na pitanje, očekivanja koja priče mogu izazvati dok su pričane treba preoblikovati. Ako pročitamo *Ivan je naručio hamburger*. pretpostavlja se da ga je i pojeo. Ako se priča nastavi i dobijemo informaciju da je hamburger zagorio, pretpostavka više ne vrijedi. No ako priča ne sadrži činjenicu da hamburger nije pojeden i postavimo pitanje *Zašto Ivan nije pojeo hamburger*? nedavanje odgovora nije dovoljno dobro i nije nešto što bi čovjek napravio. Jedini ispravan odgovor bio bi *Zato što je hamburger zagorio*. Kako bismo došli do tog odgovora potrebno je preoblikovati očekivanja odgovora i odrediti što je u tekstu utjecalo na promjenu. Najvažnije je razumijevanje kao dinamički proces koji uključuje povezivanje svjetskog znanja i informacija doslovno preuzetih iz teksta.

Slika 3. WolframAlpha QA sustav

Izvor: http://www.wolframalpha.com/

Interes za ovu domenu smanjen je jer nije postojao opće prihvaćen način za ocjenjivanje sustava i samo ocjenjivanje poprimilo puno veću ulogu u metodologiji prirodnog jezika tijekom 90-ih godina. Testovi razumijevanja teksta nude rješenje tog problema; rješenje koje ima dodatnu prednost jer je dostupno za ljude i ne zahtijeva poseban trud za proizvodnju.

Istraživanja razumijevanja teksta pokazuju da odgovor na pitanje treba biti izveden iz nestrukturiranih tekstova, kao kod QA sustava. Pitanja mogu biti postavljena slijedno, gdje jedno pitanje proizlazi iz drugog (*Tko je bio američki predsjednik 1958? A 1960? ... Kojoj stranci je pripadao?*). Za razliku od otvorenog teksta kod odgovaranja na pitanja, tekst koji sadrži odgovor unaprijed je poznat. Velik broj pitanja o jednom tekstu zahtijeva detaljniju obradu tog teksta i rješavanje problema neusklađenosti koje donose slični ali nebitni tekstovi. Testovi koji ocjenjuju razumijevanje uzrokuju manju redundanciju, što dodatno otežava traženje lokacije odgovora.

3.3 Dohvat informacija, ekstrakcija informacija i odgovaranje na pitanje

Dohvaćanje informacija ili *Information Retrieval* (IR), je pronalaženje bitnih dokumenata kao odgovor na korisnički upit. Od sredine 1950-ih IR je područje aktivnog istraživanja (Spärck Jones Willett, 1997). Povezano je s odgovaranjem na pitanja jer korisnik kreira upit za pronalaženje odgovora. Sličnost tu uglavnom i završava. IR sustavi vraćaju dokumente, ne odgovore, na korisnicima je da sami izdvoje odgovore iz dokumenata. Upiti koje korisnici postavljaju IR sustavima ne moraju biti sintaktički oblikovani kao upitne rečenice, štoviše, to im može štetiti. Neprimjetne sintaktičke razlike, kao kod pitanja *Tko je ubio medvjeda?* i *Koga je ubio medvjed?* potpuno se gube u IR sustavima.

IR sustav nužan je za odgovaranje na pitanja iz dvaju razloga. Prvo, IR tehnike proširene su tako da ne vraćaju samo relevantne dokumente, nego i nebitne odlomke koji se nalaze u dokumentu. Veličina tih odlomaka može biti redovito smanjena, bar u teoriji, tako da u ograničenom broju slučajeva, ono što je izdvojeno je učinkovito, samo čist odgovor na pitanje. Drugo, IR zajednica tijekom godina razvila je iznimno temeljitu metodologiju za ocjenjivanje. Najpoznatija je godišnja TREC konferencija, čija je metodologija i zajednica zaslužna za nedavni razvoj ocjenjivanja QA-a.

Drugi dio istraživanja TREC-a odnosi se na ekstrakciju informacija ili *Information Extraction* (IE), u početku nazvano razumijevanje poruke. Može se definirati kao aktivnost popunjavanja unaprijed definiranih predložaka iz teksta prirodnog jezika, gdje su predlošci dizajnirani za sakupljanje informacija o ključnim ulogama u tipičnim događajima (Gaizauskas and Wilks, 1998). Uzmimo za primjer predložak koji sakuplja informacije o događajima neke korporacije. Predložak će imati praznine za kupnju tvrtke, stečenu tvrtku, datum kupnje, isplaćen iznos... Upravljanje IR sustavom za ispunjavanje predloška s velikim količinama teksta rezultirat će strukturiranom bazom informacija o korporativnim preuzimanjima. Ta baza može poslije biti korištena i za druge svrhe, kao što su upiti, pronalaženje znanja (*data mining*) i sažimanje. Predloške za IE možemo shvatiti kao izražavanje pitanja, a ispunjen predložak dio koji sadrži odgovor. IR je ograničen oblik odgovaranja na pitanja u kojem su pitanja (predlošci) statički, a baza iz koje se dobivaju odgovori proizvoljno velika zbirka tekstova. IR zajednica konstruirala je svoju vježbu za ocjenjivanje *Message Understanding Conferences* ili MUC koja je trajala od 1987. do 1998. Završetak MUC vježbe, razvoj tehnologije za razumijevanje jezika kroz vježbe ocjenjivanja, omogućio je TREC-u uvjete za ocjenjivanje odgovaranja na pitanja.

3.4 Logika pitanja i odgovora

Objašnjenje pojma „erotetička logika" nužno je za logiku pitanja (Hirschman, Gaizauskas, 2001). Erotetička logika je dio logike koji analizira pitanja kao logičke entitete koji se razlikuju od izjava. Erotetičku logiku često nazivaju logika pitanja. Zanimanje logičara bilo je usmjereno na dobar formalni zapis i skup razlika pojmova za istraživanje pitanja i odgovora.

Logika pitanja započinje pretpostavkom da je korišteni jezik jasno definiran i određen. Definirani su ključni pojmovi osnovnih pitanja (kondicionalna pitanja *ako* ili obična pitanja tipa *što, koji, koje...*) i direktni odgovori pokazuju kako službene definicije sadrže osnovne intuicije o osnovnim pitanjima i odgovorima na njih (Harrah, 1984; Belnap, Steel, 1976).

Nastavili su s istraživanjem složenijih oblika pitanja i odgovora, pretpostavki, učinkovitosti i cjelovitosti. Rezultat je skup potencijalno korisnog analitičkog alata za automatizirano odgovaranje na pitanja.

Logičare ne zanima izvedba odgovora na pitanja u praksi. Započinju s radom o računalnim odgovorima na logičke upite naspram logičkih baza podataka (Green, 1969). Govori se o korištenju rezolucijske teorije dokaza kako bi dobili instancu koja se nalazi u konstruiranju dokaza o postojećoj kvantificiranoj formuli što nas vodi do logičkog programiranja i deduktivne baze podataka[8].

4. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Najvažnija područja primjene QA su crpljenje informacija iz cijelog *weba*, *online* baza podataka i upiti na pojedinim *web*-stranicama. Trenutni QA sustavi koriste tekstualne dokumente kao temeljni izvor znanja i kombiniranjem različitih tehnika NLP-a traži se odgovor na pitanje korisnika (Allam et al., 2012). U cilju pružanja točnih odgovora korisnicima, QA sustavi moraju leksičko-sintaktičku analizu primijeniti na semantičku analizu i obradu tekstova i resursa znanja. QA sustavi opremljeni su sposobnošću zaključivanja i mogu izvući više adekvatnih odgovora za predstavljanje znanja i sustav zaključuje slično opisu logike i ontologije. Ontologija je osnovica QA sustava (Lopez et al., 2011), studija o prikazu uporabljivosti NL sučelja i NL upita preko ontologije na kojoj se temelji baza znanja za krajnjeg korisnika (Kaufmann et al., 2010). Autori su predstavili četiri sučelja koja omogućuju različite jezike za pretraživanje i predstavljaju komparativnu studiju o njihovoj uporabi. Zaključili su kako korisnici imaju jasnu prednost kod upita izraženih u NL-u i mali je skup izraza sastavljenih s nekim ključnim riječima ili neke formalne strukture.

Značajan broj sustava prikazanih u TREC ocjenjivanju u mogućnosti su uspješno kombinirati IR i tehnike NLP-a. QA sustavi mogu se pregledati kroz tri glavna pristupa: sustavi temeljeni na NLP-u, IR sustavi i sustavi temeljeni na definiranom predlošku pitanja-odgovor (Andrenucci et al., 2005). Autori su istakli njihove glavne razlike i primjenu konteksta koji je primjereniji za svaki sustav .

Suradnički QA sustav je automatizirani sustav u kojem je polazište unos upita, pokušava uspostaviti kontrolirani dijalog sa svojih korisnikom, odnosno, sustav automatski surađuje s korisnicima kod pronalaženja podataka koji se traže. Ovi sustavi pružaju korisnicima dodatne informacije, srednje odgovore, kvalificirane odgovore ili alternativne upite. Suradničko ponašanje uključuje povezane

[8] Relacijska baza podataka proširena deduktivnom komponentom.

informacije relevantne za upit. Generaliziranjem upita dobivaju se relevantne informacije. Sustavi za suradničko odgovaranje koriste automatsko identificiranje novih upita koji se odnose na izvorni upit (Gaasterland, 1997). Prilagodbom tehnike strojnog učenja definira se izvlačenje informacija za odgovore u QA sustavu (Jousse et al., 2005). Autori su identificirali specifičnosti sustava i testirali i usporedili tri algoritma, pod pretpostavkom apstrakcije NL tekstova. Semantički zastupljen formalizam posvećen suradničkim QA sustavima temelji se na konceptualnim i leksičkim strukturama i predstavlja homogene *web*-tekstove, NL pitanja i srodne odgovore (Benamara, 2008). Autor predstavlja i analizira neke od preduvjeta za izgradnju suradničkih odgovora, ovisno o resursima, znanju i procesima. U cilju jačanja suradničkih QA sustava, prikazan je skup tehnika za poboljšanje tih sustava i rasprava o potencijalnom utjecaju njihovog korištenja (Meguinness, 2004).

Suradnički odgovor [10,13] na NL pitanje je jedan neizravan odgovor koji je korisniku tada korisniji nego izravan i doslovan odgovor (Corella, Lewison, 2009). Suradnički odgovor može objasniti neuspjeh računanja rezultata i/ili predložiti pitanja za nastavak istraživanja. Suradnički odgovor može dostaviti dodatne informacije koje nije izričito zahtijevao korisnik i uklapaju se u kontekstu osiguranja kvalitete sustava te su motivirani željom za približavanje sustava za dijalog s korisnikom. Suradnička obrada odgovora humanizira sustav i omogućuje korištenje prilagođenog rječnika .

Autori de Sena i Furtado predlažu model QA sustava koji pokušava uspostaviti kontrolirani dijalog s korisnikom izvan korisničkog pitanja. U dijalogu, sustav ima svoj glavni cilj identificirati korisničko pitanje i predlože novo pitanje u svezi s korisničkim početnim pitanjem. Kontrolor dijaloga temelji se na konceptu strukture u bazi znanja, u ograničenjima domena i klimatizaciji posebnih pravilima. Prototip sustava koji vraća suradničke odgovore korigira pojmove koji nedostaju, namjerava zadovoljiti potrebe korisnika te koristi semantičke informacije baze podataka u svrhu dobivanja koherentnih i informativnih odgovora (Gaasterland, 1992 c). Glavne karakteristike leksičkih strategija govore kako odgovoriti na pitanja (Benamara et al., 2004 c). Autor predstavlja strategiju reproduciranja u izgradnji sustava osiguranja kvalitete posebno u inteligentnim suradničkim QA sustavima. Metoda traženja susjednih odgovora početnom pitanju korisnika može se koristiti za obradu odgovora koji mogu zadovoljiti korisničke potrebe i zahtjeve (Gaasterland, 1992 b).

Korištenje naprednog zaključivanja QA sustavima postavlja nove izazove za istraživače jer odgovori nisu samo izvađeni izravno iz teksta ili iz strukturirane baze podataka, nego su izgrađeni od nekoliko oblika zaključivanja s ciljem stvaranja i opravdanja odgovora. Integrirani mehanizmi koji zastupaju znanje i razmišljanje omogućiti će sustave koji predviđaju odgovor na pitanja koje se ne može naći u bazi znanja. Ti sustavi trebaju identificirati i objasniti lažne pretpostavke i druge vrste sukoba koji se mogu naći u pitanju (Melo et al., 2013).

Suradnički QA sustavi prikazuju se koristeći baze podataka kao izvor znanja (Minker, 1998). Benamara predlaže logiku izrade predložaka za generiranje namjernih i preciznih odgovora u suradničkim QA sustavima (Benamara, 2004 b). Sejid QA sustav i WEBCOOP integriraju predstavljanje znanja i tehnike zaključivanja kako bi potaknuli suradnju odgovora na pitanja koje postavlja NL na *webu* (Benamara, 2004 a). PowerAqua je multi-ontološki QA sustav (Lopez, Motta, 2006).

5. ARHITEKTURA QA SUSTAVA

Za podlogu shvaćanja stvarnog sustava korisna je generička arhitekturu za QA zadatak. Određeni sustavi tada se promatraju kao instanca općenite arhitekture s posebnim izborima reprezentacije i obrade za svaku komponentu cjelokupnog modela.

Slika 4 prikazuje opću arhitekturu za QA zadatak, zamišljenu kao postavljanje pitanja sustavu koji ima izvor znanja u obliku velike zbirke tekstova s naglaskom da neće svi QA sustavi koristiti sve komponente modela. Trenutni TREC QA sustavi ne koriste dijalog ili korisnički model a neki sustavi čak ne koriste funkcionalnost modela ili ih je presloženo preslikati u model. Ovaj model je koristan kako bismo dobili predodžbu o generičkoj arhitekturi QA zadatka. Sastoji se od sljedećih 6 faza:

1. Analiza pitanja
2. Predobrada zbirke dokumenata
3. Odabir potencijalnih dokumenta
4. Analiza dokumenata
5. Ekstrakcija odgovora
6. Odgovor.

Slika 4. Opća arhitektura QA sustava

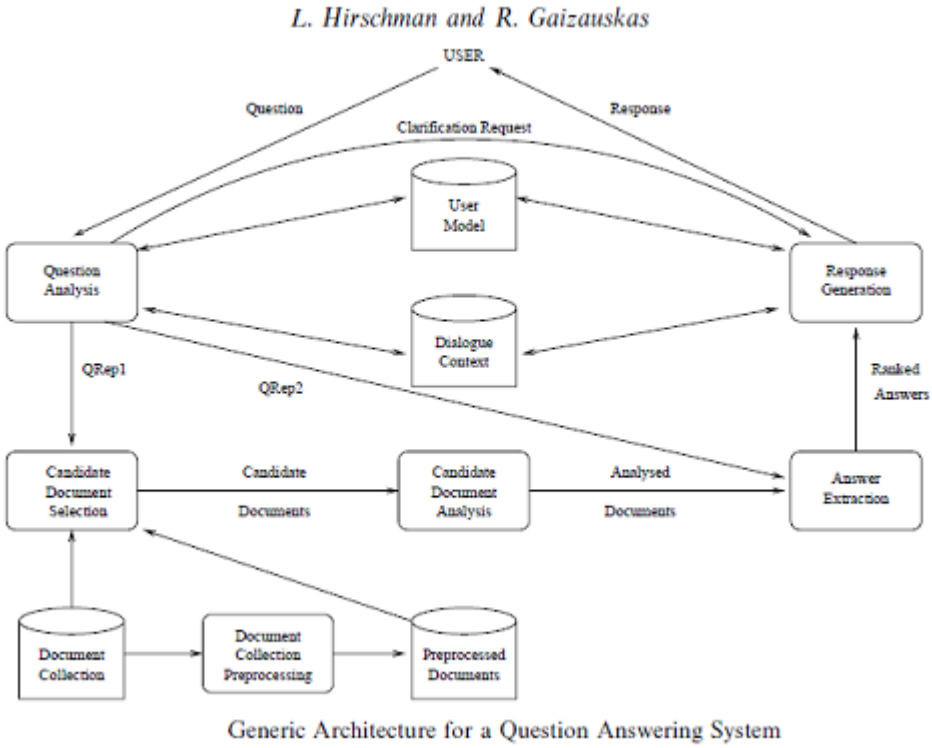

5.1 Analiza pitanja

Ulaz u ovoj fazi je pitanje prirodnog jezika. Prvo, moguća su ograničenja unosa i prirodnog jezika. Od korisnika se traži da koristi podskup prirodnog jezika, „kontrolirani jezik" koji ima ograničen vokabular i sintaksu (što je slučaj kod većine sučelja baza prirodnog jezika). Korisnik može biti prisiljen koristiti model sučelja koje sustavu značajno pojednostavljuje interpretaciju pitanja. Drugo, izravan unos pitanja može biti u obliku konteksta, u slučaju da sustav podržava kontinuirani dijalog. U pitanju može biti elipsa[9] ili anafora[10], što zahtijeva interpretaciju konteksta dijaloga. Drugi implicitni unos može biti znanje sustava o korisniku i njegovim ciljevima.

Izlaz ove faze je jedna ili više reprezentacija pitanja koje će se koristiti u daljnjim fazama. Mehanizam koji bira potencijalne dokumente u sljedećim fazama govori o IR sustavu i tada jedna reprezentacija pitanja može biti osnova, tj. usmjerivač za unos u tražilicu. Većina sustava koristi detaljniju analizu pitanja koja uključuje:

1. identifikaciju semantičkog tipa entiteta koje traži pitanje (datum, osoba, tvrtka...)
2. utvrđivanje dodatnih ograničenja na odgovor entiteta, npr.:
   a) identifikaciju ključne riječi u pitanju koja se koristi za odgovarajuću potencijalnu rečenicu koja sadrži odgovor ili
   b) identifikaciju odnosa, sintaktičkih ili semantičkih, koji postoje između entiteta koji su kandidat za odgovor i svih ostalih entiteta ili događaja spomenutih u pitanju.

Prvi korak odnosi se na traženje ključne upitne riječi (*kada* zahtijeva datum ili vrijeme, *gdje* lokaciju, *tko* osobu...). Samo to nije dovoljno, budući da razne upitne riječi, kao što su *koje* i *što* ne zahtijevaju određen tip informacije. Pitanja tipa „*Koja tvrtka..*?" ili „*Koja građevina...*?" vrlo su jednostavna dok su puno složenija pitanja koja uključuju sintaktički složenije konstrukcije kao što su „*Tko su bili Beatlesi?*", „*Koja je njihova prva pjesma?*" ili „*Koliko prvih nagrada iz informatike je dodjeljeno na Cambridgeu prošle godine?*"

Različiti sustavi imaju izgrađenu hijerarhiju tipa pitanja baziranu na tipu odgovora i pokušavaju svrstati postavljeno pitanje u odgovarajuću kategoriju hijerarhije. Ručno se gradi hijerarhija tipa pitanja od cca 25 tipova iz analize TREC podataka (Moldovan et al. 2000). Baziraju svoju hijerarhiju tipa pitanja na temelju MUC imenovanih klasa entiteta i koriste plitki parser[11] za identifikaciju tipa pitanja (Srihari, Li, 2000). Nazvan je upitna točka. Konstruiraju IR tipologiju sastavljenu od 47 kategorija baziranih na analizi 17 000 stvarnih pitanja, proširivši analizu na semantičke tipove doslovno zatražene klasificirajući pitanja kao što su „*Tko je otkrio Ameriku?*" na osobu i pitanja tipa „Tko *je bio Cristopher Columbus?*" na *zašto*-poznat (Hovy et al., 2001). Na 9. TREC konferenciji opisana se ručno napisana vrhunski rangirana hijerarhija tipa odgovora koja povezuje dijelove WordNeta[12] kako bi proširila skup mogućih tipova odgovora dostupnih svom sustavu (Harabaigu et al., 2001).

[9] Figura koja nastaje kad se iz rečenične cjeline izostavljaju pojedine riječi.
[10] Glasovna figura kojom se ponavljaju riječi na početku dvaju ili više stihova.
[11] Raščlanjivanja ili sintaktička analiza je proces analiziranja niza simbola, bilo u prirodnom jeziku ili računalnom
[12] Velika leksička baza engleskog jezika.

Identifikaciju tipa entiteta slijedi identifikacija dodatnih ograničenja s kojima se susreću entiteti koji odgovaraju opisu određenog tipa. Ovaj postupak vrlo je jednostavan, poput izlučivanja ključnih riječi od ostatka pitanja koje se usklađuju s potencijalnim rečenicama koje sadrže odgovore. Skupina ključnih riječi kasnije može biti proširena, koristeći sinonime i morfološke varijante (Srihari, Li, 2000) ili tehnikama potpunog proširenja upita, primjerice izdavanje upita temeljenog na ključnoj riječi iz enciklopedije i korištenje najbolje rangiranih ponuđenih odlomaka za proširenje skupa ključnih riječi. Postupak identifikacije ograničenja može uključivati parsiranje pitanja s gramatikama različite sofisticiranosti. Harabagiu koristi statički parser široke primjene čiji je cilj proizvesti potpune parsere. Sastavni dio analize koje pitanje proizvodi pretvara se u semantičku reprezentaciju koja bilježi zavisnosti između pojmova u pitanju. Koristi se otporan djelomični parser koji može odrediti gramatičke odnose u pitanju. Kada se ti odnosi povežu s identificiranim i traženim entitetom, prosljeđuju se kao ograničenja na koja treba računati tijekom ekstrakcije odgovora (Scott, Gaizauskas, 2001).

5.2 Predobrada zbirke dokumenata

Ako se na pitanja odgovara u stvarnom vremenu, predobrada teksta je nužna. Većina se TREC IR sustava oslanja na mehanizme koji indeksiraju[13] dokumente i nema predobrade. Odabir potencijalnog dokumenta oslonjenog na konvencionalnu tražilicu za prvi odabir dokumenata i prijevremeno spremanje analize svih tekstova čini 4. fazu ovog modela nepotrebnom.

Sustav može izgraditi cijele zbirke tekstova logičkog značenja prije izlučivanja odgovora. Primjer je *ExtrAns*[14] sustav (Molla et al.,1998). *ExtrAns* izvodi logičku reprezentaciju zbirke dokumenata unaprijed za svaki upit. Sustav koji dozvoljava plitku lingvističku obradu zbirke dokumenata unaprijed, jest sustav koji dohvaća informacije (Milward, Thomas, 2000). On prepoznaje imena entiteta, dijeli velike dokumente na dijelove a potom pohranjuje rezultate kao indeksirana ograničenja koja se mogu podudarati sa stvarnim vremenom korisnikove interakcije sa sustavom. Prager unaprijed obrađuje zbirku dokumenata i obilježava pojmove s jednom od 50 semantičkih oznaka koje su indeksirane tijekom procesa indeksiranja dokumenta (Prager, 2001). Katz izdvaja trostruke odnose izraza (oblik, subjekt, objekt) iz sintaktičke analize rečenice prirodnog jezika na *web*-stranicama. Iz toga gradi proširenu bazu kako bi potpomogao daljnjem odgovaranju na pitanja (Katz, 1997).

5.3 Odabir potencijalnih dokumenata

Većina postojećih TREC QA sustava koristi neki oblik uobičajene IR tražilice za odabir početnog skupa potencijalnih dokumenata s odgovorom. Prvo, treba odlučiti kakvu tražilicu koristiti, *bool*[15] ili rangirane odgovore. Unatoč tome što tražilice koje koriste rangirane odgovore daju bolje rezultate kod standardnog IR ocjenjivanja, neki TREC sudionici tvrde kako su *bool* tražilice prikladnije kod QA sustava (Moldovan et al.,2000).
Ako se koristi tražilica rangiranih odgovora, treba odlučiti kako će se koristiti vraćeni dokumenti, tj. koliko ih uzeti. Kod *bool* tražilica potrebno je riješiti problem ograničavajućeg

[13] Postupak u kojem informacijski sustav pregledava dokumente i katalogizira ih kako bi se omogućilo njihovo pretraživanje.

[14] An Answer Extraction System, sustav koji dohvaća odgovore.

[15] Pretraživanje u kojem se dodjeljuju vrijednosti (0 i 1 ili *true* i *false*) koje se onda uspoređuju.

broja vraćenih dokumenata. Drugo, tražilica može dopustiti preuzimanje odlomaka pa je potrebno postaviti različite parametre kao što je veličina paragrafa. U skladu s preuzimanjem, dijelovi teksta koji imaju istu temu mogu se koristiti za identifikaciju sukladnih dijelova teksta koji su kraći nego cijeli dokument i prema tome ih rangirati.

5.4 Analiza dokumenata

Odabrani potencijalni dokumenti ili paragrafi koji sadržavaju odgovor na pitanje mogu se podvrgnuti dodatnoj analizi. Ako je sustav već u potpunosti unaprijed obradio sve dokumente, ova faza nije potrebna. Najčešće, sustavi analiziraju odabrane dokumente koristeći identifikator imena entiteta koji prepoznaje i klasificira stringove od više riječi kao imena tvrtki, osoba, lokacija... Klase imena koja su identificirana trebale bi biti navedene u MUCu[16]. U mnogim slučajevima klase se proširuju kako bi uključile razne dodatne klase, kao što su proizvodi, adrese i mjere ili se predefiniraju i tako uključe podklase poput gradova, pokrajina i zemalja.

Tipično za ovu fazu je dijeljenje rečenica, označavanje dijelova govora i parsiranje (identificiranje skupine imenica, glagola...).

Opisan je QA sustav koji koristi plitku sintaktičku analizu za identificiranje pojmova s više riječi i njihove varijante u odabranom dokumentu (Ferret et al., 2001). Sustav koristi ponovno indeksiranje i ponovno rangiranje dokumenata prije usklađivanja s reprezentacijom pitanja. Neki sustavi idu dalje i obavljaju detaljniju sintaktičku analizu iza koje slijedi neka vrsta pretvaranja izvedene sintaktičke strukture u skup relacijskih ograničenja. Ograničenja su izražena logičkim izrazima ili relacijskim oznakama između odabranog pojma i izvorne rečenice.

Analiza pitanja najčešće koristi statistički parser široke primjene za prikaz ovisnosti rečenica u potencijalnom dokumentu koji sadrži odgovor. Nakon toga prikazuje se ovisnost logičkom reprezentacijom, kao što je učinjeno i s pitanjem.

5.5 Ekstrakcija odgovora

Usklađuje se prezentacija pitanja i potencijalnog teksta koji sadrži odgovor. Nastaje skup potencijalnih odgovora, rangiranih prema vjerojatnosti točnosti.

Sustavi koji analiziraju pitanje i očekivan tip odgovora, kao i neki skupovi dodatnih ograničenja, analizirat će potencijalni dokument ili dijelove tog dokumenta. Proces usklađivanja može zahtijevati da jedinica teksta iz potencijalnog dokumenta (možda rečenica, ako je odrađena podjela) sadrži string čiji se semantički tip poklapa s očekivanim odgovorom. Usklađivanje može biti tipa podvrgavanja (tumačeno kao hiponomi[17] u leksičkom sustavu kao što je WordNet) i ne treba biti ograničeno na identitet.

Nakon što je pronađena jedinica teksta koja sadrži očekivani tip odgovora, mogu se primijeniti na nju ostala ograničenja. Možemo ih shvatiti kao potpuna, te ako nisu zadovoljena kod određenog

[16] Niz radionica osnovanih da bi potaknule razvoj novih i boljih metoda izlučivanja informacija; http://en.wikipedia.org/wiki/Message_Understanding_Conference

[17] Riječ ili fraza čiji je sadržaj uključen u sadržaj nekog drugog pojma.

kandidata možemo ga odmah isključiti; ili kao povlastice koje se koriste za dodjeljivanje bodova kandidatu kod rangiranja odgovora. Značajne razlike između sustava postoje u smislu tipova ograničenja koja se koriste u ovoj fazi.

Nakon što je, primjerice, pronađen izraz točnog tipa odgovora u potencijalnom odlomku koji sadrži odgovor, taj se izraz izdvaja i pregledavaju se razne kvantitativne značajke kako bi se izračunao ukupan zbroj kojim će se taj izraz svrstati na ljestvicu ponuđenih odgovora (Harabagiu et al., 2000).

Za svaki se odlomak koji može sadržavati odgovor, a sadrži izraz koji je jednak tipu odgovora koji tražimo, izvodi ocjena. U konačnici te se ocjene računaju i uspoređuju kako bi se dobila ukupna rang ljestvica za sve potencijalne odgovore. Neki stručnjaci (Harabagiu et al., 2001) proširuju ovaj pristup koristeći algoritam strojnog učenja kako bi optimizirali linearno bodovanje koje kombinira značajke karakteristične za odgovor.

Može se izmijeniti redoslijed ovog općenitog postupka. Prvo se primijene ograničenja pitanja, zatim očekivani tip odgovora za rangiranje rečenica koji se nalaze u potencijalnim dijelovima teksta koji sadrže odgovor. Očekivani tip odgovora je filtar koji izdvaja odgovarajući dio iz odabranih rečenica. Za rangiranje rečenica koriste se značajke tipa: broj jedinstvenih ključnih riječi koje se nalaze u rečenici, redoslijed ključnih riječi u rečenici u usporedbi s redoslijedom u pitanju te podudaraju li se ključni glagoli (Srihari, Li, 2000).

Sustavi koji izdvajaju veće dokumente i prezentacije pitanja, npr. logičke oblike ili tekst obilježen sa semantičkim ili gramatičkim informacijama, mogu koristiti dodatna ograničenja kako bi ograničili proces usklađivanja. Primjer je sustav koji može identificirati logičke subjekte i objekte. On može točno odrediti *Jack Ruby* kao odgovor na pitanje *Tko je ubio Leeja Harveyja Oswalda?* iz rečenice *Ruby je ubio Oswalda, a Oswald je ubio Kennedyja*. Takva pitanja mogu biti problem kod nekih pristupa zbog preklapanja riječi.

Većina sustava koji koriste takva gramatička ograničenja imaju poteškoće jer je u tim slučajevima potrebno ograničenja promatrati samo kao povlastice koje nisu obvezne i kod njih dolazi do preklapanja riječi kada njihova ograničenja nisu primjerena.

5.6 Odgovor

Za QA ocjenjivanje jedini odgovor koji većina sustava stvara je rangirana lista najboljih 5 odgovora, svaki odgovor je tekst string od n bajtova (gdje je n = 50 ili n = 250) izdvojen iz jednog od tekstova iz zbirke dokumenata.

Ova vrsta odgovora je nedovoljna u stvarnim aplikacijama. Prvo, string od n bajtova izdvojen iz teksta uglavnom je gramatički neispravan i nečitljiv. Potreban je link na izvorni dokument kako bi omogućio lingvistički kontekst ili je potrebno preformulirati string kako bi bio razumljiv. Drugo, korisnici mogu željeti više ili manje dokaza, tj. konteksta za odgovor, ovisno o tome koliko korisnik vjeruje sustavu i koliko već zna o temi iz koje postavlja pitanje. Treće, odgovori mogu biti složeniji ili opsežniji nego što korisnik očekuje. Sustav je taj koji mora donositi odluku o tome treba li skratiti svoj odgovor te može li inicirati dijalog s korisnikom kako bi mogao donijeti odluku kako postupiti.

6. ZAKLJUČAK

Na temelju provedene analize povijesnog razvoja QA sustava zaključujemo kako im je razvoj išao od jednostavnih i specijaliziranih za usko područje do današnjih puno složenijih i kvalitetnijih sustava koji su sposobni dati kratke i sažete odgovore na pitanja iz različitih domena.

U programiranju ovakvih sustava stručnjaci se susreću s mnogim problemima, kao što su velike baze podataka, različiti tipovi korisnika, brojne vrste pitanja i odgovora. Upravo zbog toga najveći problem još uvijek predstavlja odabir najtočnijeg i najsažetijeg odgovora s kojim će korisnik biti zadovoljan.

Daljnja istraživanja sustava koji odgovaraju na pitanja ići će u smjeru proučavanja razvoja raznih tehnika ocjenjivanja odgovora s ciljem poboljšanja učinkovitosti sustava koji odgovaraju na pitanja.

LITERATURA

Allam, A., Haggag, M. (2012) „The Question Answering Systems: A Survey", International Journal of Research and Reviews in Information Sciences 2(3), 211-221

Andrenucci, A., Sneiders, E. (2005) „Automated question answering: Review of the main approaches", ICITA (1). pp. 514-519. IEEE Computer Society

Belnap, N. D. and Steel, T. B. (1976) „*The Logic of Questions and Answers*", Yale University Press, New Haven and London

Benamara, F. (2004a) „Cooperative question answering in restricted domains: the WEBCOOP experiment", Proceedings of the Workshop Question Answering in Restricted Domains, within ACL

Benamara, F. (2004b) „Generating intensional answers in intelligent question answering systems", Natural Language Generation (2), 11-20

Benamara, F. (2008) „A semantic representation formalism for cooperative question answering systems" Proceeding of Knowledge Base Computer Systems (KBCS)

Benamara, F., Saint-Dizier, P. (2004c) „Lexicalisation strategies in cooperative question-answering systems", Proceedings of the 20th international conference on Computational Linguistics. p. 1179. No. Cruse 1986 in COLING '04, Association for Computational Linguistics, Stroudsburg, PA, USA

Bobrow, D., Kaplan, R., Kay, M., Norman, D., Thompson, H. and Winograd, T. (1977) GUS, a frame driven dialog system. Artificial Intelligence, 8: 155-173.

Corella, F., Lewison, K. (2009, Oct) „A brief overview of cooperative answering", Journal of Intelligent Information Systems 1(2), 123-157

Ferret, O., Grau, B., Hurault-Plantet, M., Illouz, G. and Jacquemin, C. (2001) Terminological variants for document selection and question/answer matching. Proceedings Association for Computational Linguistics Workshop on Open-Domain Question Answering, pp. 46-53.

Gaasterland, T. (1997, Sep) „Cooperative answering through controlled query relaxation" IEEE Expert: Intelligent Systems and Their Applications 12(5), 48-59

Gaasterland, T., Godfrey, P., Minker, J. (1992a) „An overview of cooperative answering", Journal of Intelligent Information Systems 1(2), 123-157

Gaasterland, T., Godfrey, P. (1992b) „Relaxation as a platform for cooperative answering" Journal of Intelligent Information 1(3), 293-321

Gaasterland, T., Godfrey, P., Minker, J., Novik, L. (1992c) „A cooperative answering system", Logic Programming and Automated Reasoning, No. X, Springer, pp. 478-480

Green, B. F., Wolf, A. K., Chomsky, C. and Laughery, K. (1961) „BASEBALL: An automatic question answerer", Proceedings Western Joint Computer Conference 19, pp. 219-224

Harabagiu et al. (2001) „FALCON: Boosting knowledge for answer engines", Proceedings 9th Text Retrieval Conference (TREC-9), NIST Special Publication 500-249 (Available at: http://trec.nist.gov/pubs.html) (11. 1. 2014.)

Harrah, D. (1984) „The logic of questions", Gabbay, D. and Guenthner, F., editors, Handbook of Philosophical Logic, Vol. II, pp. 715-764, Reidel

Hirschman, L., & Gaizauskas, R. (2001) „Natural language question answering: The view from here" *Natural Language Engineering*, *7*(4), 275-300.

Hirschman, L., Light, M., Breck, E. and Burger, J. (1999) „Deep Read: A reading comprehension system", Proceedings 37th Annual Meeting of the Association for Computational Linguistics, pp. 325-332

Hovy, E., Gerber, L., Hermjacob, U., Junk, M. and Lin, C.-Y. (2001) „Question answering in Webclopedia", Proceedings 9th Text Retrieval Conference (TREC-9), NIST Special Publication 500-249 (Available at: http://trec.nist.gov/pubs.html) (11. 1. 2014.)

Jousse, F., Tellier, I., Tommasi, M., Marty, P. (2005) „Learning to extract answers in question answering: Experimental studies", In CORIA (p. 85)

Katz, B. (1997) „From sentence processing to information access on the world wide web", Proceedings American Association for Artificial Intelligence (AAAI) Spring Symposium on Natural Language Processing for the World Wide Web, Stanford University, Stanford CA (Available at: http://www.ai.mit.edu/people/boris/webaccess/) (11. 1. 2014.)

Kaufmann, E., Bernstein, A. (2010, Nov) „Evaluating the usability of natural language query languages and interfaces to Semantic Web knowledge bases", Web Semantics: Science, Services and Agents on the World Wide Web 8(4), 377-393

Kupiec, J. (1993) „Murax: A robust linguistic approach for question answering using an online encyclopedia", roceedings Assocition for Computing Machinery Special Interest Group on Information Retrieval (ACM-SIGIR) '93, pp. 181-190. Pittsburgh, PA

Lehnert, W. G. (1977) „*The Process of Question Answering*", (No. RR-88). YALE UNIV NEW HAVEN CONN DEPT OF COMPUTER SCIENCE

Lehnert, W. G. (1977, August) „A conceptual theory of question answering" In *Proceedings of the 5th international joint conference on Artificial intelligence-Volume (1),* pp. 158-164, Morgan Kaufmann Publishers Inc.

Light, M., Mann, G. S., Riloff, E., & Breck, E. (2001) „Analyses for elucidating current question answering technology", *Natural Language Engineering*, *7*(4), 325-342

Light, M., Mann, G. S., Riloff, E., & Breck, E. (2001) „Analyses for elucidating current question answering technology", *Natural Language Engineering*, *7*(4), 325-342

Lin, J. (2002) „The Web as a resource for question answering: Perspectives and challenges", Proceedings of the Third International Conference on Language Resources and Evaluation. pp. 2120-2127. No. Lrec, Citeseer

Lopez, V., Motta, E. (2006) „Poweraqua: Fishing the semantic web", Semantic Web: Research and Applications

Lopez, V., Uren, V., Sabou, M., Motta, E. (2011) „Is question answering fit for the semantic web?: a survey", Semantic Web, 2(2), 125-155

Maybury, M. (2004) „New directions in question answering", Elements, pp. 533-558

Mcguinness, D.L. (2004) „Question Answering on the Semantic Web", IEEE Intelligent Systems pp. 6-9

Melo, D., Pimenta Rodrigues, I., & Beires Nogueira, V. (2013) „A Review on Cooperative Question-Answering Systems"

Milward, D. and Thomas, J. (2000) „From information retrieval to information extraction", Proceedings Assocition for Computational Linguistics (ACL) Workshop on Recent Advances in Natural Language Processing and Information Retrieval (Available at: http://www.cam.sri.com/html/highlight.html) (18. 1. 2014.)

Minker, J. (1998) „An overview of cooperative answering in databases", Flexible Query Answering Systems pp. 282-285

Moldovan et al. (2000) „LASSO: A tool for sur_ng the answer net", Proceedings 8th Text Retrieval Conference (TREC-8), NIST Special ublication 500-246 (Available at: http://trec.nist.gov/pubs.html) (13. 1. 2014.)

Molla Aliod, D., Berri, J. and Hess, M. (1998) „A real world implementation of answer extraction", Proceedings 9th International Conference on Database and Expert Systems Applications Workshop `Natural Language and Information Systems' (NLIS'98), pp. 143-148

Pantel, P., Lin, T., & Gamon, M. (2012) „Mining entity types from query logs via user intent modeling", In *Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics: Long Papers-Volume (1)*, pp. 563-571

Prager, J. (2001) „One search engine or two for question answering", Proceedings 9th Text Retrieval Conference (TREC-9), NIST Special Publication 500-249 (Available at: http://trec.nist.gov/pubs.html) (11. 1. 2014.)

de Sena, G.J., Furtado, A.L. (1998) „Towards a cooperative question-answering model", Flexible Query Answering Systems 1495, 354-365

Scott, S. and Gaizauskas, R. (2001) „University of Shefield TREC-9 Q & A System", Proceedings 9th Text Retrieval Conference (TREC-9), NIST Special Publication (Available at: http://trec.nist.gov/pubs.html) (11. 1. 2014.)

Simmons, R. F. (1965) „Answering English questions by computer: a survey", *Communications of the ACM*, *8*(1), 53-70.

Sparck Jones, K. and Willett, P., editors. (1997) „*Readings in Information Retrieval*" Morgan Kaufmann, San Francisco, CA

Srihari, R. and Li, W. (2000) „Information extraction supported question answering", Proceedings 8th Text Retrieval Conference (TREC-8), NIST Special Publication 500-246 (Available at: http://trec.nist.gov/pubs.html) (11. 1. 2014.)

Turing, A. (1950) „Computing machinery and intelligence", Mind, 59(236): 433-460.

Voorhees, E. M., & Tice, D. M. (2000, July) „Building a question answering test collection", In *Proceedings of the 23rd annual international ACM SIGIR conference on Research and development in information retrieval* (pp. 200-207), ACM

W. A. Woods (1977) „Lunar rocks in natural english: Explorations in natural language question answering", In A. Zampolli, editor,Lingusitic Structures Processing, volume (5) of Fun-damental Studies in Computer Science, pages 521–569, North Holland,

Wilensky, R., Arens, Y., & Chin, D. (1984) „Talking to UNIX in English: an overview of UC", *Communications of the ACM*, *27*(6), 574-593

Winograd, T. (1972) *Understanding Natural Language,* Academic Press, New York

Woods, W. (1973) „Progress in natural language understanding - an application to lunar geology" American Federation of Information Processing Societies (AFIPS) Conference Proceedings, 441-450

Jasminka Tomljanović [1]
Marina Krsnik [2]
Mile Pavlić [3]

Professional paper
UDK 007

QUESTION ANSWERING SYSTEMS[4]

ABSTRACT

The question answering systems are a way of information retrieval that responds to the question asked in natural language. They consist of three main components : question classification, information retrieval and response extraction. The implementation of large-scale joint assessments such as TREC conference, has created a powerful interest community and accelerated the progress in the study of question answering systems. This paper presents the problem domains in answering questions. It reviews the historical development of the question answering systems, from the simplest highly specialized ones to the present more sophisticated and higer quality systems that are able to give us short and concise answers to questions belonging to a variety of domains. The systems are analyzed according to the purpose. The paper provides an overview of previous research on question answering systems. It defines the general architecture of question answering systems and analyzes current approaches to every phase of architecture. The question answering systems are still under development and experimentation. In conclusion, the selection of the most accurate and the most concise response that will satisfy the user, still remains the largest problem in question answering systems.

Keywords: *question answering systems, TREC conference, arhitecture for question answering systems*

[1] MSc, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: jasminka.tomljanovic@veleri.hr
[2] Student, Department of informatics, University of Rijeka, Radmile Matejčić 2, Rijeka, Croatia. E-mail: marina.krsnik@inf.uniri.hr
[3] PhD, Full Professor, Department of informatics, University of Rijeka, Radmile Matejčić 2, Rijeka, Croatia. E-mail: mile.pavlic@ris.hr
[4] Received: 16. 2. 2014.; accepted: 5. 5. 2014.

Vedran Harmadi [1]
Marin Kaluža [2]
Dijana Liverić [3]

Stručni rad
UDK 004.928:004.73852

USPOREDBA TEHNOLOGIJA PRIKAZA ANIMACIJA U RAZLIČITIM *WEB*-PREGLEDNICIMA[4]

SAŽETAK

U radu se provodi analiza često korištenih tehnologija za prikaz animacija u web-*preglednicima. Flash je jedna od tehnologija koja je značajno pridonijela prikazu i mogućnostima izrade* web-*animacija, te se u počecima najviše koristila za njihovu izradu. Kroz godine pojavile su se mnoge nove tehnologije, od kojih se posebice može izdvojiti HTML5 canvas, koja omogućuje prikaz animacija bez uporabe dodataka, te mnoge nove mogućnosti njihove izrade. Ovim radom želi se pokazati koja od promatranih tehnologija ostvaruje najbolje performanse prilikom izvođenja animacija u različitim* web-*preglednicima. U radu se ispituju performanse izvođenja Flash, HTML5 canvas, SVG i JavaScript animacija unutar* web-*preglednika Firefox, Safari, Opera i Chrome. Broj prikazanih okvira u sekundi, vrijeme učitavanja okvira, opterećenje procesora, korištenost memorije i veličina datoteke su performanse koje su mjerene kod izvođenja animacija unutar različitih* web-*preglednika. Radom su objašnjene promatrane tehnologije za izradu* web-*animacija. Prikazan je izvorni kod mjernog instrumenta testiranja. Izvršeno je testiranje izvođenja animacija po promatranim tehnologijama.*

Ključne riječi: *performanse, Flash, HTML5 canvas, SVG, JavaScript*

1. UVOD

Često se za način prikaza sadržaja kroz *web*-tehnologije koriste dvodimenzionalne animacije (*web*-animacije). Postoje razne tehnologije izgradnje takvih animacija.

Za izgradnju *web*-animacija u velikoj mjeri koristi se Flash tehnologija, koja je donijela mnogo novih mogućnosti za prezentaciju sadržaja na internetu. Flash tehnologija nastala je kako bi se tekst, slika i zvuk lakše strukturirali i prezentirali putem *web*-preglednika.

Osnovne *web*-tehnologije Skalarna vektorska grafika (engl. *Scalable Vector Graphics,* SVG), Javascript i HTML5 također omogućuju prikaz animacija i mogu se koristiti za izgradnju *web*-animacija.

Koja tehnologija omogućuje najbolje performanse izvođenja *web*-animacija? U radu se ispituju performanse izvođenja animacija Flash, SVG, JavaScript i HTML5 canvas unutar različitih *web*-preglednika. Testirani su parametri koji utječu na performanse izvođenja *web*-animacije, a to su:

[1] Bacc. ing. comp. *E-mail:* vedranharmadi@gmail.com
[2] Mr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* mkaluza@veleri.hr
[3] Asistent, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* dliveric@veleri.hr
[4] Datum primitka rada: 19. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

opterećenje procesora, korištenost memorije, veličina datoteke, broj prikazanih okvira u sekundi, vrijeme učitavanja okvira.

Opisane su pojedine tehnologije koje su primijenjene za izradu različitih tipova animacija. Opisani su tipovi testiranih animacija i postupak njihove izrade. Prikazana je funkcionalnost aplikacije koja je izgrađena za potrebe mjerenja.

Web-animacije, odnosno računalne animacije koje se izvršavaju direktno u *web*-pregledniku pogodnije su (brže, manje opterećuju resurse računala) od animacija koje koriste posrednički softver. To će se pokazati mjerenjem performansi izgrađenim *web*-animacijama u prije navedenim tehnologijama. Analizom 4 tehnologije za izradu *web*-animacija pokazat će se koja od njih daje najbolje rezultate po mjerenim parametrima.

2. OPIS TEHNOLOGIJA ZA IZRADU WEB-ANIMACIJA

Za izradu *web*-animacija postoje mnogobrojne tehnologije koje se danas koriste. Svaka od tih tehnologija ima svoje područje gdje se i zašto se koristi, kao i svoje prednosti i nedostatke. U nastavku će biti prikazane tehnologije koje su u ovom radu primijenjene za izradu *web*-animacija i nad kojima se provodilo testiranje.

2.1 Adobe Flash

U svojim počecima Flash je bio usmjeren i koristio se za izradu animacija i jednostavnih *web*-aplikacija koje su uključivale neke jednostavne igre, reklame i slično. Danas Flash predstavlja standard multimedijskog prikaza na internetu, koji dizajneri koriste za izradu različitih *web*-sadržaja (Carnet Cert, 2009).

Adobe Flash je multimedijska tehnologija koja se već duže vrijeme koristi za izradu animacija, reklama, *web*-navigacije i raznih drugih elemenata *web*-stranica, za integraciju videa i/ili zvuka u *web*-stranici, a u posljednje vrijeme za izradu multimedijski bogatih *web*-aplikacija, poput igara. Isto tako Flash može manipulirati vektorskom i raster grafikom, te podržava dvosmjerno emitiranje zvuka i videa (Kovačević, 2009).

Za izradu i manipulaciju objektima animacije Flash koristi ActionScript skriptni jezik koji je sličan jezgri JavaScript programskog jezika, koji omogućava dodavanje kompleksnih interakcija, kontrolu *playbacka* i podatkovni prikaz. ActionScrpit, kao i ostali skriptni jezici, slijedi svoja pravila sintakse i ključnih riječi, koristi vlastite stvorene objekte i funkcije te dopušta kreiranje novih objekata i funkcija (Kovačević, 2009).

Adobe Flash tehnologija svojom je pojavom značajno pridonijela bogatstvu multimedijskog sadržaja na internetu, te omogućila dizajnerima više mogućnosti za kreativni prikaz. S obzirom na to da Flash tehnologija ima podršku u većini „desktop" operacijskih sustava, na svim sustavima jednako se prikazuje, odnosno ima jednako ponašanje.

Nedostatak Flash tehnologije jest da za prikazivanje njegovog sadržaja korisnici moraju imati instaliranu jednu od verzija Flash čitača. Isto je tako velik nedostatak veličina datoteke u Flash

formatu te njezino dugo učitavanje kroz *web*-preglednik. Flash slabije podržavaju mobilni *web*-preglednici (Brekalo, Horvatić, 2013).

2.2 SVG

SVG (engl. *Scalable Vector Graphics*) jezik je koji opisuje dvodimenzionalnu vektorsku grafiku unutar XML dokumenta. SVG crta grafičke oblike koristeći objekte kojima je moguće posebno promijeniti vrijednost pojedinog atributa. SVG je neovisan o rezoluciji ekrana, što znači da zumiranjem ili promjenom veličine objekata slika neće gubiti na kvaliteti (W3C, 2002).

W3C definira specifikaciju SVG-a, a format zapisa bazira se na već standardiziranom XML formatu. SVG se prema XML-u odnosi kao i XHTML prema XML-u, tj. definirana su pravila i sintaksa jezika koja u potpunosti prate XML specifikaciju, odnosno baziraju se na njoj.

SVG specifikacija je otvoreni standard koji se razvija od 1999. godine. Današnji moderni *web*-preglednici omogućuju osnovnu podršku za SVG, te se uz JavaScript biblioteke danas češće koriste.

SVG sadržaj može biti interaktivan i dinamičan. Animacije se mogu definirati postavljanjem svojstava SVG elemenata ili JavaScript programskim kodom (W3C, 2011).

SVG za sada omogućuje prikaz samo 2D elemenata i transformacija nad njima, no uz pomoć CSS3 standarda moguće je raditi i 3D transformacije. SVG sadrži unaprijed definirane elemente koji predstavljaju određene oblike. Svaki od elemenata je objekt s vlastitim atributima čije se vrijednosti zadaju prilikom crtanja (Pap, Pavazza, 2012).

SVG je jezik koji je primarno namijenjen za primjenu na internetu i koji je prihvaćen u gotovo svim internetskim preglednicima. Osim vektorske grafike SVG podržava prikaz rasterskih slika te pretraživanje datoteka, kao i mogućnost indeksiranja sadržaja internetskim tražilicama. S obzirom na vektorski format, idealan je za prikaz modernih računalnih ikona.

Najčešći nedostatak je iscrtavanje SVG datoteke kompleksnog vektorskog sadržaja koje može potrajati vremenski dugo te pritom usporiti rad internetskih preglednika (Baotić, 2009).

2.3 HTML5 Canvas

HTML5 je sljedeća generacija HTML-a koja podržava nove značajke potrebne modernim *web*-aplikacijama. On ujedno standardizira mnoge značajke *web*-platforme koje *web*-programeri već godinama koriste, ali još nisu službeno odobrene ili dokumentirane pri standardizacijskoj komisiji. HTML5 je kolekcija pojedinačnih značajki (crtaća površina, video ili geolokacija). HTML5 definira crtaću površinu, odnosno element canvas kao rastersku površinu za crtanje ovisnu o rezoluciju koja se može koristiti za iscrtavanje grafova, grafike igara i drugih slika tijekom izvršavanja (W3C, 2013). Crtaća površina je pravokutnik na stranici po kojem je moguće pomoću JavaScript programskog jezika nacrtati razne oblike. HTML5 definira skup funkcija za crtanje oblika, definiranje staza, izradu gradijenata i primjenu transformacija (Pilgrim, 2010).

Canvas je element koji je izvorno podržan unutar *web*-preglednika i dio je objektnog modela dokumenta (engl. *Document Object Model*, DOM) (Hickson, 2014). Canvas

predstavlja revolucionarnu mogućnost dinamičkog generiranja sofisticirane grafike na klijentskoj strani, odnosno *web*-pregledniku. Razvio ga je Apple za implementaciju Dashboard *widgeta* i poboljšanje grafike u Safari pregledniku (Smith, 2005). Za razliku od nekih drugih tehnologija, kao što je primjerice Flash, za upotrebu canvas elementa nisu potrebne dodatne biblioteke, već je potreban HTML5 kompatibilan *web*-preglednik i uređivač teksta (Williams, 2011).

S obzirom na korištenje određene značajke HTML5 standarda potrebno je ispitati njezinu podršku, odnosno provjeriti sadrži li pojedini internetski preglednik podršku za korištenje određene značajke (Pilgrim, 2010). Svaki objekt koji se nalazi unutar canvas elementa strogo je definiran brojem i pozicijom piksela, što znači da je canvas ovisan o rezoluciji. Canvas se koristi za izradu zahtjevnijih grafičkih aplikacija, npr. igara, jer omogućuje brzo iscrtavanje složenijih scena (Pilgrim, 2010).

Canvas element omogućuje izradu naprednih grafičkih aplikacija bez potrebe za priključcima. Ova tehnologija dobiva sve veću podršku u svim modernim *web*-preglednicima, pri čemu se smanjuje potreba za priključcima (Sucan, 2009).

2.4 JavaScript

JavaScript je kompaktan skriptni jezik za razvoj internetskih aplikacija klijent-server. Programski kod upisuje se direktno u HTML stranicu i omogućuje izradu dinamičnih *web*-stranica. Postoje različite JavaScript biblioteke, pri čemu se njezina funkcionalnost može generalno podijeliti u tri osnovne kategorije (Deković, 2008):

- DOM (engl. *Document Object Model*) pristup i manipulacija sadržajem *web*-stranice
- jednostavnije i brže programiranje zbog već ugrađenih funkcionalnosti
- proširivanje funkcionalnosti stranica pomoću gotovih komponenti.

Različiti internetski preglednici mogu različito interpretirati JavaScript naredbe. Neki preglednici imaju podršku za metode i događaje koji nisu u skladu s *web*-standardima. Ako se skripte s takvim nestandardnim metodama izvode na preglednicima koji poštuju standarde, neće se moći izvršiti.

JavaScript skriptni jezik razvila je tvrtka Netscape čiji je *Web*-preglednik Netscape Navigator s udjelom od čak 90 %, bio dominantan na tržištu devedesetih godina prošlog stoljeća (Čačić, 2012).

JavaScript skriptni jezik omogućuje izmjenu sadržaja *web*-stranice bez njezinog ponovnog učitavanja, te time čini *web*-stranicu dinamičnom (Flannagan, 1997).

Kao i ostali skriptni jezici, JavaScript je brz jer se čita red po red. Provođenje JavaScript naredbi započinje odmah, jer JavaScript za svoje izvođenje ne zahtijeva vezu s poslužiteljem.

3. IZRADA I PRIKAZ WEB-ANIMACIJA

Pojam animacije podrazumijeva brzo prikazivanje niza 2D ili 3D slika modela postavljenih tako da stvaraju privid pokreta. Ostvaruje se prikazom nacrtanih objekata u različitim položajima u svakom okviru, pa izgleda kao da se objekt miče kad se okviri izmjenjuju određenom brzinom. Animacija je moguća zbog tromosti oka. Objekt koji je oko vidjelo ostaje zapamćen još nekoliko trenutaka nakon gledanja.

Neki tipovi animacija su:

- animacija po stazi - objekt se pomiče po zadanoj stazi i pritom ne mijenja svoj oblik, već samo položaj
- animacija s različitim kadrovima - animacija počinje prvim ključnim kadrom i završava posljednjim ključnim kadrom koji mogu, ali i ne moraju biti jednaki. Između prvog i posljednjeg kadra prelazi se postupno, crtanjem odgovarajućeg broja međukoraka po zadanom putu.
- animacija preobražavanjem - računalni program generira međuslike, pa se jedna slika pretvara u drugu.

Za svaki prethodno navedeni tip animacije izrađene su identične animacije, animacije s istim tijekom izvođenja, pomoću Flash, SVG, HTML5 canvas i JavaScript tehnologija. Skriptni jezici koji su primijenjeni kod izrade animacija su JavaScript i ActionScript, pri čemu je JavaScript primijenjen za izradu SVG, HTML5 canvas i JavaScript animacija, dok je ActionScript primijenjen za izradu Flash animacija.

3.1 Animacija po stazi

Animacija po stazi koncipirana je tako da se oblik kvadrata kreće po određenoj stazi. Oblik kvadrata definiran je vrijednostima visinom i širinom 200 piksela, dok je staza po kojoj se oblik kvadrata kreće definirana vrijednostima visinom 20 piksela i širinom 1200 piksela. Vrijednost pomaka kvadrata po stazi povećava se svakih 5 milisekundi za 1 piksel. Na slici 1 prikazana je izrađena animacija po stazi s različitim vrijednostima pomacima, odnosno pozicijama oblika kvadrata.

Slika 1. Prikaz animacije po stazi

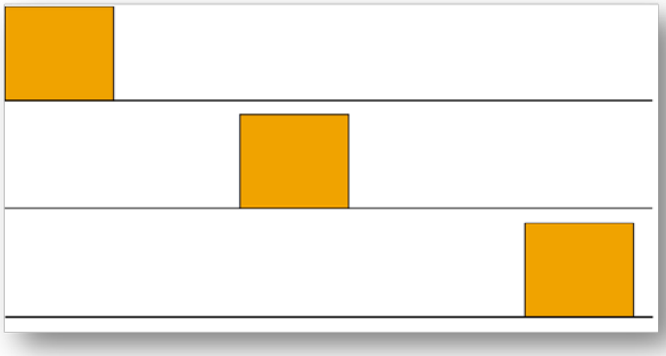

Izvor: obrada autora

3.2 Animacija s različitim kadrovima

Animacija s različitim kadrovima provodi se tako da se tijekom izvođenja animacije vrši promjena vrijednosti položaja, dimenzije, boje i vidljivosti oblika kvadrata. Oblik kvadrata definiran je vrijednostima, visinom i širinom 50 piksela. Tijekom prvog dijela izvođenja animacije, odnosno prvih 2500 milisekundi vrši se promjena vrijednosti položaja, dimenzije i vidljivosti kvadrata, dok se u drugom dijelu, odnosno drugih 2500 milisekundi, vrši promjena vrijednosti vidljivosti broja oblika kvadrata. Na slici 2 prikazana je izrađena animacija s različitim kadrovima.

Slika 2. Animacija s različitim kadrovima

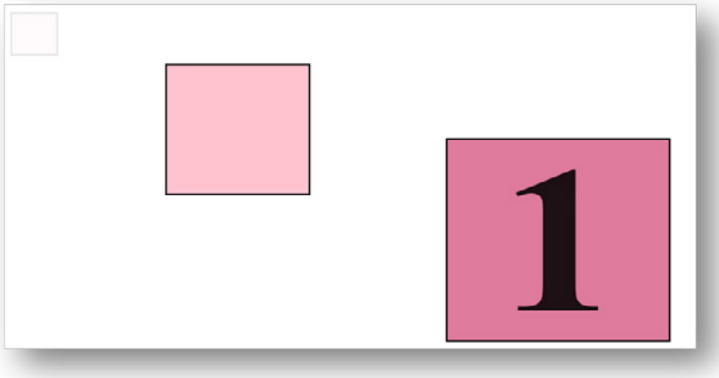

Izvor: obrada autora

3.3 Animacija preobražavanjem

Animacija preobražavanjem koncipirana je tako da se tijekom izvođenja animacije oblik kvadrata pretvori u oblik kruga. Oblik kvadrata definiran je vrijednostima visinom i širinom 200 piksela. Tijekom izvođenja animacije vrši se promjena vrijednosti boje, rotacije i zaobljenosti ruba oblika kvadrata. Na slici 3 prikazana je izrađena animacija preobražavanjem s različitim prikazom promjena oblika kvadrata.

Slika 3. Animacija preobražavanjem

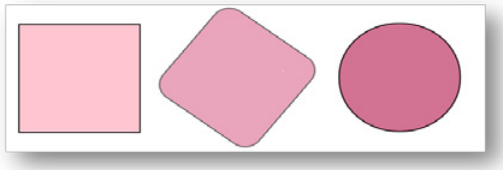

Izvor: obrada autora

4. MJERNI INSTRUMENTI TESTIRANJA

Za pokretanje animacija u različitim *web*-preglednicima te prikupljanje i obradu mjernih podataka izrađena je desktop aplikacija pomoću alata Microsoft Visual Studio. Aplikacija za testiranje omogućuje:

- odabir datoteke animacije nad kojom se želi provesti testiranje
- odabir *web*-preglednika unutar kojeg će se izvoditi animacija
- odabir broja ponavljanja izvođenja odabrane animacije
- bilježenje (engl. *log*) podataka koji se prikupljaju tijekom izvođenja animacije.
- Podaci koji se prikupljaju tijekom izvođenja animacije su:
- opterećenje procesora
- korištenost memorije
- veličina datoteke
- broj prikazanih okvira u sekundi
- vrijeme učitavanja okvira.

Slika 4. Prikaz korisničkog sučelja aplikacije testiranja animacija

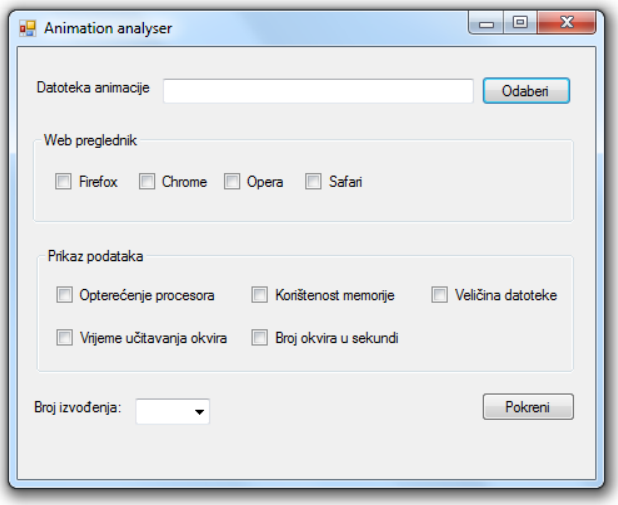

Izvor: obrada autora

U svakoj sekundi izvođenja određene animacije vrši se prikupljanje gornjih podataka. Nakon završetka izvođenja animacije unutar određenog *web*-preglednika pojedinačno se izračunava aritmetička sredina svih prikupljenih mjernih podataka koji se nakon izračuna upisuju u datoteku. Na slici 4 prikazano je korisničko sučelje aplikacije za testiranje animacija.

4.1 Mjerenje opterećenja procesora

Prikupljanje mjernih podataka testiranja animacije izvršeno je primjenom različitih klasa i metoda. Mjerenje opterećenja procesora izvršeno je primjenom PerfomanceCounter klase koja omogućuje praćenje i prikupljanje različitih vrsta podataka o procesima u realnom vremenu. Spomenuta PerfomanceCounter klasa dio je Microsoft .NET biblioteke klasa. Nad procesom, odnosno *web*-preglednikom unutar kojeg se izvodi određena animacija, tijekom svake sekunde izvođenja izvršeno je mjerenje, odnosno prikupljanje podataka o opterećenju procesora. Vrijednost opterećenja procesora mjerena je u postotnom obliku. U nastavku je prikazan programski kod mjerenja opterećenja procesora za određeni *web*-preglednik:

```
double cpuProcesa = 0;
string nazivProcesa = 'firefox';

PerformanceCounter mjeracCpuProcesa = new PerformanceCounter();

mjeracCpuProcesa.CategoryName = 'Process';
mjeracCpuProcesa.CounterName = '% Processor Time';
mjeracCpuProcesa.InstanceName = nazivProcesa;

cpuProcesa += mjeracCpuProcesa.NextValue();

mjeracCpuProcesa.Close();
mjeracCpuProcesa.Dispose();
```

4.2 Mjerenje korištenosti memorije

Kao i za mjerenje opterećenja procesora, PerformanceCounter klasa primijenjena je kod mjerenja korištenosti memorije. Nad procesom, odnosno *web*-preglednikom unutar kojeg se izvodi određena animacija, tijekom svake sekunde izvođenja izvršeno je mjerenje, odnosno prikupljanje podataka o korištenju memorije. Vrijednost korištenosti memorije mjerena je u kilobajtima. U nastavku je prikazan programski kod mjerenja korištenosti memorije za određeni *web*-preglednik:

```
double memorijaProcesa = 0;
string nazivProcesa = 'firefox';

PerformanceCounter mjeracMemorijeProcesa = new PerformanceCounter();
mjeracMemorijeProcesa.CategoryName = 'Process';
mjeracMemorijeProcesa.CounterName = 'Working Set - Private';
mjeracCpuProcesa.InstanceName = nazivProcesa;

memorijaProcesa += Convert.ToInt32(mjeracMemorijeProcesa.NextValue()) / (int)(1024);

mjeracMemorijeProcesa.Close();
mjeracMemorijeProcesa.Dispose();
```

4.3 Mjerenje veličine datoteke

Mjerenje veličine datoteke animacije izvršeno je primjenom FileInfo klase koja omogućuje prikupljanje različitih vrsta podataka o datotekama. Spomenuta FileInfo klasa dio je Microsoft .NET biblioteke klasa. Vrijednost veličine datoteke animacije mjerena je u kilobajtima. U nastavku je prikazan programski kod mjerenja veličine datoteke određene animacije:

```
String nazivDatoteke = fileDialogAnimacija.FileName;

FileInfo infoDatoteke = new FileInfo(@nazivDatoteke);
String velicinaDatotekeAnimacije = Math.Ceiling((double)infoDatoteke.Length / 1024).ToString();
```

4.4 Mjerenje broja prikazanih okvira u sekundi

Mjerenje broja prikazanih okvira u sekundi (engl. *Frames per second*, FPS) kod SVG, JavaScript i HTML5 canvas animacija izvršeno je primjenom JavaScript Stats klase, dok je isto mjerenje kod Flash animacija izvršeno primjenom ActionScript Stats klase.

Nad procesom, odnosno *web*-preglednikom unutar kojeg se izvodi određena animacija, tijekom svake sekunde izvođenja izvršeno je mjerenje, odnosno prikupljanje podataka o broju prikazanih okvira u sekundi. Veća vrijednost broja prikazanih okvira u sekundi predstavlja brže izvođenje animacije. U nastavku je prikazan programski kod mjerenja broja prikazanih okvira u sekundi:

```
var stats = new Stats();
var fps = 0;

setInterval( function () {
        stats.begin();
        fps += stats.getFPS();
        stats.end();
}, 1000 );
```

4.5 Mjerenje vremena učitavanja okvira

Kao i za mjerenje vrijednosti broja prikazanih okvira u sekundi, JavaScript i ActionScript Stats klase primijenjene su kod mjerenja vremena učitavanja okvira. Nad procesom, odnosno *web*-preglednikom unutar kojeg se izvodi određena animacija, tijekom svake sekunde izvođenja izvršeno je mjerenje, odnosno prikupljanje podataka o vremenu učitavanja okvira. Manja vrijednost vremena učitavanja okvira, koja je mjerena u milisekundama, predstavlja brže izvođenje animacije. U nastavku je prikazan programski kod mjerenja vrijednosti vremena učitavanja okvira.

```
var stats = new Stats();
var msOkvira = 0;

setInterval( function () {
        stats.begin();
        fps += stats.getMS();
        stats.end();
}, 1000 );
```

5. TESTIRANJE ANIMACIJA I USPOREDBA REZULTATA

Prema statistici korištenosti preglednika vidljivo je da su Firefox i Google Chrome najviše korišteni preglednici (W3Schools, 2014; Buckler, 2014). Vjerojatno će se u skoroj budućnosti, povećati dosadašnja podržanost tehnologija za izradu animacija u svim *web*-preglednicima.

Svi tipovi animacija (poglavlje 3) izrađeni po opisanim tehnologijama (poglavlje 2) izvodili su se unutar Firefox, Chrome, Opera i Safari *web*-preglednika.

Izvođenje animacija nije izvršeno unutar *web*-preglednika Internet Explorer jer se programske procedure za mjerenje broja prikazanih okvira u sekundi i vremena učitavanja okvira nisu mogle izvesti.

Trajanje animacije ograničeno je na 5 sekundi izvođenja.

Za testiranje i mjerenje izvođenja animacija korišteni su prethodno navedeni preglednici i izrađeni softver. Mjerenje se provodilo tako da je prilikom provođenja testova na *web*-pregledniku jedino testni *web*-preglednik bio aktivan. Svi ostali aplikacijski programi korisnika bili su ugašeni.

Svaka animacija unutar određenog *web*-preglednika izvršavala se 100 puta. Tijekom cijelog izvođenja svake pojedine animacije izvršeno je prikupljanje mjernih podataka. Nakon završetka izvođenja animacije, pojedinačno je nad svim prikupljenim mjernim podacima izvršen izračun aritmetičke sredine.

Testiranje animacija izvršeno je na računalnoj konfiguraciji sljedeće specifikacije:

- Operacijski sustav: Windows 7 (32-bit)
- Procesor: Pentium Dual-Core Processor, 2.1GHz
- Memorija: 4 GB DDR2
- Grafička kartica: Intel Graphics Media Accelerator 4500M
- Tvrdi disk: 320 GB.

Svaka tehnologija izrade i tip animacije grafički se unutar grafikona prikazuju u obliku kratica koje su definirane s dva znaka. Prvi znak kratice označava prvo slovo tehnologije izrade, dok drugi znak, odnosno broj, označava tip animacije. Animacija po stazi definirana je brojem 1, animacija s različitim kadrovima brojem 2, dok je animacije preobražavanjem definirana brojem 3. Primjerice, animacija po stazi izrađena Flash tehnologijom prikazuje se kraticom F1, dok se isto tako, SVG animacija s različitim kadrovima, prikazuje kraticom S2. Animacija preobražavanjem izrađena Canvas tehnologijom prikazuje se kraticom C3.

Grafikon 1. Broj prikazanih okvira u sekundi

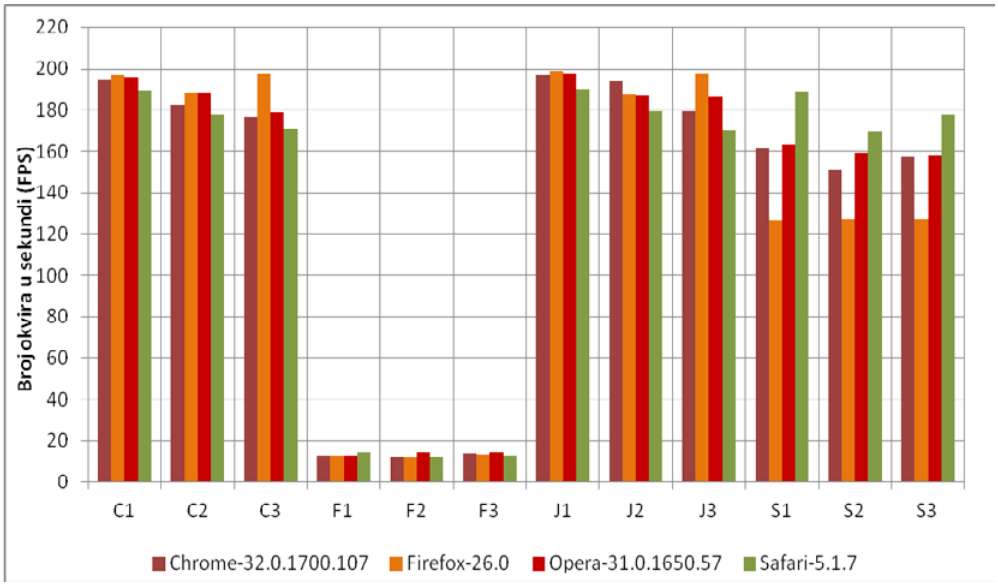

Izvor: obrada autora

Iz grafikona 1 može se vidjeti da su sve tri HTML5 canvas animacije ostvarile rezultate slične JavaScript animacijama. Ukupno u svim web-preglednicima ostvaruju najveću vrijednost broja prikazanih okvira u sekundi. JavaScript animacije ostvarile su u svim web-preglednicima slične vrijednosti broja prikazanih okvira u sekundi. SVG animacije ostvarile su nešto lošije rezultate od Javascript animacija. Suprotno tome, najsporiji prikaz svih tipova animacija ostvarile su animacije izrađene Flash tehnologijom. Flash animacije u usporedbi s HTML5 canvas animacijama unutar svih web-preglednika ostvarile su 14 puta manju vrijednost broja prikazanih okvira u sekundi.

Promatrajući pojedinačno web-preglednike kod HTML5 canvas i Javascript animacija, vidljivo je da se pomoću Safari preglednika prikazuje najmanji broj okvira u sekundi. Suprotno tomu, promatrajući samo SVG tehnologiju, pomoću Safari preglednika prikazuje se najviše okvira u sekundi. Firefox je kod HTML5 canvas i Javascript animacija uglavnom najbrži web-preglednik, dok je kod SVG animacija značajnije najsporiji web-preglednik.

Promatrajući pojedinačno vrste animacija vidi se da se animacije po stazi (1) prikazuju s uglavnom najviše okvira u sekundi, a animacije preobražavanjem (3) prikazuju se s uglavnom najmanje okvira po pojedinom pregledniku i pojedinoj tehnologiji.

Grafikon 2. Vrijeme učitavanja okvira kod Flash animacija

Izvor: obrada autora

Iz grafikona 2 može se vidjeti da su sve tri Flash animacije ostvarile visoke vrijednosti vremena učitavanja okvira, zbog kojih je ostvaren znatno sporiji prikaz u odnosu na vrijeme učitavanja animacija koje su izgrađene drugim tehnologijama (grafikon 3). Flash animacije sporije su se prikazivale unutar svih web-preglednika u odnosu na animacije s ostalim tehnologijama, pri čemu je najsporije prikazivanje zabilježeno kod prikazivanja animacije po stazi unutar Firefox web-preglednika. Suprotno tome, ukupno gledano, najbrži prikaz svih Flash animacija ostvaren je prikazivanjem unutar Safari web-preglednika.

Grafikon 3. Vrijeme učitavanja okvira kod HTML5 canvas, JavaScript i SVG animacija

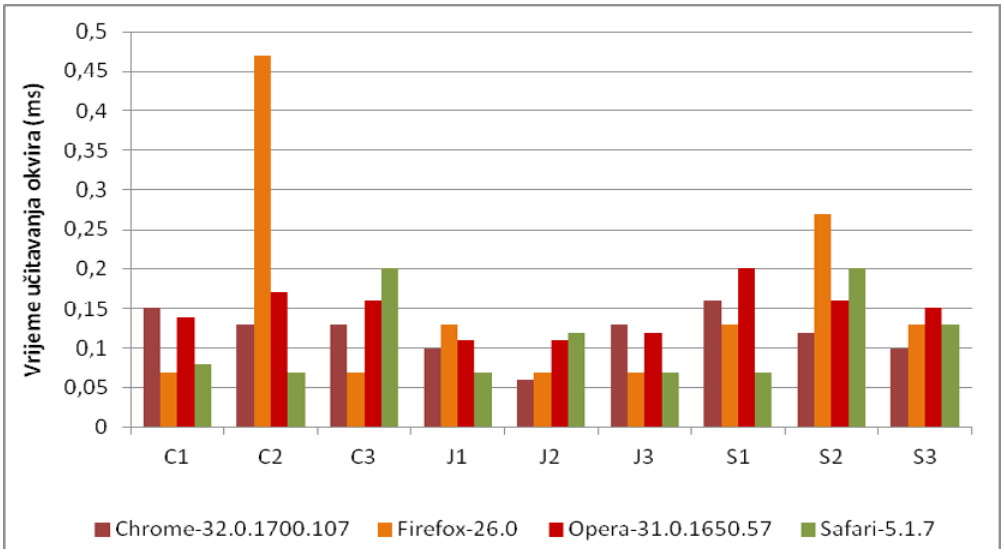

Izvor: obrada autora

Iz grafikona 3 može se vidjeti da je vrijeme učitavanja okvira kod svih triju HTML5 canvas, JavaScript i SVG animacija vrlo slično. S obzirom na male vrijednosti vremena učitavanja okvira ostvaren je brzi prikaz animacija unutar svih web-preglednika. Najveće vrijeme učitavanja okvira animacije zabilježeno je kod prikaza HTML5 canvas animacije s različitim kadrovima unutar Firefox web-preglednika.

Grafikon 4. Korištenost memorije

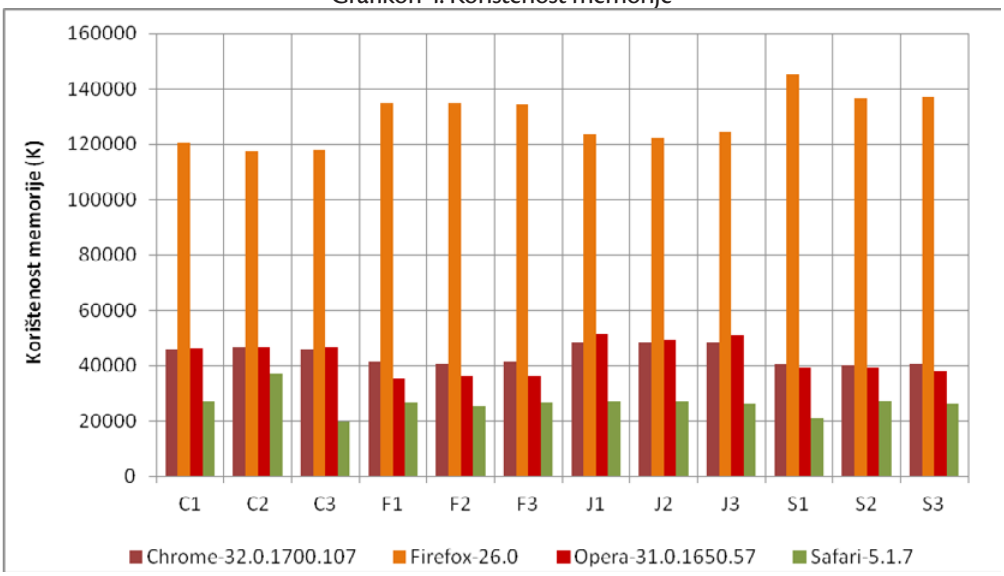

Izvor: obrada autora

Na grafikonu 4 može se vidjeti da svi tipovi animacija svih tehnologija po pojedinom web-pregledniku koriste približno jednaku količinu memorije. Razlika koja se može uočiti jest da je tijekom izvođenja svih triju animacija svih tehnologija unutar Firefox web-preglednika vrijednost korištenosti memorije znatno veća, odnosno da dostiže vrijednosti od čak 144 MB. Najmanja vrijednost korištenosti memorije tijekom izvođenja svih triju animacija svih tehnologija zabilježena je kod Safari web-preglednika. Preglednici Chrome i Opera ostvaruju uglavnom slične rezultate, ali troše više memorije od Safari preglednika.

HTML5 canvas i Javascript animacije na Chrome i Opera preglednicima troše više memorije od Flash i SVG animacija. Suprotno tomu HTML5 canvas i Javascript animacije na Firefox web-pregledniku troše manje memorije od Flash i SVG animacija.

Promatrajući tipove animacija po pojedinoj tehnologiji i pregledniku uočava se da ne postoji značajna razlika u korištenosti memorije.

Grafikon 5. Opterećenje procesora

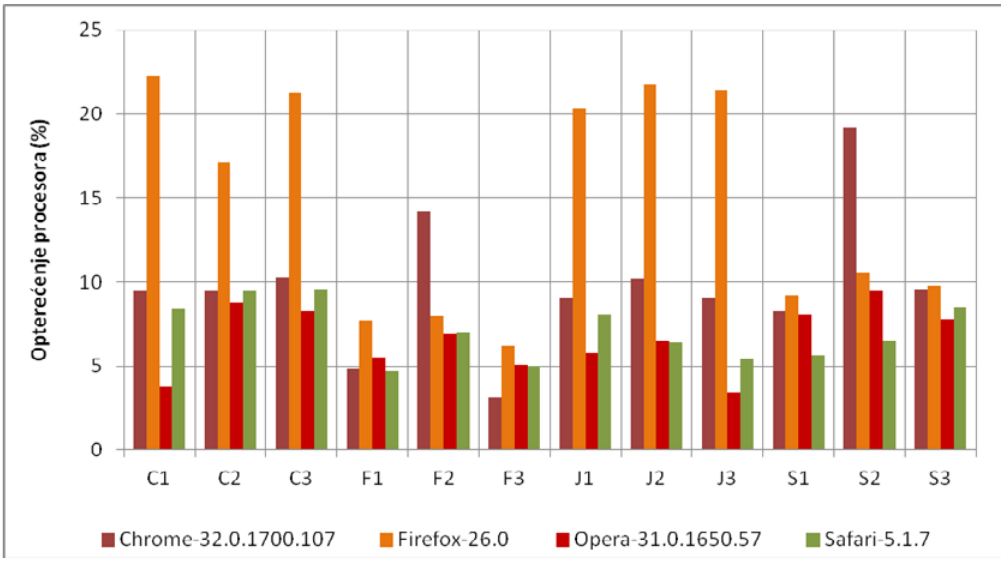

Izvor: obrada autora

Iz grafikona 5 može se vidjeti da su sve tri animacije Canvas, Flash, JavaScript i SVG po *web*-pregledniku ostvarile uglavnom slične vrijednosti opterećenja procesora. Najveća vrijednost, odnosno vrijednost od 22 posto opterećenja procesora zabilježena je kod izvođenja HTML5 canvas animacije po stazi unutar Firefox *web*-preglednika. Ukupno gledano, kod svih Flash animacija, opterećenje procesora najveće je kod njihovog izvođenja unutar Firefox *web*-preglednika. HTML5 canvas i JavaScript animacije s Firefox *web*-preglednikom značajnije opterećuju procesor (cca 20 %), u odnosu na ostale *web*-preglednike. Opera *web*-preglednik uglavnom najmanje opterećuje procesor kod HTML5 canvas i Javascript animacija.

Grafikon 6. Veličina datoteka svih triju animacija

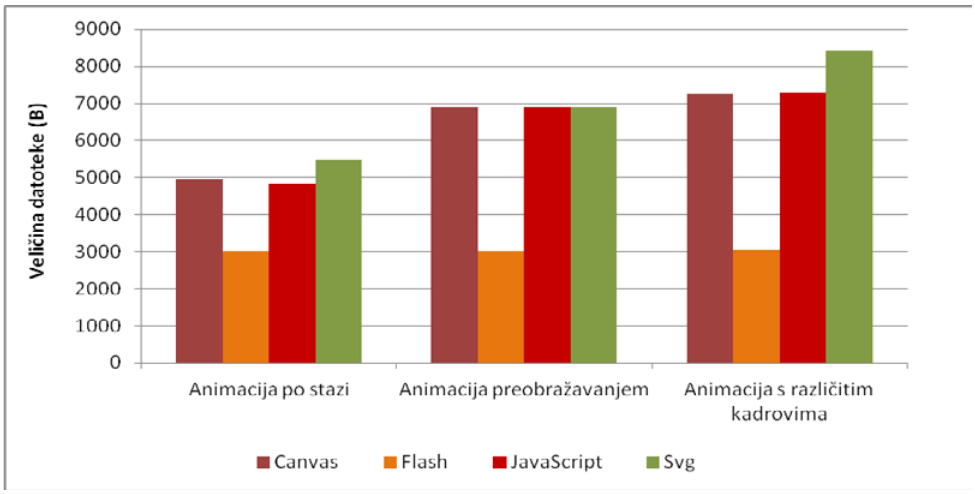

Izvor: obrada autora

Grafikon 6 prikazuje veličinu datoteke u bajtovima svih triju animacija, na svim testiranim tehnologijama. Može se vidjeti da su veličine datoteka kod svih Flash animacija jednake i značajnije manje od animacija izrađenih pomoću ostalih tehnologija. Kod HTML5 canvas, JavaScript i SVG animacija vidljiva je sličnost u veličinama animacija po pojedinim tipovima animacija. Najveća veličina datoteke animacije, u odnosu na ostale, zabilježena je kod SVG animacije s različitim kadrovima. Vidljivo je rastući trend veličine datoteka iste tehnologije za različite tipove animacija, od najmanje animacije po stazi, do najveće animacije s različitim kadrovima.

6. DISKUSIJA

Iz navedenog istraživanja i dobivenih rezultata testiranja može se zaključiti da korištenje Flash tehnologije za izradu *web*-animacija nije najbolje rješenje. Za istu namjenu, značajno bolji rezultati postignuti su korištenjem HTML5 Canvas, SVG i JavaScript tehnologija, koje su za svoje prikazivanje animacija slično opterećivale procesor i koristile radnu memoriju. Velika razlika vidljiva je u brzini prikazivanja, gdje se Flash animacija prikazivala do 14 puta sporije od animacija izgrađenih u ostalim tehnologijama. Razlog tomu jest razlika između renderiranja sadržaja, pri čemu Flash tehnologija za svoj prikaz zahtijeva dodatak (engl. *plugin*), dok se kod ostalih tehnologija sadržaj renderira izvorno.

Brzina prikazivanja animacija različitih tehnologija potvrđuje se vremenom potrebnim za učitavanje okvira. Prema tome, vrijednost učitavanja okvira izravno utječe na vrijednost brzine prikazivanja animacije. Tako je, zbog visoke vrijednosti vremena potrebnog za učitavanje okvira, uočen znatno sporiji prikaz Flash animacija.

Golemi nedostatak Flash tehnologije za izradu *web*-animacija jest u tome što je za svoj znatno sporiji prikaz svih tipova animacija slično zahtijevala perfomanse računala, kao i animacije izgrađene ostalim tehnologijama, kod kojih je ostvaren znatno brži prikaz, u nekim slučajevima čak 14 puta brži.

Što se tiče samih *web*-preglednika, iz rezultata je vidljivo da su tijekom testiranja svih izrađenih animacija, Chrome, Safari i Opera *web*-preglednici, za njihovo izvođenje, najmanje opterećivali procesor i koristili memoriju. Suprotno tomu, najveća vrijednost opterećenja procesora i korištenosti memorije zabilježena je kod izvođenja svih animacija unutar Firefox *web*-preglednika.

Animacije svih tehnologija podjednako su se prikazivale unutar svih *web*-preglednika. To je pokazatelj da sve promatrane tehnologije za izradu *web*-animacija imaju zadovoljavajuću podršku njihovog izvođenja kod svih *web*-preglednika.

7. ZAKLJUČAK

Sveopća prisutnost informacijsko-komunikacijskih tehnologija (ICT) i potrebe korisnika za upotrebom i obradom multimedijskih sadržaja zahtijevaju razvoj i uvođenje novih tehnologija koje će omogućiti brži i jednostavniji pristup sadržajima i koje će poboljšati performanse sustava. Svaka nova tehnologija mora proći dug vremenski period da bi se dokazala kao dobar nov standard.

Na temelju brzine prikazivanja animacije, odnosno vrijednosti broja prikazanih okvira u sekundi, može se uvidjeti da se Flash tehnologija ne može smatrati najpogodnijom tehnologijom za izradu *web*-animacija. Činjenica koja potvrđuje sporost prikaza Flash animacija na *web*-pregledniku jest vrijeme koje je potrebno za učitavanje okvira animacije.

Prema dobivenim rezultatima testiranja animacija svih tehnologija, može se zaključiti da su HTML5 canvas, JavaScript i SVG pogodne tehnologije za izradu animacija na internetu. Za izgradnju animacije u navedenim tehnologijama potreban je uređivač teksta, dok je za izgradnju Flash animacija potrebna specijalizirana aplikacija. Flash zahtijeva programski dodatak (*plugin*) za izvođenje u pregledniku, a HTML5 canvas, Javascript i SVG izvršavaju se direktno u pregledniku.

S obzirom na to da su HTML5 canvas i Javascript animacije ostvarile najveći broj prikazanih okvira u sekundi, te neznačajnu razliku u korištenosti memorije i opterećenju procesora u odnosu na ostale tehnologije, mogu se smatrati najpogodnijim tehnologijama za izradu animacija na internetu. Činjenica koja to potvrđuje jest nativnost HTML5 tehnologije kojom je omogućeno da se objekti ne ugrađuju u *web*-dokument, već da se tretiraju kao izvorni. Takav pristup omogućuje niz prednosti kao što su: nezahtjevnost za dodacima, brzina, navigacijske kontrole u sklopu *web*-preglednika, upravljanje tipkovnicom.

Isto tako, izbor HTML5 kao najpogodnije tehnologije za izradu animacija potvrđuje njezina pozicija najboljeg rješenja za razvoj animacija koje zadovoljavaju zahtjev – može se izvoditi na svim platformama.

LITERATURA

Baotić, G. (2009) *Najčešće korišteni grafički formati*, Završni rad, Zagreb: Fakultet elektrotehnike i računarstva, http://www.baotic.net/graficki-formati-na-webu/vektorski/svg/ (pristupano 13. 2. 2014.)

Brekalo, S., Horvatić, S. (2013) *Usporedba značajki web animacija kreiranih u SVG, HTML5 Canvas i Flash tehnologijama*, Zbornik radova Međimurskog veleučilišta u Čakovcu, Vol. 4 No. 2, http://hrcak.srce.hr/113470

Buckler, C. (2014) *Browser Trends January 2014: a Yearly Review*,

http://www.sitepoint.com/browser-trends-january-2014-yearly-review/ (pristupano 17. 2. 2014.)

Carnet Cert (2009) *Ranjivosti Adobe Flash tehnologije*, http://www.cert.hr/sites/default/files/CCERT-PUBDOC-2009-05-264.pdf (pristupano 18. 2. 2014.)

Čačić, B. (2012) Razvoj naprednih korisničkih sučelja u web 2.0 okruženju, Grafički fakultet, Zagreb, http://eprints.grf.hr/930/1/DB104_%C4%8Ca%C4%8Di%C4%87_Marko.pdf (pristupano 29. 4. 2014.)

Deković, T. (2008) *JavaScript biblioteke*, http://tomislavdekovic.iz.hr/sheshnjak/clanci/javascriptBiblioteke.html (pristupano 13. 2. 2014.)

Flannagan, D. (1997) Javascript: The Definitive Guide, O'Reilly & Associates, http://docstore.mik.ua/orelly/web/jscript/index.html (pristupano 30. 4. 2014)

Hickson, I. (2014) HTML Living standard, http://www.whatwg.org/specs/web-apps/current-work/multipage/ (pristupano 30. 4. 2014)

Kovačević, D. (2009) *Animirani 3D likovi u Flash tehnologiji*, Diplomski rad, Fakultet elektrotehnike i računarstva, Zagreb, http://hotlab.fer.hr/images/50009024/diplomski-Kovacevic.pdf (pristupano 13. 2. 2014.)

Pap, K., Pavazza, S. (2012) The Alternative Way of Creating Infographics Using SVG Technology, Grafički fakultet, Zagreb, http://hrcak.srce.hr/file/128170 (pristupano 29. 4. 2014.)

Pilgrim, M. (2010) *HTML5 Spreman za upotrebu*, Zagreb: Dobar plan

Smith, D. (2005) Dashboard Widgets for MAC OS X Tiger: Visual QuickStart Guide, Peachpit Press, Berkeley, CA, 2005)

Sucan, M. (2009) *HTML5 canvas – the basics*, http://dev.opera.com/articles/view/html-5-canvas-the-basics/ (pristupano 18. 2. 2014.)

W3C (2002) Scalable Vector Graphics (SVG) 1.2, World Wide Web Consortium, http://www.w3.org/TR/2002/WD-SVG12-20021115/ (pristupano 30. 4. 2014)

W3C (2011) Scalable Vector Graphics (SVG) 1.1, World Wide Web Consortium, http://www.w3.org/TR/SVG/ (pristupano 30. 4. 2014)

W3C (2013) HTML Canvas 2D Context, World Wide Web Consortium, http://www.w3.org/TR/2dcontext/ (pristupano 30. 4. 2014)

W3Schools (2014) Browser Statistics, http://www.w3schools.com/browsers/browsers_stats.asp (pristupano, 29. 4. 2014.)

Williams, J. (2011) *Learning HTML5 Game Programming: A Hands-on Guide to Building Online Games Using Canvas SVG and WebGL*, Addison-Wesley Professional, 2011.

Vedran Harmadi [1]
Marin Kaluža [2]
Dijana Liverić [3]

Professional paper
UDC 004.928:004.73852

COMPARISON OF TECHNOLOGIES ENABLING ANIMATION DISPLAY IN DIFFERENT WEB BROWSERS[4]

ABSTRACT

This paper presents the analysis of commonly used technologies for building and execution of animation in different web browsers. Flash is a technology that has significantly contributed to the possibilities of creating a web animation, and certainly to the development of other technologies. Over the years, a number of technologies have been developed, like HTML5 canvas, which brings us a huge amount of improvements over the old document-oriented web. The main goal of this paper is to present which technology achieves the best performance in animation execution in different web browsers. The paper analyzes execution performances of Flash, HTML5 canvas, SVG, and JavaScript animations in Firefox, Safari, Opera, and Chrome web browsers. Measurement was performed on a frame frequency - frames per second (FPS), loading time, CPU usage, file size and RAM usage. The paper also presents the source code for tests that were performed on the observed animations for measuring their performances.

Key words: *performance, Flash, HTML5 canvas, SVG, JavaScript*

[1] Bacc. ing. comp. E-mail: vedranharmadi@gmail.com
[2] MSc, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: mkaluza@veleri.hr
[3] Assistant, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: dliveric@veleri.hr
[4] Received: 19. 2. 2014.; accepted: 5. 5. 2014.

Adrian Smijulj [1]
Ana Meštrović [2]

Stručni rad
UDK 004.415.2

IZGRADNJA MVC MODULARNOG RADNOG OKVIRA[3]

SAŽETAK

Cilj je ovoga stručnoga rada prikazati tehnologije i komponente vezane uz izradu radnog okvira te prikazati implementaciju jednostavnog radnog okvira koji sadrži najnužnije komponente za brzi razvoj web*-aplikacija. Iznesena su teorijska razmatranja vezana uz primjenu radnog okvira u razvoju aplikacije. Predstavljene su i analizirane potencijalne komponente radnog okvira. Nadalje, prikazana je implementacija radnog okvira uz korištenje suvremenih tehnologija kao što su PHP, MySQL, HTML itd. Prikazani radni okvir cjelokupno je izgrađen primjenom objektno-orijentiranog pristupa. Korištena je Model-View-Controller arhitektura i alati poput ORM sučelja za automatizirani rad s entitetima i sustavom za upravljanje događajima. Prednost korištenja izrađenog radnog okvira je prestanak ulaganja programerova vremena na osmišljavanje arhitekture i izradu alata, već će se u potpunosti moći posvetiti zadacima projekta. Iako sadrži samo temeljne komponente, radni okvir će po svojoj modularnoj arhitekturi biti fleksibilan, što će omogućiti programeru da ga proširi prema vlastitim potrebama i prilagodi prema zahtjevima aplikacije koju je potrebno izraditi. Zaključak je rada kako je u razvoju složenih aplikacija poželjno uložiti vrijeme u izradu radnog okvira ili neke slične komponente koja će kasnije omogućiti brži i pouzdaniji razvoj cjelokupne aplikacije.*

Ključne riječi: *radni okvir, Model-View-Controller arhitektura (MVC), programiranje pogonjeno događajima, modularni sustavi , PHP*

1. UVOD

Programiranje i razvoj aplikacija postaju sve zahtjevniji zadaci. Razvojem novih tehnologija, mogućnosti i nastajanjem sve kompleksnijih problema, potrebno je uložiti više vremena za izradu projekta. Programer ponekad mora razvijati svoja rješenja na dvije, pa čak i više programskih platformi. Jedan od mogućih pristupa koji može olakšati i ubrzati razvoj aplikacija je korištenje radnih okvira (engl. frameworks). To su alati koji odrađuju poslove koji mogu biti vrlo često repetitivni, trivijalni, ponekad kritični i općenito poslovi kojima se programeri ne bi trebali baviti prilikom rada na projektu jer uzimaju dodatno vrijeme za razvoj. Programeri na projektu moraju razvijati zadani projekt, a ne probleme arhitekture kôda, nedostatka funkcionalnosti ili sigurnosti[4].

[1] Mag. edu. *E-mail:* adrian.1358@gmail.com
[2] Dr. sc., docent, Odjel za informatiku, Sveučilište u Rijeci, Radmile Matejčić 2, Rijeka, Hrvatska. *E-mail:* amestrovic@inf.uniri.hr
[3] Datum primitka rada: 27. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.
[4] SensioLabs, (2013)., The Book for Symfony 2.3, preuzeto 10. 8. 2013.

U ovome radu fokus je postavljen na izradu radnog okvira i to u jednom od najpoznatijih skriptnih jezika u domeni web-tehnologija, a to je PHP. s ciljem povećanja učinkovitost programera i samog kôda, integrirano je nekoliko različitih komponenti, odnosno modula, a svaki je odgovoran za odrađivanje jednog segmenta aplikacije koje će programeri-korisnici koristiti po potrebi. Kreiranje ovog radnog okvira nastalo je temeljem različitih iskustava s drugim popularnim radnim okvirima, a istovremeno sa željom da se iz svakoga uzmu dobre ideje i pretvore u jedan novi alat. Korisno je napomenuti kako radni okvir nije produkt koji se kreira jednokratno, stoga je logičan nastavak ovoga rada usavršavanje, održavanje i dodavanje novih mogućnosti, kako bi bio u skladu s novim tehnologijama i nadolazećim potrebama programera.

U radu je posebno analizirana Model-View-Controller (MVC) arhitektura. MVC arhitektura sedamdesetih je godina inicijalno uvedena u jezik Smalltalk-76, a potom implementirana unutar biblioteka verzije Smallatlk-80 (Krasner, Pope, 1988). Nakon toga je MVC arhitektura prihvaćena kao općeniti koncept.

U nastavku rada opisana je ideja radnog okvira i MVC arhitekture te koncepti bitni za njegovu realizaciju: modularno programiranje, Object-Relational Mapping (ORM) koncept, te programiranje pogonjeno događajima. U trećem poglavlju opisan je postupak implementacije modula za kreiranje korisnika i korisničkih grupa. U četvrtom poglavlju iznesena su zaključna razmatranja.

2. IZRADA RADNOG OKVIRA

U ovome poglavlju bit će prikazana izrada radnog okvira, i to tako da će prvo biti teorijski obrađene komponente, a nakon toga će biti prikazana implementacija. Bit će obrađeno nekoliko poznatijih i popularnijih termina iz područja programiranja, i to počevši od osnovne MVC arhitekture koja će biti korištena. Osim toga, bit će razmotrene i karakteristike modularnog programiranja, ORM sučelja i programiranja pogonjenog događajima, kao sloj koji će dodatno podržavati radni okvir.

Radni okvir je alat koji se sastoji od mnoštva različitih komponenti koje programeru mogu olakšati posao i ubrzati proces izrade aplikacije. Okviri su kolekcije različitih pomoćnih funkcija, klasa, knjižnica i dr. koje pomažu nudeći već gotova rješenja za specifične i često korištene probleme. Programeri se mogu odlučiti za korištenje već popularnih gotovih rješenja, no ponekad mogu krenuti i u izradu vlastitog. Za ovaj korak prethodno treba utvrditi potrebno vrijeme izrade i predvidjeti probleme koji se mogu pojaviti. Vlastita izrada može biti i štetna, jer često ne postoji dovoljno znanja i iskustva kako bi se sve prepreke u potpunosti riješile. Ipak, često je onima koji rade s vlastitim radnim okvirom kasnije lakše riješiti određene aplikacijske probleme jer poznaju arhitekturu koju su sami postavili pa lakše mogu ponovno iskoristiti isti kôd na drugim projektima (Fowler, 2002).

Neki od primjera rješenja koja nude različiti radni okviri su sustav rada s korisnicima, MVC arhitektura, klase za rad s kolačićima (engl. cookies) i sesijama (engl. sessions), formulari, ORM sučelje, klase za rad s rutama, datotekama itd. Korištenjem radnog okvira, sve navedene

probleme programer preskače, čime se može odmah baviti stvarnim problemom, odnosno poslovnom logikom. Osim navedenog, postoji još niz prednosti:

- sigurnost,
- nema cijene *(open source)*,
- podrška od strane proizvođača i zajednice.

Postoje i mane, npr.:

- ponekad programer pasivno uči rad u radnom okviru, a ne u jeziku,
- ograničenja od strane radnog okvira,
- kôd radnog okvira je otvorenog tipa, što znači da napredniji programeri mogu znati kako aplikacija interno funkcionira i mogu iskoristiti slabosti.

Trenutno postoji mnogo dostupnih gotovih radnih okvira, a neki od poznatijih su zasigurno Symfony, CakePHP, CodeIgniter, ZendFramework, Laravel, Yii (McArthur, 2008). Specifičnost rada s navedenim radnim okvirima jest njihov neidentičan rad. Stoga, promjenom radnog okvira s jednog na drugi, programer mora detaljno proučiti strukturu, konvencije i njegove specifičnosti.

Ukupno gledajući, postoje dobri razlozi za korištenje gotovog radnog okvira. No, izrađujući vlastiti, moguće je u potpunosti prilagoditi kompletnu arhitekturu vlastitim potrebama i željama, odnosno dodavati samo ono potrebno za određeni projekt, te kasnije napraviti izmjene ili nadogradnje sustava. S druge strane, tijekom izrade ovakvih sustava nije potrebno apsolutni svaki dio samostalno izraditi jer postoje već dobra modularna rješenja, pa će tako za sustav upravljanja predlošcima u radnom okviru biti integriran popularan Smarty Templating Engine (Hayder, & Gheorghe, 2006), čime će se uštedjeti vrijeme potrebno za izradu radnog okvira.

2.1 Model–View–Controller arhitektura

MVC je kôdna arhitektura koja je, iako originalno razvijana za *desktop* platforme, danas popularna na suvremenim *web*-platformama. Glavne ideje ovoga modela su razdvajanje kôda u zasebne cjeline, odnosno dosljedna struktura i mogućnost ponovnog korištenja istog kôda (engl. *code reusability*). Sama ideja je prvi put javno prezentirana već 1988. godine (Krasner, Pope, 1988), a do današnjeg dana doživjela je nekoliko iteracija pa je stvoreno nekoliko inačica originalne ideje (HMVC, MVA, MVP, MVVM, itd.).

MVC arhitektura sastoji se od određenih komponenti u kojima je svaka zadužena za obavljanje specifičnih funkcija. To je puno bolje u odnosu na prethodne inačice u kojima se sve nalazilo na jednom mjestu, a što je pak dovodilo do otežanog čitanja kôda, otežanog pronalaženja i ispravljanja pogrešaka, ali i do znatno manje funkcionalnosti i fleksibilnosti.

Cijela arhitektura se sastoji od triju specifičnih i međusobno zavisnih komponenti: *model*, *view* (pogled, prezentacija) i *controller* (kontroler, upravljač). Na slici 1 prikazan je općenit princip rada MVC arhitekture u *web*-okruženju:

Slika 1. Općenit princip rada MVC arhitekture u *web*-okruženju

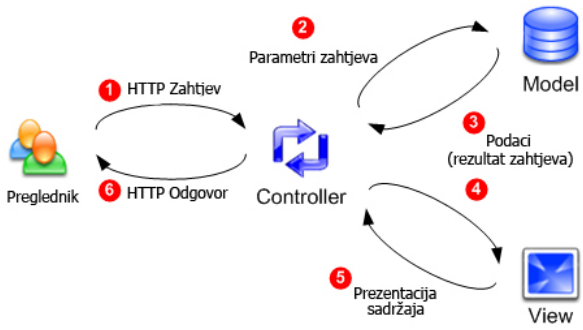

Izvor: (Hayder, Gheorghe, 2006)

Cijeli proces započinje korisnikovim zahtjevom (u trenutku kada korisnik unese *web*-adresu u svom pregledniku) kojeg najprije analizira kontroler, a koji sadržava skup prethodno definiranih slijedova operacija, odnosno funkcija koje je potrebno izvršiti. U tom procesu vrši se i komunikacija s preostale dvije komponente – modelom i prezentacijom, tako da potrebne parametre prosljeđuje svakoj komponenti te, ovisno o rezultatu, kontrolira daljnji slijed izvršavanja cjelokupnog procesa. Uloga modela je rad s podacima, odnosno komunikacija s bazom podataka, dodatna obrada dobivenih podataka, ukoliko je potrebno, te u konačnici vraćanje rezultata prema kontroleru. Dobiveni podaci će, po potrebi, biti poslani drugim procesima i biti opet naknadno obrađivani. Ipak, u većini slučajeva kontroler će završiti proces pozivajući prezentacijsku komponentu, koja će pak generirati zadani predložak po kojemu će se dobiveni podaci i prezentirati. Tako dobiveni predložak, odnosno generirani HTML kôd, kontroler će poslati prema korisniku, odnosno korisnikovom pregledniku.

MVC arhitektura se neko vrijeme razvija unapređivanjem prethodnih verzija pa je razvijeno više različitih verzija MVC arhitekture. Arhitekture su uglavnom slične, s manjim razlikama u logici odvijanja procesa i nazivlju komponenata. Jedna verzija MVC arhitekture je MVA, odnosno *Model-View-Adapter* i zanimljivo je da se danas sve više koristi u kontekstu *web*-tehnologija, naročito na klijentskoj strani aplikacije (npr. u skriptnom jeziku JavaScript). U ovom konceptu postoji posebna komponenta adapter koja se nalazi između komponenti model i prezentacija i ona regulira procese tako što prati rad i procese temeljem odgovora koje dobiva od okolnih susjednih komponenti. Npr. prezentacijska komponenta šalje „signal" da je u tekstualno polje u formularu upisano ime, adapter prima tu informaciju i tada šalje zahtjev modelu za ažuriranjem podataka koji će se kasnije koristiti za spremanje, npr. u bazu podataka. Obrnuti proces je također moguć, ukoliko se podaci u modelu promijene, model komponenta će poslati signal adapteru koji će na isti način reagirati prema prezentacijskooj komponenti, odnosno sadržaj formulara će se također ažurirati. Danas se primjena ovakvog način rada može vidjeti npr. u JavaScript radnim okvirima kao što su Backbone.js, Angular.js, Kendo UI (Adams, 2013) itd., a koji omogućuju izvršavanje MVC arhitekture djelomično na klijentskoj strani, za razliku od klasičnog pristupa u kojem se arhitektura primjenjivala samo na poslužitelju.

Sličan princip koristi i *three-tier-pattern* arhitekura (Eckerson, 1995), u kojoj se kao i u MVC arhitekturi, cjelina nastoji razdvojiti u tri razine, a to su prezentacijska, logička i podatkovna razina. Zanimljivo je da se ove razine izvršavaju na različitim platformama, pa se tako prezentacijska razina može nalaziti u *desktop* aplikaciji u obliku korisničkog sučelja, dok se logička i podatkovna razina mogu nalaziti na različitim poslužiteljima u izoliranoj okolini. Iz ovoga nastaje, također interesantna, prednost: razine ne ovise međusobno, i to u smislu da je na različitim razinama moguće kompletno zamijeniti okruženje (npr. u prezentacijskoj razini izmijeniti operativni sustav ili aplikaciju) i sve dok specifične razine „odrađuju" svoju funkciju, cijela arhitektura će ispravno funkcionirati. U odnosu na MVC arhitekturu, osim ove razlike, ovdje također ne postoji mogućnost komunikacije prve i zadnje razine, već cijeli proces uvijek započinje prezentacijskom, a završava podatkovnom razinom, što u određenim situacijama može biti i mana.

2.2 Modularno programiranje

Modularno programiranje je tehnika dizajniranja softvera koja naglašava razdvajanje kôda u neovisne cjeline koje se u svakom trenutku mogu uključiti ili isključiti i to bez utjecaja na ostatak sustava (Šribar, Motik, 2010; Matković, 2006). Ovo se znatno razlikuje od tzv. „monolitičnih aplikacija" u kojima je i najmanji dio kôda zapravo neizostavni dio cjeline, što je gotovo uvijek nepoželjan faktor u procesu izrade softvera. Uobičajeni primjeri modularnih sustava su integrirani informacijski sustavi za podršku poslovanju (ERP sustavi, engl. *Enterprise Resource Planning Sastems*) ili sustavi za elektroničko poslovanje koji se mogu sastojati također od više modula. Primjer modularnog sustava za elektroničko poslovanje prikazan je na slici 2.

Slika 2. Primjer modularnog aplikacijskog sustava za elektroničko poslovanje

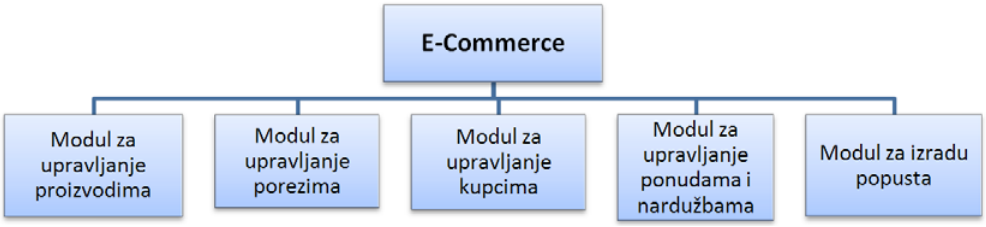

Izvor: Obrada autora

U navedenim primjerima vidimo kako se kompleksni sustavi mogu sastojati od svojih manjih zasebnih cjelina. Tako npr. ERP sustav može sadržavati modul za upravljanje odnosima s korisnicima (engl. *Customer Relationship Management*, CRM), ali i ne mora, ukoliko za to ne postoji zahtjev, dok će sustav i dalje funkcionirati uredno. S druge strane, sustav za elektroničko poslovanje može, ali i ne mora, sadržavati modul za izradu popusta na cijenu proizvoda.

Bitno je napomenuti kako moduli kao takvi ne komuniciraju međusobno u sustavu, osim u smislu korištenja drugog modula kako bi prvi mogao ispuniti svoju namjenu (npr. modul koji bi mogao služiti za ispisivanje izvješća može funkcionirati jedino ako prethodno u sustavu postoji i modul koji kreira izvješća).

Osim što omogućuje bolju strukturiranost i neovisnost kôda, ova tehnika ima još neke prednosti:

- kôd je smješten u različitim datotekama koje se kasnije uključuju u cjelinu,
- u isto vrijeme nekoliko programera može raditi na različitim dijelovima sustava,
- osnovu sustava je lakše održavati (popravci i unaprijeđivanje kôda) – ušteda na vremenu a time i novcu,
- kod isporuke proizvoda, moguće je definirati ukupnu cijenu na temelju modula koji su uključeni u paketu.

2.3 ORM sučelje

Općenito, pri kreiranju programskih aplikacija, programer će se gotovo uvijek susresti s različitim postupcima manipuliranja podacima, odnosno bazom podataka. Kod takvih operacija, programer piše različite upite nad bazom podataka (SQL upiti) i time kreira, čita, mijenja ili briše postojeće podatke. No, upiti često mogu biti slični ili čak isti za različite dijelove aplikacije. U praksi kôd se kopira, a u konačnici ga je i vrlo teško održavati jer se promjene ne izvode samo na jednom mjestu, nego na cijelom sustavu (automatski postoji mogućnost pogreške u kôdu na svakoj „kopiji").

Object relational mapping je način organizacije kôda odgovornog za izvršavanje upita prema bazi podataka. To je tehnika kojom je omogućena komunikacija i konverzija podataka između dva zapravo nekompatibilna sustava – objektno orijentiranog jezika i baze podataka. Konkretnije, ova tehnika omogućuje programerima da u kôdu gotovo u cijelosti isključe pisanje SQL upita jer to za njih odrađuje ORM sučelje, dok se njihov kôd svodi na rad s objektima. Na slici 3 je generalno prikazan način rada ORM sučelja.

Slika 3. Uloga i način rada ORM sučelja

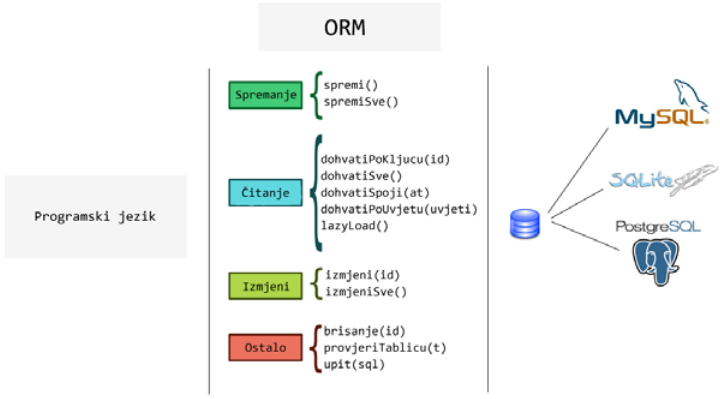

Izvor: https://code.google.com/p/quickdb/

U praksi, korištenjem ORM-a, programer radi s objektima različitih klasa koje predstavljaju neke tipove entiteta koji imaju implementirane različite metode za rad s bazom podataka (npr. različite metode za čitanje ili spremanje podataka). Sama logika je enkapsulirana i ona se brine o

točnom izvođenju SQL upita umjesto programera. Možemo reći da ORM zapravo stvara virtualnu reprezentaciju objektne baze podataka, jer u kôdu zapravo virtualno spremamo objekt u bazu, odnosno čitamo ili dohvaćamo objekt iz baze. No, to u stvarnosti nije tako (za razliku od objektnih baza podataka), jer se u konačnici podaci zapisuju u obliku retka u tablici u bazi podataka. Danas postoje već nekoliko gotovih ORM rješenja (gotovo da se mogu i nazvati radni okviri zbog svoje kompleksnosti i mogućnosti), kao npr. Doctrine Project[5], Active Record[6] itd., a nerijetko se pišu i razna manja rješenja zbog bolje prilagodbe postojećoj strukturi podataka. Neka od rješenja nude i mogućnost rada s različitim platformama kao što su MySQL, PostgreSQL, SQLite, itd. U sljedećem primjeru kôda prikazan je primjer rada s poznatim ORM sučeljem Doctrine Project.

```
1  // Primjer pretraživanje članaka
2  $article = $entityManager->find('CMS\Article', 1234);
3  $article->setHeadline('Hello World!');
4  $article2 = $entityManager->find('CMS\Article', 1234);
5  echo $article2->getHeadline();
6  // Svi korisnici koji imaju 20 godina i prezivaju se Miller
7  $users = $em->getRepository('MyProject\Domain\User')->findBy(array('age' => 20, 'surname' => 'Miller'));
```

Velika prednost korištenja ove tehnike očituje se u tome što programeri ne moraju pisati SQL upite, a osim toga, kôd izgleda preglednije jer se sve svodi na rad s objektima te pozivanje njihovih metoda. Međutim, vrlo je teško kreirati ORM sučelje koje može pokriti sve naše zahtjeve. Drugim riječima, kompleksniji SQL upiti se moraju i dalje ručno pisati. Uz ovo, pokazalo se da programeri ponekad nesvjesno kreiraju loše dizajnirane tablice jer ih automatski prilagođavaju ORM sučelju koje koriste.

U izgradnji radnog okvira bit će implementirano i ORM sučelje. Pri razvoju ove komponente, nastojalo se što više pojednostaviti upotrebu, čime će se povećati produktivnost programera i smanjiti ukupna količina potrebnog kôda.

2.4 Izrada MVC arhitekture

U ovome poglavlju će biti prikazana izrada MVC arhitekture radnog okvira u skriptnom jeziku PHP, koja čini osnovu modularnog radnog okvira. Na slici 4 dan je prikaz UML dijagram[7] s kojim će se moći zornije prikazati cjelokupna struktura radnog okvira.

Radni okvir sastojat će se od nekoliko temeljnih klasa koje će sadržavati sve što je potrebno kako bi se sustav pravilno inicijalizirao, što će se izvoditi na svakom zahtjevu klijenta prema određenoj aplikaciji na poslužitelju. Sve započinje s klasom *Application*, izvršavanjem metoda kao što *init*() ili *getModuleConfig*(), nakon čega će se na kraju instancirati jedan objekt klase *Controller*. Ovdje će se vrlo često instancirati različiti objekti klase *Entity*, koja zbog dodatnih potrebnih metoda proširuje klasu *Model*, koja pak, u konačnici, proširuje klasu *DB_Resource* i koristi klasu *DB*, što omogućuje rad s bazom podataka. Jedino je u ponekim slučajevima moguće izravno korištenje klase *DB_Resource*, i to kada se želi zaobići klasa *Entity*, odnosno

[5] http://www.doctrine-project.org/, preuzeto 10. 8. 2013.

[6] http://www.phpactiverecord.org/, preuzeto 10. 8. 2013.

[7] UML dijagram - Ujedinjeni jezik za modeliranje (eng. Unified Modelling Language, kraće: UML) je normirani jezik opće namjene koji se koristi za modeliranje računalnih sustava temeljenih na objektno-orijentiranoj paradigmi.

kada ona, zbog okolnih faktora, programeru jednostavno nije potrebna. Iza ovog dijela nalazi se klasa *View* koja će također instancirati objekt klase *Smarty*. On će nam koristiti za generiranje HTML sadržaja, a koji će se u konačnici prikazati krajnjem korisniku.

Klase, atributi i metode su razvrstane logički prema svojoj namjeni. Struktura nije strogo definirana, stoga ju je moguće, prema eventualnim potreba klase, dodatno proširiti vlastitim metodama ili umetnuti dodatnu klasu između nekih postojećih, ukoliko je to potrebno.

Radni okvir će biti modularan, što znači da će podržavati proizvoljno uključivanje i isključivanje modula iz sustava. Nadalje, svaki modul koji će se pisati radit će prema MVC ahitekturi - drugim riječima, svaki modul će imati svoje kontrolere (može ih biti i više, ovisno o potrebi) te će sustav, prema definiranom algoritmu, prepoznati u kojem se modulu, kontroleru i akciji radi i to iz HTTP zahtjeva korisnika, odnosno pomoću upisane adrese. Za ovo će biti odgovoran usmjerivač, tzv. „ruter" i njegovo procesiranje će se u pravilu uvijek izvršavati prije bilo kojeg kontrolera (ponekad se ovaj kontroler naziva i prednji kontroler).

Slika 4. UML dijagram radnog okvira

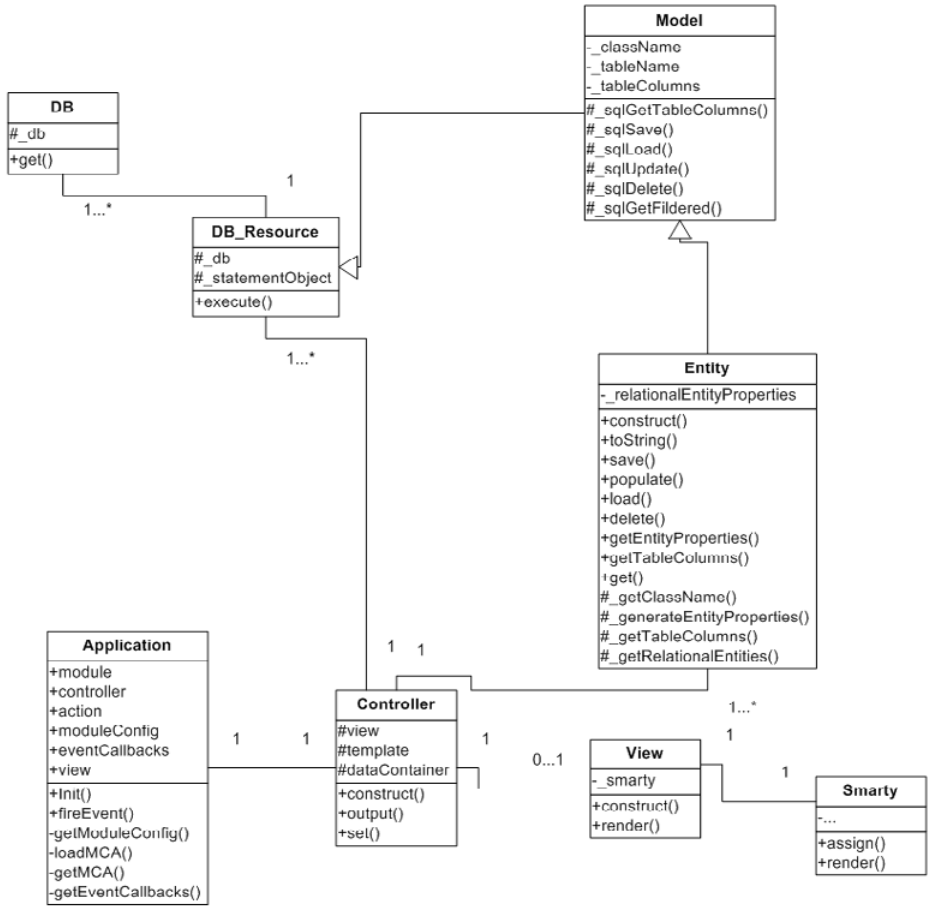

Izvor: Obrada autora

Nakon prepoznavanja, nastavak procesa je jednostavan - sustav će instancirati objekt zadanog kontrolera, izvršiti metodu na njemu i ispisati rezultat korisniku. Ovaj proces je prikazan na slici 5.

Slika 5. Usmjerivač i ostali procesi radnog okvira

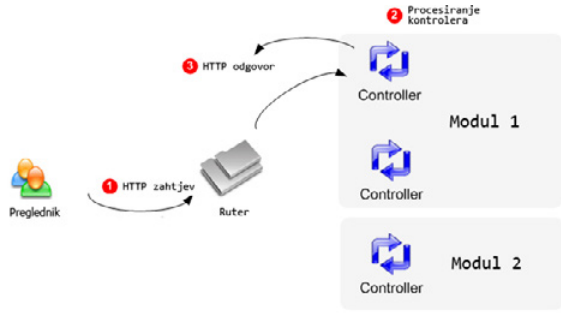

Izvor: Obrada autora

Iako su u dosadašnjim primjerima akcije vraćale rezultat, odnosno generirani HTML (engl. *output*), to ne mora biti uvijek tako. Npr., akcije ponekad mogu samo odraditi spremanje ili brisanje podataka u bazi, vršiti preusmjeravanje itd.

Kontroleri i njihove akcije se zapravo logički grupiraju u cjeline, pa tako može postojati sljedeća podjela – tri modula i klase kontrolera koje sadrže tipične akcije (slika 6):

Slika 6. Jednostavni primjeri kontrolera

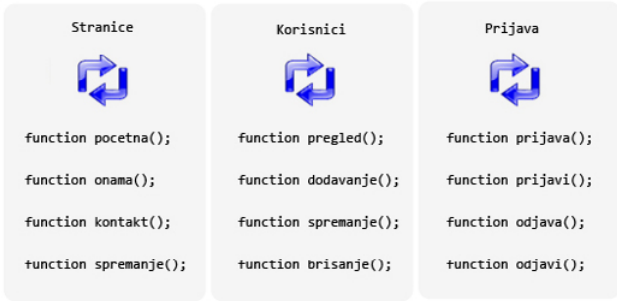

Izvor: Obrada autora

U prvom slučaju definiran je kontroler *Stranice* istoimenog modula, koji je odgovoran za prikaz statičkih stranica. Prve tri akcije *pocetna*(), *onama*() i *kontakt*() mogu poslužiti za dohvaćanje predloška u kojima se nalaze potrebne informacije, dok četvrta metoda može spremati podatke iz formulara koji je korisnik dobio prethodno ispunjavajući formular dobiven pomoću akcije *kontakt*(). Organizacija je slična i u druga dva kontrolera, definirane su akcije koje će vraćati formulare za unos podataka (npr. *dodavanje*() i *prijava*()) i akcije koje će procesuirati podatke (npr. *spremanje*(), *odjava*()).

U ovom poglavlju analiziran je način rada spomenutog usmjerivača i elementi potrebni za njegovo pravilno funkcioniranje. Preciznije, analiziran je način na koji sustav bira potrebnu klasu i njezinu metodu, odnosno akciju kojom korisnik šalje zahtjev za određenom stranicom na poslužitelj. Da bi se ovo postiglo, potrebno je definirati sustav koji će za dani zahtjev znati koji se objekt mora instancirati i koja metoda se mora izvršiti. Ovo se postiže tako da se najprije u postavkama poslužitelja svi zahtjevi preusmjere na jednu datoteku u kojoj će cijeli sustav, i u konačnici usmjerivač, biti definiran. Navedena datoteka će u imati naziv *index.php* a preusmjeravanje će se ostvariti pomoću datoteke *.htaccess*.

2.5 Programiranje pogonjeno događajima

Kao što je poznato, pri pokretanju klasičnih programa, kompletan kôd se izvršava u određenom redoslijedu kojega je definirao programer. Dakle, nakon izvršene naredbe, izvršit će se sljedeća i tako sve do posljednje, odnosno do kraja programa. Iako postoji mogućnost da određeni dijelovi kôda nikada ni ne budu izvršeni (npr. kod grananja), nikada se neće dogoditi da se kasnija naredba izvrši prije nego što treba. Ovakva struktura može biti pogodna u okolinama gdje program korisniku ispisuje poruku, zatim čeka njegov odgovor te na temelju toga postupa dalje prema svojem kôdu. S druge strane, razvojem softvera i korisničkih sučelja, nastala je potreba za osmišljavanjem drugačije kodne arhitekture. Npr. u Windows operativnom sustavu, u prozoru koji nudi više od samo jedne mogućnosti, takav program ne bi imao mogućnost otkriti koji gumb (naredbu) je korisnik kliknuo. Drugim riječima, nastaje potreba za osmišljavanjem sustava koji će moći pratiti akcije koje je korisnik napravio i temeljem njih reagirati na potreban način.

Programiranje pogonjeno događajima" (engl. *„event-driven programming"*) je pristup koji se znatno razlikuje od klasičnog proceduralnog programiranja, jer se dijelovi koda odvijaju pri aktivaciji događaja. To može biti npr., klik na gumb, fokusiranje elementa, pritisak tipke na tipkovnici, prijelaz preko određene površine na sučelju, itd. Sve ovo su različite vrste događaja koje je moguće pratiti, a što programeru omogućuje da odrađuje baš onu funkcionalnost koja je potrebna. To mogu biti npr., prikaz, skrivanje ili pomicanje elemenata na sučelju, prikaz ili spremanje podataka u bazu, zatvaranje programa, itd. Ovakav način rada je zapravo najprisutniji u današnjem programiranju jer su aplikacije i sučelja jednostavno dizajnirana tako da je njihovo funkcioniranje moguće ostvariti jedino putem ovog koncepta.

No, na koji način programsko okruženje „doznaje" za neki događaj? Radi se, zapravo, o konstantom ispitivanju okruženja u kojemu se korisnik nalazi. Iako to korisniku nije vidljivo, u pozadinskom dijelu svakog programa pogonjenog događajima nalazi se petlja (engl. *event-loop*, naziv koji se također koristi je i *event-listener*) koja provjerava sve elemente na kojima se može ostvariti događaj (poput klika, fokusiranja i sl.). Ukoliko se stanje promijenilo, takva petlja će odmah izvršiti funkciju na istom elementu koja će odraditi ono što je programer specificirao. Funkcije koje se izvršavaju nakon određenog događaja nazivaju se *callback* ili *handler* funkcijama. Ova generalna ideja je prikazana na sljedećoj slici (slika 7):

Slika 7. Koncept detektiranja događaja

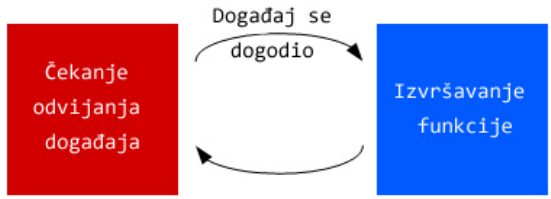

Izvor: Obrada autora

Osim velike fleksibilnosti koju ovaj kocenpt pruža, postoji i još nekoliko prednosti kao što su:

- strukturiranost i kontrola (razdvojen kôd),
- omogućava izradu boljih sučelja,
- kompleksnije kôdne strukture i veće mogućnosti (neovisan kôd).

Pored opisane primjene, sličan koncept se primjenjuje i u objektno-orijentiranom kontekstu, a koji će detaljnije biti analizirati u sljedećem odlomku.

2.5.1 Klase za praćenje stanja objekta

U uvodnom dijelu ovog poglavlja, u kojem su prikazani ključni elementi programiranja pogonjenog događajima, govorilo se uglavnom o primjeni koncepta pri izradi sučelja i definiranju interakcije s korisnikom. U nastavku slijedi malo drugačija implementacija pristupa koji ima elemente programiranja pogonjenog događajima te neke vlastite specifične zahtjeve i karakteristike, a služit će za praćenje stanja objekata te izvođenju adekvatnih *callback* funkcija.

Cilj izrade klasa za praćenje stanja objekta (klasa *Observer*) je također postojanje veza između elemenata u zajedničkom okruženju koje će omogućiti praćenje njihova stanja, no, konkretno, ovog puta navedeni elementi su zapravo objekti. Npr., za promjenu stanja jednog objekta, ostali ovisni objekti će moći „saznati" za tu promjenu te reagirati po potrebi. Fleksibilnost, definirana na ovaj način, može omogućiti bolju kontrolu objekata te olakšati dodavanje novih funkcionalnosti u postojeći kôd.

Tok ovog koncepta je vrlo jednostavan, a sastoji se od četiri elementa (ovoga puta koristit ćemo englesku terminologiju radi lakšeg razumijevanja):

1. Klasa *Observable* („pratljiva" klasa) je zapravo apstraktna klasa ili sučelje, koje će svaki konkretni objekt morati implementirati, a sadržavat će potrebne metode za rad s centralnom klasom *Observer* (priključenje ili isključenje *Observera*, praćenje stanja ostalih objekata itd.).
2. Klasa *ConcreteObservable* (konkretna klasa) koja implementira navedeno sučelje, a predstavlja objekt koji može mijenjati stanja, pri kojima će doći do obavještavanja ostalih objekata klase *ConcreteObservable*.
3. Klasa *Observer* (promatrač), također apstraktna klasa ili sučelje, koje mora implementirati konkretna klasa *Observer*.
4. Klasa *ConcreteObserver* – konkretna *Observer* klasa po kojoj će se instancirati svi *Observer* objekti, prati i obavještava objekte o promjenama stanja.

Prvo što je potrebno napraviti jest instanciranje konkretnih „pratljivih" objekata klase *ConcreteObservable*, koji će, naravno, implementrati sučelje *Observable*, čime će biti obavezni definirati potrebne metode za rad s klasom *ConcreteObserver*. Nakon toga, prethodno instancirani navedeni objekti klase *ConcreteObserver,* moraju se povezati s „pratljivim" objektima. Pri prijelazu u nova stanja, *ConcreteObserver* će „obavještavati" ostale povezane objekte koji će reagirati na određeni način, odnosno izvršavati određeni kôd, sami mijenjati stanja itd.

Za primjer, moguće je pretpostaviti da postoji objekt klase *Osoba*, koja, recimo, predstavlja oca. Uz navedenu, pretpostavimo prisutnost još dva objekta, ovoga puta klase *Dijete*, a koji predstavljaju djecu prve osobe. Ovim konceptom moguće je izvesti da se, automatski, pri brisanju prvog objekta (oca), brišu i objekti djece. Za ovo bi, naravno, bio odgovoran spomenuti *ConcreteObserver*, koji bi o promjeni stanja obavijestio preostala dva objekta, a koji bi onda reagirali na isti način. Navedena logika za određene situacije u kojima djeca nisu od velike važnosti sasvim je korektna, a i pritom automatizirana.

Moguće je uvidjeti da i ovdje postoje, na neki način, događaji koji mogu izazvati promjene u drugim dijelovima koda, odnosno u drugim objektima. Ovaj koncept je poznat već duže vrijeme i primjenjuje se upravo zbog fleksibilnosti i automatizacije koju je moguće postići. Osim toga, također smanjuje mogućnost pogrešaka, odnosno mogućnost da se objekti ne nađu u nekom od nelogičnih stanja.

2.5.2 Programiranje pogonjeno događajima u PHP-u

U ovom poglavlju bit će prikazana primjena programiranja pogonjenog događajima u PHP-u, tako što će se pokušati emulirati originalna ideja. Ono što će zapravo biti učinjeno jest interakcija između određenih dijelova kôda, gdje će jedan dio pozivati jedan ili više drugih dijelova i to putem „emitiranja" događaja. Nakon toga, funkcije koje su se prethodno „registirale" kao *callback* funkcija za navedeni događaj će se izvršiti (funkcija, dakako, može biti više od samo jedne). Potrebno je uzeti obzir da će i ti pozvani dijelovi također imati mogućnost emitiranja događaja, odnosno poziva drugih dijelova kôda, pa čak i onog iz kojega je poziv izvorno stigao, stoga je ponekad potrebno pripaziti da program ne uđe u beskonačnu petlju (moguće je, dakako, i implementirati provjeru koja će osigurati da ne dođe do ovakvih pogrešaka).

Implementacija programiranja pogonjenog događajima u radni okvir zapravo nije složen korak. Prije analize kôda, slijedi okvirni prikaz na koji način će se ostvariti željena funkcionalnost (slika 8). Prije svega, prvo što je potrebno napraviti jest registrirati *callback* funkcije za određene događaje (točka 1). Drugim riječima, upisat će se imena metoda koje se moraju izvršiti pri određenom događaju. Nakon toga, pri svakoj inicijalizaciji sustava, sve metode će se prikupiti (točka 2) i pohraniti u internu varijablu kako bi bile stalno dostupne ostatku sustava. I sada se dolazi, zapravo, do konkretnog slučaja (točka 3) u kojemu se nalazi emitiranje događaja (engl. *firing an event*) gdje će sustav potražiti ima li registirirane *callback* funkcije za dobiveni događaj. Ako one postoje, sustav će ih jednostavno izvršiti (točka 4)., a u protivnom se ništa neće dogoditi.

Slika 8. Način implementacije načina rada pogonjenog događajima

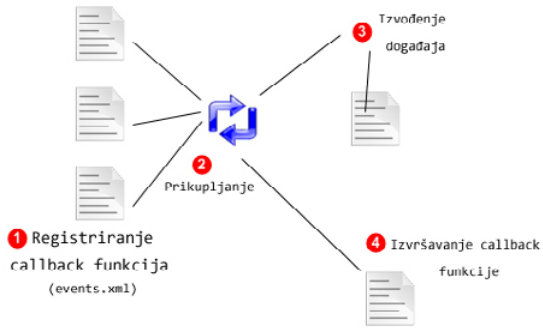

Izvor: Obrada autora

Registriranje *callback* funkcija je vrlo jednostavno, sve potrebne parametre potrebno je unijeti u XML datoteku events.xml. Radi bolje preglednosti, programer može za svaki modul kreirati zasebnu datoteku i u njoj upisivati *callback* funkcije. Sadržaj jedne datoteke *events.xml* prikazan je u sljedećem isječku kôda:

```
1  <events>
2   <event>
3    <type>beforeController</type>
4    <callback>Pages|updatePageStats</callback>
5   </event>
6   <event>
7    <type>afterController</type>
8    <callback>Pages|test</callback>
9   </event>
10 </events>
```

U primjeru se zapravno nalaze dvije registrirane *callback* funkcije koje će se pozivati na događajima *beforeController* i *afterController*. Moguće je uvidjeti da su ovo zapravo događaji koje izvršava sam sustav pri svojoj inicijalizaciji. Ovo je ugrađeno s ciljem da se programeru pružaju dodatne mogućnosti izvršavanja dodatnih operacija prije učitavanja kontrolera i poslije. Naravno, ovdje su mogli biti događaji koje je definirao sam programer, a moguće je i dodati dodatne događaje sustava, kao npr., prije same inicijalizacije i na kraju. Poslije „type" parametra slijedi definiranje callback funkcije koja će se pozvati. Sustav podrazumijeva da će se definicije tih funkcija nalaziti u poznatim datotekama kontrolera, stoga je u parametru potrebno upisati samo ime kontrolera i njegovu metodu, što se odvaja znakom „|".

Nakon toga, sve što preostaje je izvršavanje događaja u kontroleru, a to će biti učinjeno pomoću posebne metode koja je prethodno ugrađena u radni okvir. Ova metoda će proći kroz internu varijablu u kojoj su spremljene sve *callback* funkcije i provjeriti postoje li one koje su definirane za dani događaj. Što se tiče poretka izvršavanja, odnosno prioriteta, ovo je također jednostavno izvedeno, i to tako da se u *events.xml* callback funkcije upisuju u željenom poretku. Ako je potrebno promijeniti prioritet

izvršavanja, dovoljno je samo zamijeniti mjesta registriranja funkcija u datoteci i sustav će izvršavati funkcije po novom poretku.

3. IMPLEMENTACIJA MODULA ZA UPRAVLJANJE KORISNICIMA I KORISNIČKIM GRUPAMA

U ovom poglavlju bit će prikazan postupak izrade pojednostavljenog modula za kreiranje korisnika te korisničkih grupa. Navedenim primjerom će se pokazati koliko je jednostavno i brzo moguće kreirati dijelove aplikacija ovim radnim okvirom, odnosno njegovim ugrađenim komponentama. Za početak, potrebno je definirati konačni cilj ostvariv izradom ovog modula. Korisnik će imati sljedeće mogućnosti:

1. pregledavati trenutno unesene korisnike iz tablice,
2. dodavati, brisati, mijenjati korisnike spremljene u bazi podataka,
3. pregledavati trenutno unesene korisničke grupe iz tablice,
4. dodavati, brisati, mijenjati korisničke grupe spremljene u bazi podataka.

3.1 Tipovi entiteta i baza podataka

Kako će u sustavu biti potrebni korisnici i korisničke grupe, kreirat će se dva tipa entiteta i to User i Usergroup. Potrebno je napraviti dvije klase i kreirati tablicu u bazi podataka, a sustav će znati kako stupce tretirati i na koji način ih spremati. Za svaki entitet je potrebno napraviti nekoliko tablica u bazi, i to prema sljedećim SQL kôdu:

```
1  CREATETABLE`user`(
2  `id`BIGINT(10)NOTNULLAUTO_INCREMENT,
3  `username`VARCHAR(20)NULLDEFAULT''COLLATE'utf8_bin',
4  `usergroup_id`BIGINT(20)NULLDEFAULT'0',
5  `password`VARCHAR(20)NULLDEFAULT''COLLATE'utf8_bin',
6  `first_name`VARCHAR(30)NULLDEFAULT''COLLATE'utf8_bin',
7  `last_name`VARCHAR(30)NULLDEFAULT''COLLATE'utf8_bin',
8  `age`INT(10)NULLDEFAULTNULL,
9  PRIMARYKEY(`id`)
10 )
11 COLLATE='utf8_bin'
12 ENGINE=InnoDB
```

Navedenim SQL kôdom kreirat će se tablica u bazi po imenu *user* i to s gore navedenim stupcima, od kojih će svaki sadržavati konkretan podatak osim *usergroup_id*, koji predstavlja vanjski ključ korisničke grupe za koju će korisnik biti vezan. Vanjski ključevi, kao što je i navedeno u prethodnim poglavljima, moraju sadržavati sufiks „_id" zbog ORM sučelja koje će pri učitavanju podataka prepoznati da se ovdje radi o drugom entitetu, odnosno o korisničkoj grupi. Nakon ovoga, potrebna je i, naravno, tablica korisničkih grupa koja je prikazana u narednom odsječku kôda. Ovdje postoji prostor za dodavanje još nekih podataka, no zbog ovog primjera nastojalo se maksimalno pojednostaviti strukturu. Nakon pripreme entiteta i baze podataka, slijedi izrada kontrolera koji će upravljati aplikacijom.

```
CREATETABLE`usergroup`(
 `id`INT(10)NOTNULLAUTO_INCREMENT,
 `name`VARCHAR(50)NULLDEFAULT''COLLATE'utf8_bin',
 PRIMARYKEY(`id`)
 )
COLLATE='utf8_bin'
ENGINE=InnoDB
```

3.2 Izrada kontrolera i predložaka

Kako postoje dvije sekcije aplikacije, odnosno korisnici i korisničke grupe, tako će biti potrebno kreirati i dva kontrolera, te na taj način odvojiti logiku. U aplikaciji je definiran dio kôda odgovoran za upravljanje korisnicima. Koristi se metoda *index*() koja je odgovorna je za prikazivanje početne stranice, odnosno popisa svih korisnika zbog čega je i korištena metoda *get*(), čime se dohvaćaju svi korisnici. Osim toga, specijalno za ovu aplikaciju razvijena je i Grid klasa koja će automatski generirati potreban HTML kôd za kreiranje tablice koju će ujedno i popuniti s podacima. Klikom na gumb „Add user" korisnik dolazi na drugu stranicu, čiji tok kontrolira metoda *action*() (iz prethodno prikazanog kôda). Potrebno je napomenuti da će ova ista metoda biti odgovorna za kreiranja novog korisnika, ali i za ažuriranje postojećih. Ovo se moglo izvesti pisanjem dvije različite metode, no ponekad je kôd zgodnije smanjiti, pogotovo kada je moguće postići više različitih funkcionalnosti. Kôd metode *action*() zapravo na samom početku provjeva jesu li poslani podaci iz formulara korištenjem metode *$_POST*. Ukoliko jesu, to znači da je korisnik popunio obrazac, te je upisane podatke potrebno spremiti. U suprotnome, učitava korisnika prema dobivenom ID-ju iz URL-a. Ako je validan, entitet User će se uspješno popuniti potrebnim podacima koji će se zatim prenijeti i u predložak koji će se koristiti za prikaz formulara. U suprotnome, entitet se neće popuniti podacima, te će se korisniku prikazati prazan formular. Kako je pri kreiranju korisnika potrebno odrediti kojoj će korisničkoj grupi pripasti, tako su i učitane sve korisničke grupe.

```
class User extends Controller{
  public function index() {
    $e = new Entity();
    $users = $e->get('User');
       $columns = array('username' => 'Username', 'first_name' => 'First name', 'last_name' => 'Last name',
'usergroup|name' => 'Usergroup');
    $grid = new Grid('datatable', 'users');
    $grid->setColumns($columns)->setData($users);
    $this->grid = $grid->render(); }
  public function action(){
    $user = new UserEntity();
    if (_getParam('id')) {
      $user->load(_getParam('id'));
    }
    if (isset($_POST) && count($_POST) > 0) {
      $user->populate($_POST)->save();}
    $e = new Entity();
    $this->usergroups = $e->get('Usergroup');
    $this->user = $user->load(_getParam('id'));}
```

3.3 Ažuriranje statistike stranica

U poglavlju koje je bilo posvećeno implementaciji kôda pogonjenog događajima, spomenuto je da se prije i poslije instanciranja svakog kontrolera emitiraju sustavni događaji *beforeController* i *afterController*. U ovom primjeru će se ovi događaji iskoristiti kako bi se zapisao broj posjeta određenoj stranici. Ukratko, registrirat će se funkcija na *beforeController* događaju, a koja će dobivenoj stranici povećati broj posjeta.

Za početak, pogledajmo datoteku *events.xml* pomoću koje će se odraditi registracija događaja i *callback* funkcije:

```
1    <event>
2      <type>beforeController</type>
3      <callback>Pages|updatePageStats</callback>
4    </event>
```

Ovih nekoliko poprilično jednostavnih linija kôda omogućit će, prije svake inicijalizacije kontrolera (na *beforeController* događaju), izvršenje funkcije *updatePageStats*(). Navedena funkcija je prikazana u sljedećem isječku kôda:

```
1  public function updatePageStats() {
2    $model = new Page_Stats();
3    $model->updatePageStats(Application::$action);
4    Application::fireEvent('korisnik_dod');
5  }
```

Navedena funkcija će samo instancirati objekt klase *Page_Stats* te na njemu pozvati metodu *updatePageStats*(), a kao parametar proslijediti naziv trenutne akcije. Navedena metoda zapravo samo izvršava SQL upit koji će ažurirati statistiku tako što će za trenutnu stranicu, ukoliko nije upisana u tablici, u tablici *page_stats* kreirati redak s početnom vrijednosti statistike koja iznosi 1. Ukoliko dođe do ponovnog učitavanja iste stranice, u tablici se neće ponovno kreirati isti redak za trenutnu stranicu, već će se isti povećati za 1, što je postignuto s ON DUPLICATE KEY UPDATE komandom (pri upitu na MySQL).

Ovo je bio jednostavan primjer na kojem možemo iskoristiti ugrađeni mehanizam pogonjen događajima u našem radnom okviru. Osim što imamo veliku fleksibilnost, ovom metodom omogućili smo suradnju različitih dijelova sustava te istovremeno njihovu potpunu neovisnost. Gore navedena funkcija se, naravno, može proširiti, a programer ima i mogućnosti dodavati funkcije za svaku situaciju u kojoj je potrebno koristiti *callback* funkciju. Neki od primjera događaja na koje možemo registrirati funkcije su uspješna autorizacija korisnika, kreiranje stranice, kreiranje ili brisanje korisnika, upload datoteke, itd.

4. ZAKLJUČAK

Zbog sve složenijih i zahtjevnih aplikacija, programeri moraju tražiti sve bolja sredstva rada. Repetitivne radnje se moraju svesti na minimum. U prvom planu mora biti razvoj same aplikacije, a ne rješavanje problema programskog jezika (ili ponekad čak radnog okvira) koji je u uporabi.

Ovim radom nastojalo se barem djelomično prikazati što se može postići pisanjem vlastitog radnog okvira. Na temelju vlastitog iskustva s drugim radnim okvirima i tehnologijama, nastojalo se učiniti programiranje što prirodnijim i jednostavnijim procesom, što je vrlo često problem u drugim razvojnim okruženjima. Često korištenje klasa neintuitivnih imena, ponekad nejasne logike i strukture, te sama težina radnog okvira, odnosno njegova dodatna procesiranja, mogu učiniti cijeli radni okvir manje efikasnim i nezgodnim za korištenje.

Iako je za potpunu funkcionalnost potrebno osmisliti veći broj komponenata, najvažniji je, zapravo, pravilan rad cijeloga sustava kao cjeline te omogućavanje lakog pristupa programeru komponentama sustava. Osim što programer ovime dobiva skup alata koji će mu omogućiti brži i efikasniji rad, radni okvir svojim ugrađenim konvencijama će također forsirati skladnu i dosljednu strukturu, što će pasivno omogućiti organiziranije pisanje kôda te dodavanje dodatnih komponenti po potrebi.

Radni okvir koji je ovdje izrađen ipak predstavlja samo temeljne i najnužnije alate, zbog čega bi bilo zgodno uvesti još neke dodatne komponente, kao što su sustav za autorizaciju i autentifikaciju korisnika, integracija dodatnih „cache" mehanizama, mogućnost korištenja kratkih ruta, izrada CMS rješenja, komponenti za višejezične aplikacije, slanje elektroničke pošte, itd. No, s jasnom strukturom i pravilima, ovaj posao bi se trebao olakšati, a s podržanom modularnom strukturom, pisanje posebnih modula specifičnih za pojedini projekt moguće je ponovno iskoristiti i, po potrebi, prilagoditi na drugim aplikacijama.

Nakon izrade navedenih komponenti, slijedi održavanje radnog okvira, s obzirom da nove tehnologije konstantno donose nove mogućnosti. Zbog velike količina posla u ovome segmentu, ipak bi bilo poželjno okupiti tim programera koji bi zajedno mogli surađivati i doprinositi radnom okviru. Na ovaj način, budući posao razvoja aplikacija bit će još brži, a samim time i produktivniji.

LITERATURA

Adams, J. (2013) *Learning Kendo UI Web Development*, Packt Publishing Ltd.

Ahsanul B., Anupom S., (2008) *Cake PHP Application Development*, Birmingham: Packg Publishing Ltd.

Eckerson, W. W. (1995) „Three tier client/server architectures: achieving scalability, performance, and efficiency in client/server applications", *Open Information Systems*, 3(20), p. 46-50

Fowler P. et al. (2002) *Patterns of Enterprise Application Architecture*, Addison Wesley

Hayder, H., Gheorghe, L. (2006) *Smarty PHP Template Programming And Applications*. Packt Publishing Ltd.

Krasner, G. E.; Pope, S. T. (1988) „A cookbook for using the model–view controller user interface paradigm in Smalltalk-80. Journal of Object-Oriented Programming", 1(3) p. 26-49

Matković S. et al. (2006) *Osnove programiranja u okruženju grafičkih operativnih sistema: Programski jezik C#*, Beograd: RG i CET

McArthur, K. (2008) *Pro PHP: Patterns, Frameworks, Testing and More*. Apress.

Sarode, P. (2001) Writing a reusable implementation of the MVC design pattern, JAVA REPORT, Volume: 6, Issue: 7

SensioLabs, (2013) *The Book for Symfony 2.3* (10. 8. 2013.)

Šribar J., Motik B. (2010) *Demistificirani C++*, Zagreb: Element

Adrian Smijulj [1]
Ana Meštrović [2]

Professional paper
UDC 004.415.2

MVC MODULAR FRAMEWORK BUILDING[3]

ABSTRACT

The objective of this paper was to provide an overview of the existing technologies and components related to framework creation and to show implementation of a simple framework that contains the most essential components for rapid development of web applications. In the first part of the paper, the theoretical considerations related to the implementation of the framework in developing applications are presented. Potential components of the framework are presented and analyzed on the theoretical level. The second part shows the implementation of the framework using modern technologies like PHP, MySQL, HTML etc. The presented framework is built using the object-oriented approach. The MVC architecture and ORM tools such as automated interface are used to work with the entities and for event management system. The advantage of the presented approach is that the programmer will not have to invest time in architecture design and tool development any more, but will be fully able to focus on project tasks. Although it contains only the core components, the framework will be flexible thanks to its modular architecture, allowing the developer to extend it to suit one's specific needs and to adapt it to the requirements of the application to be developed. To conclude, while developing complex applications it is advisable to invest time in making a framework or similar component that will later enable faster and more reliable development of the application.

Key words: *model-view-controller architecture (MVC), framework, event driven programming, modular systems, PHP*

[1] B. Ed. E-mail: adrian.1358@gmail.com
[2] PhD, Assistant professor, Department of informatics University of Rijeka, Radmile Matejčić 2, Rijeka, Croatia. E-mail: amestrovic@inf.uniri.hr
[3] Received: 27. 2. 2014.; accepted: 5. 5. 2014.

TEHNIČKE ZNANOSTI

Bojan Hlača[1]
Dušan Rudić [2]
Erika Gržin [3]

Prethodno priopćenje
UDK 656.073.235

PROMET KONTEJNERA NA PRAVCU DALEKI ISTOK – SJEVER ILI JUG EUROPE[4]

SAŽETAK

Robni tokovi kontejnera na prometnom pravcu iz Dalekog istoka prema Europi pokazuju trend daljnjeg rasta. Te projekcije prometa mobiliziraju sve sudionike u logističkom lancu od narudžbe robe do njene konačne isporuke. Transportni lanac kontejnera na svjetskom tržištu mora biti tako definiran da je moguća njegova stalna optimalizacija. Okosnicu transportnog lanca kontejnera čine kombinacija pomorskog prijevoza i kopnene mreže prometnica za prijevoz kontejnera do odredišta. Megakontejnerske kompanije imaju sličnu strategiju uređivanja direktnog i indirektnog linijskog brodskog servisa. Strategija se bazira na pravilnom izboru luka pojedine linije. Izbor pojedine luke je odraz njezine interne efikasnosti, ali i razvijenosti mreže kopnenih servisa. Snaga pojedine luke rezultat je i ekonomske razvijenosti zaleđa, odnosno gravitacijskog područja. Prostor Europe je u radu podijeljen na sjever i jug središnjeg dijela te se demografskom i ekonomskom analizom došlo do određenih pokazatelja koji daju odgovor na osnovno pitanje rada, a to je izbor - sjever ili jug Europe.

Ključne riječi: *kontejnerski promet, Daleki istok, sjever Europe, jug Europe*

1. UVOD

Europska unija ujedinjenjem država Europe i samim time ukidanjem velikog broja administrativnih prepreka postala je jaka ekonomska svjetska regija. Robna razmjena Europske unije sa svijetom odvija se posredstvom luka i to na sjeveru i jugu Europe. Najintenzivniji prekomorski pravci kretanja uvoza i izvoza roba Europske unije idu u smjeru Dalekog istoka. Države Dalekog istoka karakterizira vrlo intenzivna izvozna aktivnost. Kroz investicijske zahvate svjetskih korporacija te su države postale danas i veliki uvoznici. U posljednjih dvadesetak godina gustoća robnih tokova iz pravca Dalekog istoka prema Europi i obrnuto višestruko je narasla.

Predmet ovog rada je proučavanje karakteristika robnih kretanja iz pravca Dalekog istoka prema Europskoj uniji kroz Sueski kanal. Osnovno pitanje koje se nameće iz svih analiza robnih kretanja Europe jest treba li za destinaciju robe u Europi koristiti luke juga ili sjevera, odnosno prometne pravce s juga ili sa sjevera Europe. U ovom radu će se pokušati doći

[1] Dr. sc., profesor visoke škole, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* dusan.rudic@veleri.hr
[2] Dr. sc., profesor visoke škole, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* bojan.hlaca@srce.hr
[3] Struč. spec. ing. traff., asistent, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* erika.grzin@veleri.hr
[4] Datum primitka rada: 28. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

do definicije preduvjeta korištenja određenog prometnog pravca. Za intenzivne robne tokove mora se predvidjeti efikasan sustav prijevoza roba. Svjetske kontejnerske brodske kompanije razvile su u vrlo konkurentnim uvjetima svoju strategiju penetracije robnih tokova. Luke su se prilagođavale tržišnim uvjetima i tražile načine da bi privukle brodare. Brodari u ostvarivanju svojih poslovnih ciljeva često kroz svoje povezane kompanije grade nove, prvenstveno tzv. *transhipment* luke. *Roba, proizvod koji je naručen na prostoru država Dalekog istoka (Kina, Južna Koreja, Japan i dr.) na svom putu prema konačnoj destinaciji, Europi, prolazi kroz Sueski kanal. Čija je konačna odluka za odabir robnih tokova prema južnom europskom pravcu ili sjevernom? Koji su pravci brodova na svom putu prema Europi u linijskom servisu? Koje će luke ticati? Koje kriterije imaju brodari za ticanje pojedine luke u linijskom servisu?*

U nastavku rada analizirat će se alternativa korištenja tzv. *transhipment* ili tzv. *gateway* luke, u cilju efikasnog prijevoza roba do krajnjeg korisnika. U radu će se iskristalizirati princip optimalizacije transportnog lanca kontejnera iz pravca Dalekog istoka prema Europi. Kombinacija tzv. direktnog linijskog servisa i indirektnog ili *feedera* dio je strategije optimalizacije ukupnog logističkog lanca od proizvođača iz Dalekog istoka do konačnog odredišta u Europskoj uniji, ali i obrnuto.

2. PROMETNI PRAVAC SJEVER - JUG EUROPE

Kod bilo kakve analize robnih tokova sjevera i juga Europe dolazimo do saznanja da sedam luka Sjevernog mora ima četiri puta veći kontejnerski promet u odnosu na jedanaest luka juga Europe. Kroz Sueski kanal prolazi 43 % ukupnog kontejnerskog prometa Europe, posebno tereta iz Kine, Japana, Koreje i država ASEAN-a. Sav spomenuti teret prolazi kroz Mediteran i ide kroz Gibraltar prema Sjevernom moru. Vrijeme i troškovi brodskih linija mogu biti smanjeni tako da se promet skrene od sjevera prema jugu. Na tržištu gdje postoji mnoštvo konkurentskih luka brodske kompanije još su uvijek koncentrirane tako da veće količine roba idu prema Sjevernom moru.

Glavni razlog koji potvrđuje tu činjenicu je efikasnost. Ta efikasnost može se objasniti kao kombinacija pomorskih i kopnenih uvjeta.

2.1 Kopneni uvjeti korištenja prometnih pravaca

Kopneni uvjeti iznimno su važni za odabir pojedine luke, odnosno pojedinog prometnog pravca. Postoji nekoliko bitnih uvjeta koji utječu na taj odabir:

1. Europska ekonomska geografija – razvijenost gospodarstva i ekonomske aktivnosti rezultira odnosom od 65 do 70 % u korist sjevera;
2. Europska fizička geografija – Alpe i unutarnji plovni put Rajne formiraju prirodnu barijeru i stvaraju prirodan koridor zahvata Švicarske i Austrije prema lukama Sjevernog mora;
3. Europska multimodalna transportna infrastruktura – luke Sjevernog mora izuzetno dobro koriste unutarnje plovne putove i dostupnost željeznice duboko u zaleđe. Na jugu Europe, željeznički promet prema zaleđu na dosta je niskoj operativnoj razini. Prelazak Alpa stvara cestovnom prijevozu više troškova od strane juga, nego od strane sjevera.

2.2 Pomorski uvjeti korištenja prometnih pravaca

Pomorski uvjeti i odabir pojedine luke i pripadajućeg prometnog pravca rezultanta su poslovne politike brodskih kompanija. Osnovni parametar pri tome je odnos između popunjenosti brodskog prostora i troškova broda. Na taj način mogu se definirati sljedeći uvjeti:

1. Veći kontejnerski brodovi – između luka Sjevernog mora i Dalekog istoka znači smanjenje troškova po jedinici tereta i povećan kapacitet prijevoza. Klasterizacijom aktivnosti, ekonomskom isplativošću i mogućnosti velikog gaza glavnih luka Sjevernog mora rezultiraju ticanjem brodova s minimalnim troškovima po jedinici tereta.
2. Mali pomorski troškovi – kombinacijom visokog kapaciteta prijevoza u oba pravca na liniji Azija – Europa čini jeftiniji prijevoz kontejnera iz Kine prema lukama Sjevernog mora (od luke Le Havre do Hamburga) nego prijevoza do luka na jugu Europe.
3. Sjeverni pravac ojačan je u pravcu zapad – istok te stvara atraktivnost povezivanja mreže linijskog servisa prema Baltiku.
4. Na jugu Europe postoji jasno ograničenje između tzv. *transhipment hub* luka i tzv. *gateway continetal* luka (luka direktnog prekrcaja brod – brod i luka prekrcaja brod – kopneno sredstvo). Luke Sjevernog mora kombiniraju oba sustava.

2.3 Trendovi razvoja prometa na relaciji sjever – jug Europe

Brodske kompanije imaju definiranu poslovnu strategiju. Slijedeći trenutne tržišne odnose i potrebe svojih klijenata neobično je važno uzeti u obzir i projekcije razvoja tržišta. Buduća konkurentnost na tržištu znači prilagođavanje novonastalim uvjetima. Upravo iz tih razloga one se moraju prilagođavati sljedećim trendovima:

1. Najveće strukturne promjene očekuju se u sjevernojadranskim lukama. Ekonomski razvoj Slovenije, Hrvatske i Mađarske rezultirat će boljom prometnom infrastrukturom i ekonomskom integracijom u europski sustav. Razvoj kopnene infrastrukture prema Mađarskoj ojačat će poziciju luke sjevernog Jadrana prema konkurentskim lukama Sjevernog mora.
2. Razvoj tržišta sjeverne Europe, ako se sagledaju i pesimistične prognoze, pokazuje snažan rast čak i u apsolutnim mjerilima. Rezultat tih kretanja stalna je potreba jačanja kapaciteta multimodala.
3. Trend rasta kapaciteta kontejnerskih brodova i rasta kapaciteta kontejnerskih terminala rezultirat će tzv. modelom "status-quo" na tržištu srednje Europe. To znači da u relativnom mjerilima odnosa sjever - jug u budućnosti ne treba očekivati značajne promjene.

Grafikon 1. Ukupni unutarnji i vanjski, kopneni i pomorski troškovi za kontejner iz pravca Azije prema Europi za niz europskih gradova

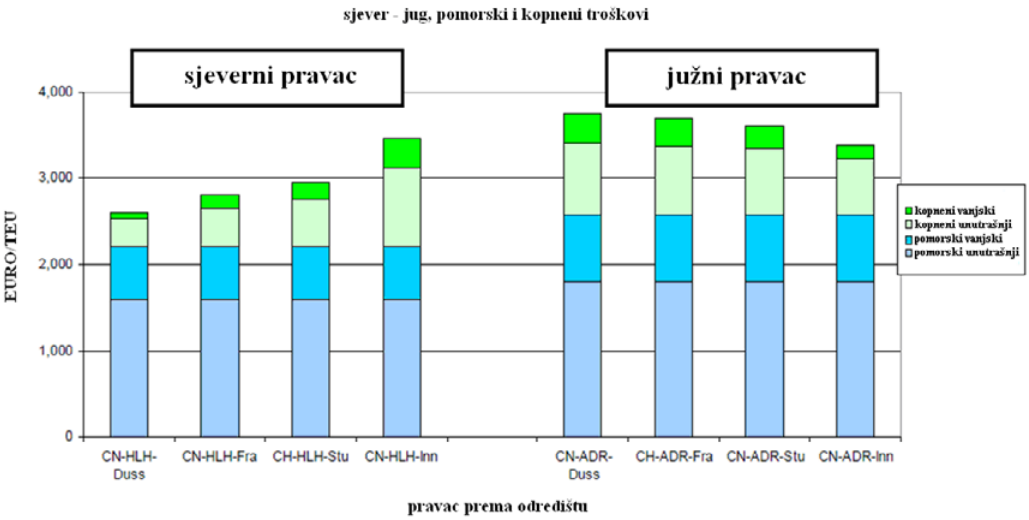

Izvor: http://www.panteia.eu/nl/Brands/NEA.aspx (3. 2. 2014.)

Na grafikonu 2 mogu se vidjeti ukupni troškovi po jedinici kontejnera za gradove Dusseldort, Franfurt, Studgart i Inngolstadt koristeći sjeverni ili južni pravac. Južni pravac skuplji je u prvenstveno pomorskim troškovima.

3. PREDNOST I NEDOSTACI KORIŠTENJA PROMETNIH PRAVACA IZ DALEKOG ISTOKA PREMA EUROPI

3.1 Europska prometna politika

Europa unija u segmentu prometnih aktivnosti danas je izrazito usmjerena prema stvaranju pretpostavki srednjoročnog i dugoročnog trenda razvoja prometa na velikim udaljenostima, u odnosima različitih modela prijevoza te međuodnosu klimatskih promjena i ekonomskog razvoja. Važan segment proučavanja je tržište kontejnerskog prometa na relaciji Azija -Europa koje kontinuirano raste kao rezultat specifičnih oblika globalizacije. Ta globalizacija prvenstveno se ogleda u visokom omjeru razvoja proizvodnje, odnosno investiranju u proizvodne kapacitete na području Kine. Pokazatelji rasta kontejnerskog prometa pokazuju veoma uzlazne trendove kroz Sueski kanal.

Povijesno govoreći, transatlanski pravac, tzv. "short-sea" promet i ostali prometni pravci izuzetno su bitni iz domene europskih prometnih kretanja, no svi pokazatelji govore da se najveći trend rasta i dalje očekuje na prometnom pravcu kroz Sueski kanal.

Postoje tri bitna pokazatelja za tu tvrdnju:

1. rast europskog kontejnerskog prometa
2. rast u veličini kontejnerskih brodova orijentiranih prema Sueskom kanalu
3. rast pomorskog prometa kroz Mediteran.

Europska prometna politika prilagođava se ranije navedenom trendu u smjeru maksimaliziranja ekonomskih i vanjskih prednosti. U 2011. godini Europska komisija kroz Bijelu knjigu (EC White Paper) u članku 392 osvrnula se na model tzv. "short sea shipping" tvrdnjom (http://ec.europa.eu/white-papers/index_en.htm (4. 2. 2014.)):

"*Europska infrastrukturna politika za luke mora posvetiti posebnu pažnju i osigurati dobru povezanost kopnenog transportnog sustava i luka kroz cijeli obalni pojas Europske unije. To se mora postići kroz puno izbalansiraniju distribuciju ulaza i izlaza roba u europski prometni sustav. Luke će pri tome trebati unaprijediti pristupačnost, kvalitetu i pouzdanost obavljanja svojih djelatnosti*".

3.2 Strategija ticanja određene luke

U slučaju kontejnerskog prometa na relaciji Azija – Europa neophodno je istražiti i optimalizirati kombinaciju pomorskog i kopnenog transporta, odabrati određenu luku i potencijalne utjecaje na eventualne buduće promjene.

Ako se osvrne na tzv. mikrorazinu i pokuša matematički doći do rješenja, dolazi se do sljedećih postavki:

München je udaljen od luka Beneluxa (Antwerpen, Zeebruge, Amsterdam, Rotterdam) oko 830 km cestom, dok je udaljenost do neke luke Jadrana oko 550 km. Udaljenost morskog puta između Italije i delte Rajne je oko 2.600 nautičkih milja (4.815 km). Kontejner iz Kine za konačnu destinaciju München može uštedjeti 280 km kopnenog puta i 4.815 km morskog puta skretanjem sa sjevernog pravca na južni.

Ovaj primjer pokazuje prednosti korištenja tzv. „južnog pravca" u odnosu na „sjeverni". Može se reći da ovaj primjer i sugerira skretanje roba sa sjevera prema jugu europskog kontinenta. U praksi, međutim, ovo skretanje nije se dotaklo prijevoznih kompanija koje kontroliraju tržište prijevoza kontejnera. Navedeni primjer ne stvara ukupnu sliku. Zašto? Odgovor se može naći u logici funkcioniranja brodova u linijskom servisu koji je vrlo jasan i nadasve jednosmjeran. Brodske kompanije u linijskom servisu koriste "hub" luke i vežu se na transportne mreže. Alternativa tome su servisi, "od točke do točke" i valorizacija ranije navedenog primjera kontejnera iz Kine prema Mediteranu.

Analiza učinaka takve strategije brodara nedvosmisleno govori o potrebi njihova planiranja na bazi funkcioniranja sustava (tzv. "system - based"), za razliku od planiranja na bazi slučaja (tzv. "case - based").

Navedena tvrdnja o načinu planiranja brodara zahtijeva analizu morskog, ali i kopnenog transporta i sustava distribucije. To znači i preduvjet ticanja luka globalnih brodara na prometnom pravcu Azija – Europa. Potpuno je razvidno da su glavni europski pomorski robni

tokovi (Daleki Istok i Sjeverna Amerika) pokriveni upotrebom velikih kontejnerskih brodova koji dotiču vrlo mali broj luka.

Da bi maksimalizirali prometni učinak, veliki kontejnerski brodovi koji u europski prostor dolaze preko Sueskog kanala tiču relativno mali broj luka i potpuno su koncentrirani na početak i kraj rotacije brodske linije.

Na zemljovidu 1 u nastavku vidi se tipičan primjer linije prema Dalekom istoku koja ima najmanje tri ticanja u lukama sjeverne Europe, jedan na delti Rajne, jedan na području sjeverozapadne Njemačke i jedan na području Ujedinjenog Kraljevstva.

Ovaj primjer pokazan na zemljovidu brodska je linija s Dalekim istokom najvećeg svjetskog brodara Maersk line. U okviru ove brodske linije kontejneri predviđeni za Europu imaju ishodišnu točku iz četiri kineske luke i dalje prema Tanjung Pelepas u Maleziji.

Zemljovid 1. Azija – Europa, linijski servis, kompanija Maersk

Izvor: www.maersk.com (3. 2. 2014.)

Na svom putu prema Europi poslije Sueskog kanala sav teret predviđen za odredište mediteranskog dijela Europe i afričkih država iskrcava se u luci Tangier u Maroku. U nastavku brodske linije prema Sjevernom moru za prostor sjeverne Europe teret se iskrcava u lukama Felixstowe, Bremerhaven i Rotterdam. Ostale brodske kompanije imaju slične rasporede luka, alternativno prema Antwerpenu, Hamburgu i Southamptonu.

U navedenim rasporedima ovih brodskih linija razlikuju se četiri važne karakteristike:

1. Kada kontejnerski brod napusti luku Yantian u Kini na putu prema Europi, u rasporedu ima vrlo mali broj luka do prostora sjeverne Europe.
2. Brod ima minimalnu devijaciju od najkraće moguće rute između luka Šangaja i Bremenhavena.
3. Ukupni broj luka ticanja broda vrlo je mali. U rasporedu plovidbe brod tiče samo dvije, tzv. „transhipment" luke, a to su Tangier i Tanjung, zamijenivši pritom niz tzv. „gateway" luka na području zamalja Aseana i regije Mediterana.
4. Luke tzv. „transhipmenta" u ovom slučaju su vrlo moderne i efikasne. Zajedničko im je upravljanje terminalom od strane operatora APM Terminals (AP Maller – Maersk Group) s mogućnosti prijama trenutno najvećih kontejnerskih brodova na svijetu.

Ovaj primjer pokazuje strategiju vodećih brodskih kompanija koje posluju u vrlo konkurentnim uvjetima svjetskog pomorskog tržišta. Karakterističan je visok stupanj kontrole nad pomorskim servisom i težnja za optimalizacijom transportne mreže koja reducira broj ticanja luka. Tzv. „hub" luke Mediterana i jugoistočne Azije omogućavaju pristup regionalnim transportnim mrežama. Može se uočiti vrlo velika sličnost ove strategije kontejnerskih brodskih kompanija s linijskim servisom aviokompanija, kroz visok stupanj specijalizacija, kroz upotrebu kontinentalnih i tzv. „low cost" aviokompanija.

Izbor luka ticanja megakontejnerskih brodskih kompanija mora biti kombinacija jake mreže brodskih linijskih servisa i efekata jake transportne mreže zaleđa luka. Rješenje optimalizacije tih transportnih lanaca su troškovi servisa kontejnerskih brodskih kompanija u odnosu na odabir luke i veličinu broda.

4. PODJELA PROSTORA EUROPE NA SJEVER I JUG

Podjelu europskog prostora na sjever i jug Europe izradila je konzultantska kompanija Etis Group za potrebe Europske komisije. Prostor Europe podijeljen je tako na osnovna četiri dijela (zemljovid 2). Dio srednje Europe podijeljen je na sjeverni središnji i južni središnji dio. Istočni dio Europe podijeljen je na sjever i jug kontinenta.

Zemljovid 2. Pozicioniranje europskog prostora

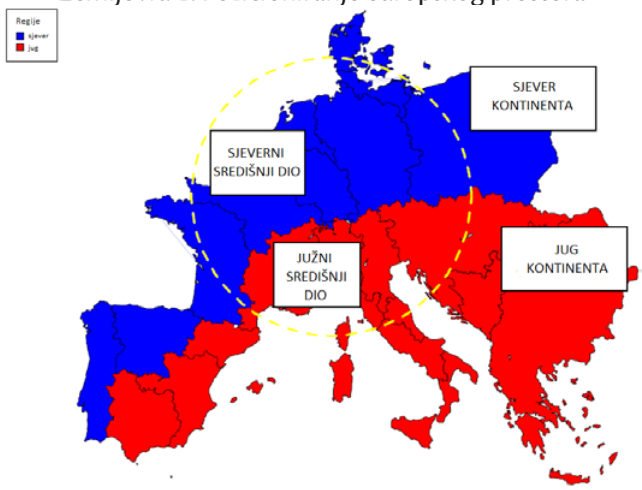

Izvor: www.etisplus.eu (4. 2. 2014.)

Na osnovi podataka o demografskoj strukturi stanovništva ovih četiriju prostora Europe došlo se do podataka da je ukupna populacija sjevernog središnjeg dijela Europe 69 % prema 31 % južnog središnjeg dijela (grafikon 2).

Grafikon 2. Udio populacije stanovništva

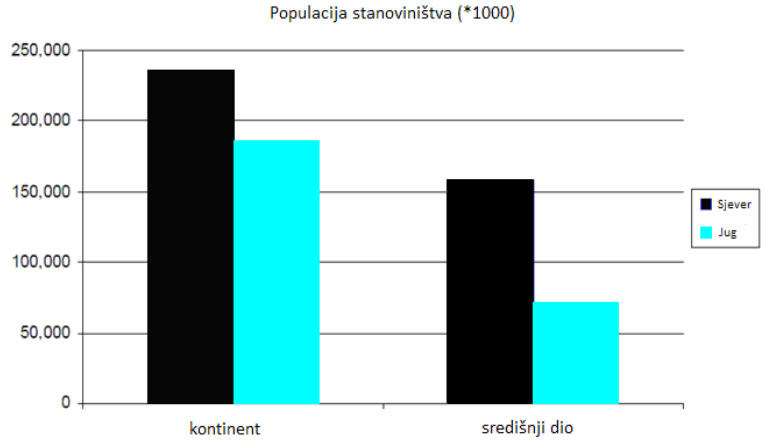

Izvor: www.etisplus.eu (4. 2. 2014.)

Razvijenost gospodarstva na ovim dijelovima prostora Europe izražena u GDP-u prikazana je grafikonom 3.

Grafikon 3. Udio razvoja gospodarstva

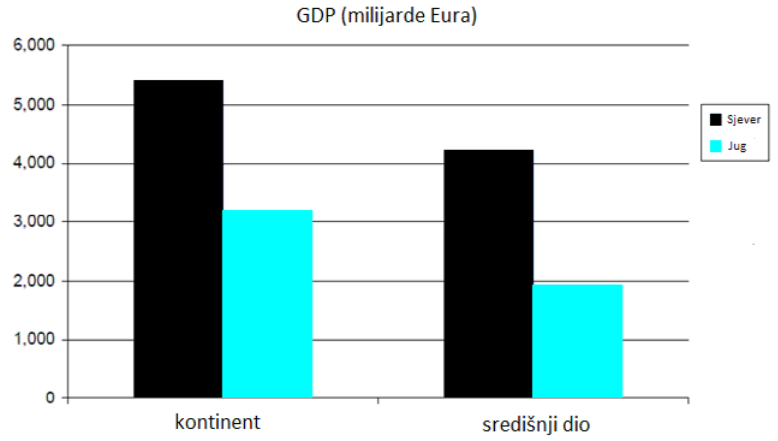

Izvor: www.etisplus.eu (4. 2. 2014.)

Uvozno-izvozne aktivnosti ovog dijela prostora Europe definirane su u podacima kontejnerskog prijevoza (grafikon 4 i 5)

Grafikon 4. Kontejneri (u mil. tona) uvoza/izvoza, 2005.

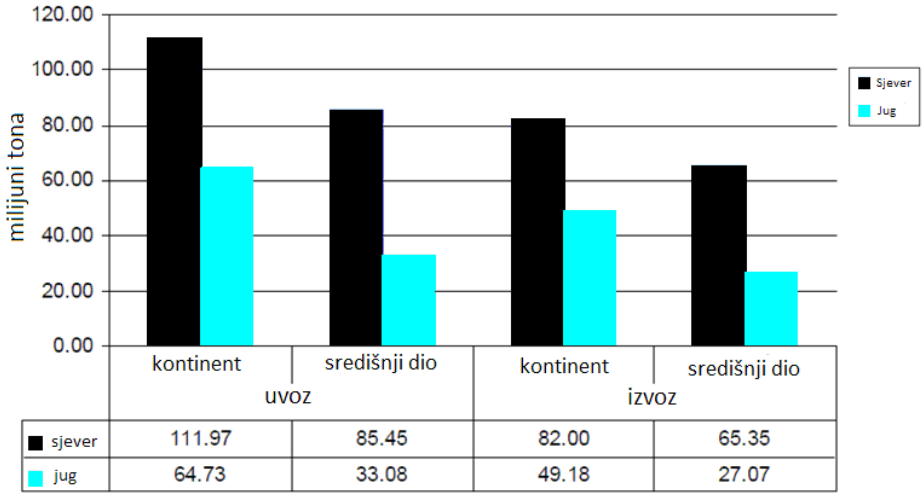

	uvoz		izvoz	
sjever	111.97	85.45	82.00	65.35
jug	64.73	33.08	49.18	27.07

Izvor: www.worldnet-shipping.com (5. 2. 2014.)

Grafikon 5. Kontejneri (u TEU) uvoza/izvoza, 2005.

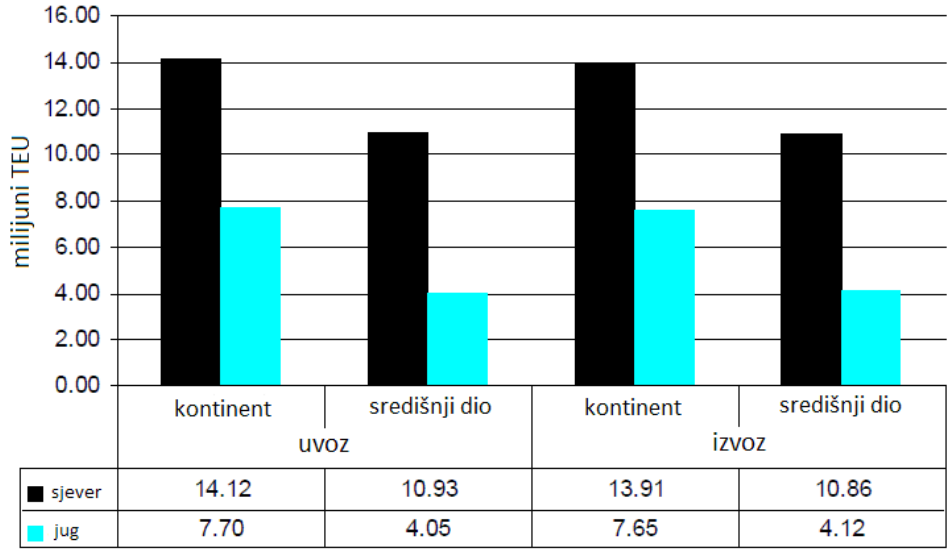

	uvoz		izvoz	
sjever	14.12	10.93	13.91	10.86
jug	7.70	4.05	7.65	4.12

Izvor: www.worldnet-shipping.com (5. 2. 2014.)

Po svim promatranim pokazateljima navedenim u prethodnim grafikonima može se prepoznati znatna dominacija sjevernog dijela Europe u odnosu na južni dio. Ta dominacija prvenstveno se ogleda u ekonomskoj razvijenosti prostora izraženoj u GDP-u. Sjever Europe pokazuje dominaciju u

razvijenosti robnih tokova kontejnera, što je u direktnoj korelaciji s razvijenošću GDP-a, no i podaci o demografskoj strukturi stanovništva pokazuju veću gustoću sjevernog dijela prostora Europe.

5. UDJELI PROMETA U EUROPSKIM LUKAMA SJEVERA I JUGA

5.1 Gravitacijsko područje luka

Uzevši u obzir distribucijsku potražnju neke robe kroz robne tokove Europe, može se zaključiti da regija sjevernog kontinentalnog dijela ima 65 % udjela. Sjeverni središnji dio ima distribucijsku potražnju robe u 72 % udjela. Ovi podaci dobiveni su kroz statistiku godišnjeg prekrcaja luka u sjevernom kontinentalnom i sjevernom središnjem dijelu Europe (www.etisplus.eu (4. 2. 2014.)).

Zemljovid 3 pokazuje sve kontejnerske luke pripadajuće države te veće gradove Europe. Ovdje je prikazano 60 kontejnerskih luka, što ukupno prekrcavaju 535 milijuna tona u kontejnerima ili 66 milijuna TEU.

Glavni predmet proučavanja su prekomorski uvozno-izvozni robni tokovi. U slučaju prometnog pravca uvoza kontejneri dolaze iz Dalekog istoka prema prostoru Europe i preusmjeravaju se prema cestovnom, željezničkom i prijevozu unutarnjim plovnim putem.

Njemačke luke imaju gravitacijsko područje Danske, Njemačke, Poljske, Češke, Slovačke, Austrije, pa čak i dijela Mađarske i Rumunjske. Upravo na ovom središnjem dijelu europskog prostora proteže se i gravitacijsko područje luka sjevernog Jadrana (Rijeka, Kopar i Trst). Postoje vrlo mali objektivni razlozi odabira kretanja robnih tokova na ovom središnjem dijelu europskog kontinenta prema jugu ili prema sjeveru.

Zemljovid 3. Kontejneri (u tonama) 2008. godine, ukupni godišnji statistički podaci luke

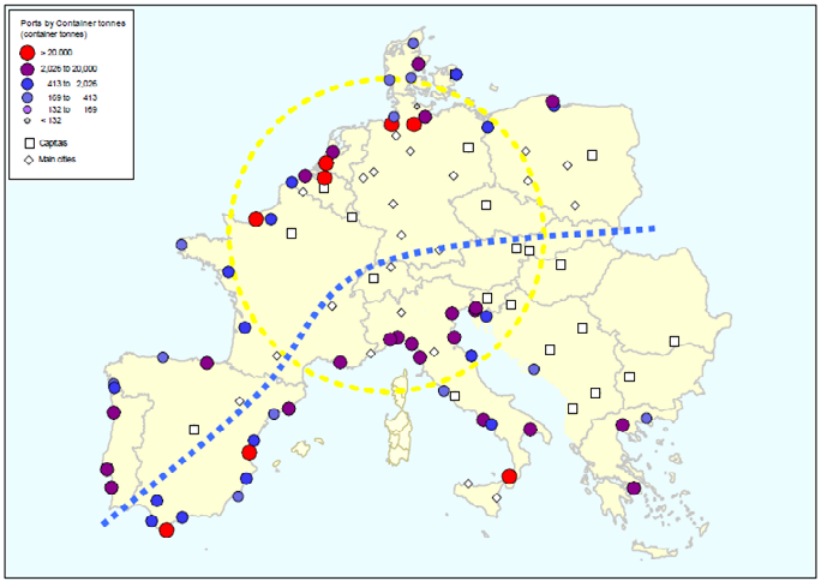

Izvor: izradili autori na osnovi raspoloživih podataka Panteia/NEA
(http://www.panteia.eu/nl/Brands/NEA.aspx (3. 2. 2014.))

Dobar primjer koji može potkrijepiti ovu tvrdnju je područje Austrije. Podaci dobiveni od Austrijske trgovačke komore (www.wko.at (5. 2. 2014.)) pokazuju da je Austrija geografski dio gravitacijskog područja sjevernojadranskih luka, no s visokim udjelom kretanja prekomorskih robnih tokova austrijskog gospodarstva prema lukama Njemačke, Nizozemske i Belgije.

Zemljovid 4. Kretanje robnih tokova istočnog dijela Europe

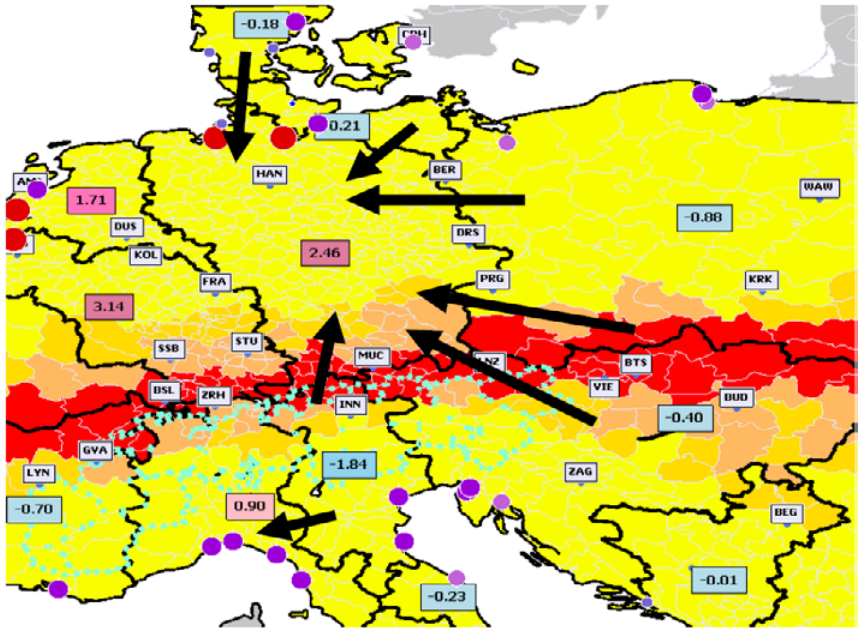

Izvor: www.worldnet-shipping.com (5. 2. 2014)

Podaci pokazuju da je luka Rotterdam 2009. godine bila glavna uvozna luka Austrije. Iste godine luka Hamburg bila je njena glavna izvozna luka. Danas je glavna uvozno-izvozna luka Austrije luka Kopar, dok luke Trst i Rijeka imaju vrlo mali udio.

Tablica 1. Luke austrijskog prekomorskog uvoza

	Uvoz u tisućama tona	
	2010.	2009.
Koper	3.296	2.025
Rotterdam	2.865	3.250
Hamburg	1.136	897
Antwerp	1.008	952
Constanta	557	237
Bremerhaven	92	85
Rijeka	33	36
TOTAL	8.988	7.483
Udjeli sjevera	57 %	69 %

Izvor: www.wko.at (5. 2. 2014.)

Tablica 2. Luke austrijskog prekomorskog izvoza

	Izvoz u tisućama tona	
	2010.	2009.
Hamburg	1.716	1.504
Koper	1.651	1.324
Bremerhaven	1.147	1.050
Antwerp	952	878
Rotterdam	695	820
Rijeka	227	251
Constanta	35	12
TOTAL	6.422	5.839
Udjeli sjevera	70 %	73 %

Izvor: www.wko.at (5. 2. 2014.)

5.2 Pomorski linijski prijevoz direktnog ticanja luka Dalekog istoka i Europe (direktni servis)

Pomorski prijevoz i svi parametri vezani uz njega uvelike utječu na izbor ticanja pojedine luke. Izbor pomorskog pravca sjever ili jug Europe ovisi o smanjenju troškova brodskih linija.

Uzevši u razmatranje primjer kretanja robnih tokova tako da kontejner dolazi u Europu kroz Sueski kanal, može se doći do nekoliko interesantnih pokazatelja. Evidentno je da je razdaljina plovidbe od izlaska iz Sueskog kanala do bilo koje luke sjevernog Mediterana od Barcelone do Rijeke kraća nego razdaljina do luka na Sjevernom moru od Le Havra do Hamburga.

Ako se tiču luke na jugu Europe umjesto luka na sjeveru, u pomorskoj plovidbi između Azije i Europe može se uštedjeti otprilike 4.000 kilometara.

Postavlja se logično pitanje - zašto brodske kompanije u cilju valorizacije te uštede ne koriste više luke južnog pravca, odnosno Mediterana. Jedan od odgovora na ovu nedoumicu može dati primjer rasporeda linija francuske tvrtke CMA-CGM za sjevernu Europu, zapadni Mediteran, Jadran i Crno more.

Zemljovid 5. CMA-CGM linijski servis za Sjevernu Europu (FAL 1)

Izvor: http://www.cma-cgm.com/ (3. 2. 2014.)

Zemljovid 6. CMA-CGM linijski servis za Jadran (BEX 2)

Izvor: http://www.cma-cgm.com/ (3. 2. 2014.)

Zemljovid 7. CMA-CGM linijski servis za Crno more (BEX)

Izvor: http://www.cma-cgm.com/ (3. 2. 2014.)

Zemljovid 8. CMA-CGM linijski servis za zapadni Mediteran (MEX)

Izvor: http://www.cma-cgm.com/ (3. 2. 2014.)

Svaki od ova četiri brodska servisa sastoji se od grupe brodova koji tiču određene luke. Kontejneri za konačnu destinaciju u Europi sortirani su prema lukama koje gravitiraju toj destinaciji, a dolaze, primjerice, iz Šangaja. Ti kontejneri transportiraju direktno prema regijama Europe. Sva ta roba prolazi Sueski kanal, ali brodovi svoj put tu ne završavaju.

Brodovi koji dolaze na Sjever su iz različite grupe brodova od onih koji dolaze na Jug, a i sav raspored linija potpuno je drugačiji. Svi financijski troškovi linija i ticanja luka, te razdaljine potpuno su različiti.

Troškovi linija u relaciji su s ukupnim transportom iz Kine/Koreje/Japana do Europe, a nisu samo relativno manje relacije između Sueskog kanala i konačne luke u Europi. Usporedba je napravljena između četiri linijska servisa:

Tablica 3. Direktni linijski servis megakontejnerskog brodara CMA-CGM

	Sjever Europe	Sjeverni Mediteran	Jadran	Crno more
Naziv linije	FAL 1	ME	BEX2	BEX
Rotacija u danima	70	77	63	77
Broj rotacija godišnje	52	52	52	52
Broj luka ticanja	16	23	16	19
Broj brodova u liniji	10	11	9	11
Veličina brodova (TEU)	11388	8400	6572	6552
Godina gradnje brodova	2009.	2010.	2010.	2010.
Brzina (čvorovi)	25	24	24	26

Izvor: http://www.cma-cgm.com/ (3. 2. 2014.)

Svaki od ova četiri linijska servisa nudi tjednu frekvenciju na osnovi jedanaest brodova u rotaciji koja traje od 63 do 77 dana po putovanju. Svaki brod godišnje napravi oko 5 rotacija. Svaka linija koristi nove brodove s približno istim brzinama plovidbe.

Može se razlikovati nekoliko bitnih parametara između ovih četiriju linijskih servisa:

1. Brodovi na liniji za sjevernu Europu imaju gotovo dvostruki kapacitet kontejnera, naravno i tereta u odnosu na liniju za Jadran i Crno more; 1.138 TEU prema 6.552 TEU

2. Rotacija za sjever ima duži plovidbeni put, vrijeme putovanja linije za sjevernu Europu (70 dana) kraće je nego vrijeme putovanja linije za zapadni Mediteran ili Crno more (77 dana). Ta razlika ogleda se u manjem broju luka ticanja (luka linije) i veće efikasnosti luka sjevera Europe.

Na temelju navedenog može se zaključiti:

1. Jednom kada se brodska linija uspostavi, najveći dio troškova je konstanta, i to po brodu godišnje. Kapitalni troškovi, posade i goriva su definirani. Prosječni troškovi po kontejneru ovise o popunjenosti kapaciteta broda i relativno su mali po kontejneru.

2. Na ovom primjeru brodskih kontejnerskih linija CMA-CGM (isto vrijedi za veliku većinu megakontejnerskih brodara) može se vidjeti tzv. „transit time", odnosno frekvencija ticanja brodova prema određenoj luci 7 dana za sve 4 prikazane linije. Na taj način se logističkim operatorima, odnosno korisnicama usluga brodskih linija omogućava vrlo jednostavno prebacivanje svojih kontejnera s jedne linije na drugu, npr. sa sjevera Europe (FAL 1) prema zapadnom Mediteranu (MEX) ili po potrebi Jadranu (BEX2). Na ovaj način megakontejnerski brodar prilagođava se uvjetima vrlo jake konkurencije na tržištu. Osim toga postoji izrazito velik potencijal optimalizacije cijelog transportnog lanca.

5.3 Pomorski linijski prijevoz indirektnog ticanja luka Dalekog istoka i Europe (*feeder* servis)

Prethodno je prikazan direktni linijski servis megakontejnerskog brodara CMA-CGM.

Dok su kompanije kao CMA-CGM i Hyndai Merchant Marine u promatranom razdoblju koristile direktni linijski servis iz Dalekog istoka, ostale su koristile indirektni ili tzv. *feeder* servis (zemljovid 9 i 10).

Zemljovid 9. NYK servis Jadran, ADS1

Izvor: www2.nykline.com (4. 2. 2014.)

U ovom slučaju kontejnerski brodar NYK Line (dio tzv. Grand Alliance) kontejnere na putu iz Dalekog istoka prema Jadranu iskrca u talijanskoj HUB luci Taranto. Kontejneri se u tzv. „transhipmentu" ukrcavaju na *feeder* kontejnerske brodove u lukama Ancona, Ravena i Trst.

Zemljovid 10. NYK servis Jadran, ADS2

Izvor: www2.nykline.com (4. 2. 2014.)

Ovaj linijski servis (zemljovid 10) predviđa sličan scenarij i povezuje luku Taranto s lukama Venecijom, Koprom i Rijekom.

Tablica 4. *Feeder* servis u Jadranu

	Jadran
Naziv linije	ADS
Rotacija u danima	7
Broj rotacija godišnje	90
Broj luka ticanja	4
Broj brodova u liniji	2
Veličina brodova (TEU)	1700
Godina gradnje brodova	2000
Brzina (čvorovi)	20,5

Izvor: www2.nykline.com (4. 2. 2014.)

Ovakva vrsta indirektnog (*feeder*) linijskog servisa omogućava brodskim kompanijama dovoz kontejnera većim kontejnerskim brodovima iz Dalekog istoka do Mediterana i to do većih HUB luka kao što je Taranto (14,3 metra gaza). U tom slučaju kontejnerski brodovi u liniji imaju minimalnu devijaciju rute prema lukama sjeverne Europe.

Na ovaj način kontejneri se prevoze vrlo efikasno do HUB luke, ali stvara se problem dodatnih troškova *transhipmenta* u toj HUB luci i kašnjenja za dodatni prijevoz *feeder* brodom do konačnog odredišta.

Dok se za konačnu destinaciju na sjeveru Europe koriste kontejnerski brodovi maksimalnog kapaciteta (megakontejnerski brodovi), za Jadran se koriste u kombinaciji s manjim kontejnerskim brodovima (*feeder*) za indirektno ticanje odredišne luke.

Indirektni linijski servis u ovom slučaju ima sljedeće karakteristike:

Kategorija 1 – glavni interkontinentalni linijski servis koristi megakontejnerske brodove

(> 10.000 TEU)

Kategorija 2 – sekundarni interkontinentalni linijski servis koristi srednje kontejnerske brodove (4.000 – 10.000 TEU)

Kategorija 3 – *feeder* linijski servis koristi manje kontejnerske brodove (1.000 – 3.000 TEU)

5.4 Parametri za donošenje odluke brodara o ticanju određene luke

Luke sjeverne Europe i HUB luke Mediterana (npr. Taranto, Tangier, Algeciras i Gioa Tauro) imaju karakteristike kategorije 1. luke tzv. *gateway* južne Europe (npr. Rijeka, Kopar, Trst, Venecija) imaju karakteristiku kombinacije kategorija 2. i 3.

Ključni parametri za donošenje odluke brodara o primjeni određene kategorije su:

1. Popunjenost kapaciteta broda
2. Dovoljan gaz i potrebna prekrcajna oprema pojedine luke
3. Namjera brodara za ticanje što manjeg broja luka,
4. Više ticanja luka znači veći promet brodara, ali i veće lučke troškove.

6. SJEVERNOJADRANSKI PROMETNI PRAVAC KAO DIO JUŽNOG EUROPSKOG PRAVCA

Iz tablica 1. i 2. točke 5. može se zaključiti rast udjela uvoza i izvoza Austrije prema luci Kopar, odnosno južnom pravcu Europe.

Povećanje robnih tokova prema jugu posljedica je stvaranja pomorskih i kopnenih uvjeta. Luka Kopar povećala je kapacitet pretovara roba investiranjem u nove kontejnerske dizalice i proširenjem postojećeg kontejnerskog terminala.

Uvođenjem novih željezničkih operatora slovenske željeznice stvorile su kopnene uvjete koji su konkurentni sjevernomorskim lukama i njihovim pripadajućim prometnim pravcima. Kombinacija pomorskih i kopnenih uvjeta koji su navedeni u točki 2 ovog članka rezultiraju interesom velikih brodskih kontejnerskih kompanija za optimalizaciju svojih transportnih lanaca.

Smanjenje troškova po jedinici kontejnera je dinamički proces. Luka Kopar i slovenske željeznice napravile su značajan korak prema zadovoljavanju interesa brodarskih kompanija koje posluju u izuzetno konkurentnim uvjetima.

Luke sjevernog Jadrana konkuriraju međusobno s osnovnim ciljem povećanja prometa roba koje se može desiti samo privlačenjem brodara i skretanja robnih tokova.

Povećanjem udjela u robnim tokovima Austrije luka Kopar postala je lider na sjevernom Jadranu u kontejnerskom prometu. U ovom slučaju, međutim, luka Kopar nije samo konkurent ostalim lukama sjevernog Jadrana, već značajan čimbenik jačanja cijelog južnog pravca Europe.

Od jačanja konkurentske sposobnosti luke Kopar i slovenskog prometnog pravca koristi mogu imati i sve luke u okruženju. Optimalizacija transportnih lanaca preko prometnih pravaca riječke luke i luke Trst brodarske kompanije mogu dobiti dodatne opcije za preusmjeravanje robnih tokova i zadovoljavanje svojih poslovnih ciljeva.

Riječka luka mora zadovoljiti pomorske i kopnene uvjete da bi značajnije privukla robne tokove. Brodarske kompanije samo će zadovoljavanjem njihovog osnovnog cilja, a to je smanjenje troškova po jedinici kontejnera, prepoznati mogućnost optimalizacije svog transportnog lanca.

7. ZAKLJUČAK

Robni tokovi europskog kontejnerskog prometa pokazuju snažan rast poglavito u prometnom pravcu prema Dalekom istoku. Roba, proizvod, kontejner koji je naručen na prostoru zemalja Dalekog istoka (Kina, Južna Koreja, Japan i dr.) na svom putu prema konačnoj destinaciji, Europi, prolazi kroz Sueski kanal. Nakon prolaženja Sueskog kanala od strane kontejnerskog broda postoji cijeli niz preduvjeta ticanja pojedine luke, odnosno odabira konačnog prometnog pravca. Odabir konačnog prometnog pravca do konačne destinacije robe je kombinacija pomorskih i kopnenih parametara u logističkom lancu. Kopneni parametri ogledaju se u razvijenosti mreža kopnenog prijevoza. Pomorski parametri ogledaju se u strategiji pojedinih kontejnerskih linijskih servisa. Strategija megakontejnerskih brodarskih kompanija je ticanje što je moguće manje luka, s time da je najveći broj luka na pojedinoj rotaciji linijskog direktnog prijevoza na samom početku i na kraju putovanja. Između tih dviju točaka tiče se relativno mali broj luka, pretežno luka tzv. *transhipmenta*. Sve linije megakontejnerskih brodara na pravcu Daleki istok prema Europi imaju tu istu strategiju. Razlika je samo u tome, da koriste različite veličine brodova prema određenoj liniji. Najveći mogući kontejnerski brodovi koriste se za linije prema lukama sjeverne Europe, što je srazmjerno veličini robnih tokova te regije. Karakteristika tih direktnih kontejnerskih linija je i zajednički tzv. „transit time", odnosno vrijeme između ticanja pojedine luke brodova na istoj liniji. Isti „transit time" omogućuje veoma efikasno skretanje pojedinih kontejnera s pojedine linije istog brodara. Rezultat koji se postiže je optimalizacija transportnog lanca u izuzetno konkurentnom tržišnom okruženju.

Izbor pojedinih luka u linijskom prijevozu ovisi o mnoštvu parametara. Luke se bore na pomorskom tržištu za privlačenje brodara, a time i robnih tokova. Luke južnog dijela Europe po svojoj efikasnosti i s mrežom kopnenih servisa ne mogu se nositi s razvijenim lukama sjevera Europe. Korištenjem južnog pravca brod na svojem putovanju može uštedjeti od 7 do 10 dana u odnosu na korištenje sjevernog pravca. Time se štedi na troškovima broda, dobiva više na vremenu dolaska robe, a osim toga i emisija ugljikova dioksida je znatno manja.

Svi ovi parametri nisu dovoljni da roba, ponajprije kontejneri, nađu masovni put prema južnom pravcu. Središnji dio Europe podijeljen na središnji sjeverni i središnji južni prostor odlikuje se znatno većim vrijednostima GDP-a. Sukladno tome i kontejnerski robni tokovi su izraženiji na sjevernom dijelu. Demografski podaci pokazuju veću gustoću stanovništva na sjevernom središnjem dijelu Europe u odnosu na južni. Izjednačenost robnog prometa u uvozu i izvozu sjevernog središnjeg prostora na pravcu prema Dalekom istoku je vrlo značajan parametar odabira luka sjevera. Mreža kopnenih servisa i povezivanje pojedinih luka sjevera je na vrlo visokoj prometnoj razini i južne luke u dogledno vrijeme ne mogu tome konkurirati. Sve projekcije prometa za srednjoročno i dugoročno razdoblje u Europi ne pokazuju nikakva bitna odstupanja od današnjih relacija sjevera i juga.

Luke sjevernog Jadrana dijele sudbinu cijelog južnog prometnog pravca. Razvoj gospodarstava zemalja srednje i istočne Europe, odnosno južnog središnjeg prostora Europe može rezultirati daljnjim jačanjem konkurentnosti tih luka. Pozitivan primjer u posljednje vrijeme je povećanje robnog prometa Austrije prema luci Kopar, odnosno preuzimanju dijela robnih tokova kontejnera sa sjevera (luka Rotterdam). Luka Kopar je postala glavna uvozna luka Austrije, bez obzira što je područje Austrije njeno gravitacijsko područje. Razlog skretanja robnih kontejnerskih tokova sa sjevera prema jugu Europe treba tražiti u kombinaciji jačanja mreže kopnenih servisa (prvenstveno novim željezničkim operatorima) i pomorskih servisa (jačanje mreže linijskih servisa).

LITERATURA

Šamanović, J. (1999) *Logistički i distribucijski sustavi*, Split: Sveučilište u Splitu, Ekonomski fakultet Split

Borg, J. (2005) Morske luke u kontekstu europske prometne politike, Valetta: ESPO, Konferencija europskih morskih luka

Izvori s interneta:

www.maersk.com (3. 2. 2014.)

http://www.cma-cgm.com/ (3. 2. 2014.)

www2.nykline.com (3. 2. 2014.)

http://www.panteia.eu/nl/Brands/NEA.aspx (3. 2. 2014.)

www.etisplus.eu (4. 2. 2014.)

http://ec.europa.eu/white-papers/index_en.htm (4. 2. 2014.)

www.wko.at (5. 2. 2014.)

Bojan Hlača [1]
Dušan Rudić [2]
Erika Gržin [3]

Preliminary communication
UDC 656.073.235

CONTAINER TRAFFIC ON THE FAR EAST – NORTH OR SOUTH EUROPE ROUTE[4]

ABSTRACT

The container cargo flows on the Far East - Europe route show continuous growth trends. Such traffic projections mobilize all participants in the logistics chain – from ordering to final delivery of goods. The container transport chain on the global market must be defined in a manner which will allow continuous optimization of the same. The backbone of container transport chain is a combination of maritime transport and road networks on the mainland, for transport of containers to their destination. Mega container companies have a similar strategy for the establishment of direct and indirect line shipping service. The strategy is based on the right selection of ports for the individual line. The selection of a particular port reflects the port's internal efficiency, but also the development of the mainland service network. The individual port's strength is a result of the hinterland's or, respectively, the gravitational area's economic development. In this paper, the central part of the European area is divided into North and South; the analysis of demographic and economic factors produced certain indicators which provide an answer to the paper's fundamental question, namely, the choice between North and South of Europe.

Key words: *container traffic, the Far East, North Europe, South Europe*

[1] PhD, College Professor, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: dusan.rudic@veleri.hr
[2] PhD, College Professor, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: bojan.hlaca@srce.hr
[3] Professional Specialist in Transport, Engineering, Ing. Traff., Assistant, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: erika.grzin@veleri.hr
[4] Received: 28. 2. 2014.; accepted: 5. 5. 2014.

Marko Kršulja [1]
Dario Bognolo [2]

Prethodno priopćenje
UDK 539.37:519.6

ODREĐIVANJE ALATNE GEOMETRIJE U OVISNOSTI O PONAŠANJU MATERIJALA TIJEKOM PROCESA OBRADE DEFORMIRANJEM[3]

SAŽETAK

U ovome istraživanju analizira se ponašanje lima X5CrNiMo17-12-2 tijekom procesa dubokog izvlačenja. Prikazana su mehanička i kemijska svojstva ispitivanog lima dobivena pomoću spektrometrije i standardnog vlačnog testa. U radu je ispitan osnovni proračun koji daje dobru pretpostavku očekivanog ponašanja materijala prilikom oblikovanja ulaznog uzorka u konačni oblik. Na temelju mehaničkih svojstava izvedena je simulacija ponašanja materijala metodom konačnih elemenata u softveru ABAQUS. Rezultati proračuna matematičkog modela alatne geometrije u ovisnosti o ponašanju materijala i simulacije su uspoređeni.

Ključne riječi: *deformiranje, duboko izvlačenje, čelični lim, MKE, modeliranje*

1. UVOD

Deformiranje metala objašnjava promjene u mikrostrukturi metala prilikom njegovog oblikovanja u konačan proizvod. Oblikovljivost se definira kao sposobnost materijala da se deformira određenim postupkom oblikovanja iz svog početnog oblika u zahtijevani oblik bez pojave greške. Duboko izvlačenje je tehnologija oblikovanja metala u hladnom stanju (iako se pojavljuje određena temperatura i nekim specifičnim slučajevima, može se obavljati i u toplom stanju) kod koje se pretvorbom iz ravne ploče u određeni geometrijski oblik izrađuju različiti proizvodi kao što su sudoperi, dijelovi automobila, kutije i slično. Riječ je, ukratko, o proizvodnji limenih proizvoda i preradi limova kod kojih postoji tendencija korištenja tanjih limova uz zadržavanje čvrstoće materijala, posebno u automobilskoj industriji. Manja masa automobila omogućava manju potrošnju energije za pokretanje automobila.

Vrlo je važno dobro odabrati parametre u procesu obrade kako bi se uspio napraviti gotov proizvod traženih dimenzijskih točnosti i svojstava. Problem netočnosti oblika koji je redovito važan česta je istraživačka tema te ga valja adekvatno istražiti (Filho et al., 2009; Kršulja et al., 2012). U procesu obrade deformiranjem dolazi do međudjelovanja geometrija alata tj. žiga i matrice. Položaj alata i matrice je definiran procesnom kinematikom stroja i njegovim mogućnostima. Putanja alata i utiskivanje

[1] Dr. sc., dipl. ing. strojarstva, asistent, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* krsulja.marko@veleri.hr
[2] Dipl. ing. strojarstva, predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* dbognolo@veleri.hr
[3] Datum primitka rada: 22. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

lima u matricu određenom brzinom i silom uzrokuje lokalne deformacije koje zajednički djeluju na konačan oblik. Sile u procesu i brzinu kretanja alata potrebno je uskladiti s ponašanjem lima koji se oblikuje (Aleksandrović et al., 2010). Pucanje lima u pojedinim segmentima ovisi o odabranim parametrima u procesu koji negativno utječu na mikrostrukturu. Pri tome je potrebno poznavati mehanizme nastanka dislokacija, ponašanje anizotropije te općenito ponašanje kristalnih zrna prije, tijekom i nakon procesa.

Alati i matrice mogu se proizvesti od različitih materijala. Osim u razlici u cijeni, takve razlike mogu pridonijeti i u razlici ponašanja konačnog proizvoda. Dakle, promjenom alata mijenjaju se uvjeti trenja i zagrijavanja s ciljem poboljšavanja mehaničkih osobina materijala (Plančak et al., 2012). U slučaju uporabe istih alata i mijenjaja vrsta limova zbog različitih mehaničkih svojstava i kemijske strukture, može doći do pojave pukotina i grešaka. U ovome istraživanju ispitat će oblici alata potrebnih za proizvodnju čašice visine h = 36 mm, te promjera di = 34,5 mm. Ispitat će se razlike matematičkog proračuna i simulacije metodom konačnih elemenata. Također, jedan od ciljeva je pratiti deformaciju materijala X5CrNiMo17-12-2 te ispitati sile koje utječu na naprezanja u procesu, a zatim i na postizanje konačnog oblika.

2. KEMIJSKA SVOJSTVA

U ovome istraživanju ispitana su kemijska svojstva lima X5CrNiMo17-12-2, oznaka čelika prema EN 10027-2 je W. nr. 1.4401, u nekim slučajevima označava se i s AISI 316. Običan čelični lim namijenjen postupku dubokog izvlačenja mora, uz nizak sadržaj ugljika i malu čvrstoću te visoku istezljivost, imati kemijski obrađenu površinu (tzv. dekapirani lim). Ovim se kemijskim postupkom na površini lima stvara tanki sloj fosfata koji će biti granični sloj i spriječiti izravni dodir čistih metalnih površina materijala i alata, a ujedno je i nosilac maziva koji se redovito rabi u postupku dubokog izvlačenja. Na taj način se sprječava ljepljenje lima za alat ili matricu. U tablici 1 prikazani su rezultati kemijske analize ispitivane epruvete. Ispitivanje je provedeno na Spektrometru GDS500A, Leco (Tehnički fakultet u Rijeci, laboratorij za ispitivanje materijala). Ispitane su tri epruvete i provedena su tri mjerenja na svakoj epruveti. Rezultati prosječno dobivenih vrijednosti pokazuju poklapanje dobivenih rezultata s propisanim standardom.

Tablica 1. Kemijski sastav ispitane epruvete i propisani kemijski sastav čelika (%)

Kemijski sastav	C	Si	Mn	P	S	Cr	Mo	Ni
X5CrNiMo 17-12-2	≤ 0,07	≤ 1,00	≤ 2,0	0,045	≤ 0,030	8,50 -16,50	2,0 - 2,5	10 - 13
Uzorak	0,0321	0,507	0,902	0,036	0,005	16,6	2,05	9,80

Izvor: obrada autora

3. MEHANIČKA SVOJSTVA

Vlačnim se testom utvrđuje međusobna zavisnost naprezanja i deformacije, a koja se prikazuje σ - ε (naprezanje - deformacija) dijagramom. Epruveta se pod aksijalnim opterećenjem razvlači do loma. Tijekom razvlačenja, materijal epruvete pruža otpor i epruveta se produljuje. Na dijagramu se zapaža točka najveće vlačne čvrstoće, a taj je trenutak praćen značajnim suženjem presjeka epruvete. Nakon toga dolazi do daljnjeg produljenja epruvete što je popraćeno smanjenjem čvrstoće materijala te konačno do loma. Plastično ponašanje materijala započinje kada se ustanove trajne i nepovratne deformacije. U standardiziranim ispitivanjima, zbog poteškoće određivanja točke tečenja kod materijala koji nemaju izraženu granicu tečenja, koristi se naprezanje $R_{p0,2}$ ($\sigma_{0,2}$), tj. naprezanje pri kojemu ostaju trajne deformacije od 0,2 % (ε = 0,002). Dimenzije epruveta su standardizirane.

U stvarnom se dijagramu naprezanje-deformacija ponašanje materijala može opisati tzv. Holloman-Ludwigovom relacijom. Jednadžba koja se koristi u području proporcionalnosti je Hookeova relacija:

$$\sigma = E \cdot \varepsilon, \sigma = E \cdot \varepsilon, \qquad (1)$$

gdje je:

σ - naprezanje, E - Youngov modul elastičnosti, ε - deformacija. Relacija kojom se opisuje ponašanje materijala pri tečenju često se piše u obliku:

$$\sigma = C \cdot \varepsilon^{n}, \qquad (2)$$

što predstavlja tzv. Holloman - Ludwigovu relaciju. U području tehnologije obrade materijala zapis se ove relacije može naći i u obliku:

$$k_f = C \cdot \varphi^n \, k_f = C \cdot \varphi^n. \qquad (2a)$$

U izrazima (2 i 2a), prva veličina lijeve strane (σ odnosno k_f) predstavlja naprezanje tečenja, C je faktor materijala, dok je ε odnosno φ - deformacija. Pri procesima plastičnih obrada izradaka, kada se pojavljuju velike deformacije, za njihov se opis rabi geometrijska deformacija. Nadalje, eksponent očvršćivanja n može imati vrijednosti od n = 0 (idealno plastičan) ili n = 1 (elastičan). Za većinu metala eksponent očvršćivanja n ima vrijednosti između 0,10 i 0,50. Na veličinu faktora materijala C i eksponenta očvršćivanja n utječe vrsta materijala, brzina deformacije, temperatura te veličina i oblik kristalnog zrna.

Grafikon 1 prikazuje metodu izrezivanja epruveta kod ispitivanja jednoosnog stanja naprezanja i ponašanje materijala pri različitim kutovima 0°, 45° i 90° od smjera djelovanja opterećenja valjanja. Smjer orijentacije valjanja lima prilikom njegove proizvodnje ima značajne posljedice (anizotropija) u operacijama dubokog izvlačenja. Svojstva valjanih ploča kod većine metala nisu uvijek jednolike u svim smjerovima, te se pomoću mikroskopa može primijetiti da su zrna u mikrostrukturi usmjerena u smjeru valjanja odnosno postoji određeni stupanj anizotropije. Točna povijest određene anizotropije ovisi o kemijskom svojstvu materijala te procesu izrade (tj. ljevanje, valjanje, izvlačenje, žarenje itd.).

Grafikon 1. Metoda izrezivanja epruveta ovisno o smjeru valjanja lima

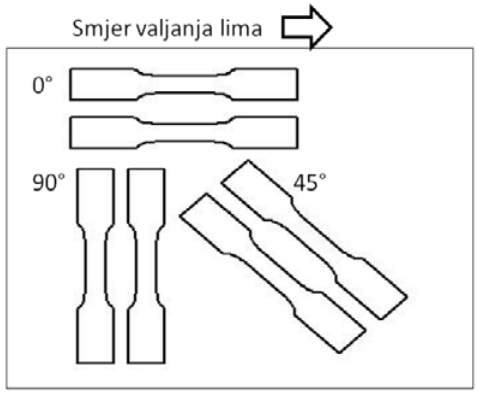

Izvor: obrada autora

Koeficijent anizotropije obilježava se slovom *r*, naziva se još i Lankfordovim koeficijentom koji izražava omjer poprečnog naprezanja i debljine. Koeficijent *r* daje dobru procjenu o sposobnosti lima da se deformira u obliku dubokog izvlačenja ($r_0 \neq r_{45} \neq r_{90}$). Greška koja nastaje zbog anizotropije je ušičavost. Poznavanjem anizotropije materijala možemo eliminirati pojavu ušičavosti koja rezultira škartom i općenito lošom iskoristivosti materijala. Koeficijent anizotropije *r* izračunava se prema (Poverzanović, 1996):

$$r = \frac{\varphi_b}{\varphi_t} = \frac{\frac{\ln b}{b_0}}{\frac{\ln t}{t_0}} = \frac{\frac{\ln b}{b_0}}{\frac{\ln(l \cdot b)}{l_0 \cdot b_0}}, r = \frac{\varphi_b}{\varphi_t} = \frac{\frac{\ln b}{b_0}}{\frac{\ln t}{t_0}} = \frac{\frac{\ln b}{b_0}}{\frac{\ln(l \cdot b)}{l_0 \cdot b_0}},$$

(3)

gdje je: ϕ_b - deformacija širine lima, ϕ_t - deformacija debljine lima, b_0 - početna širina ispitivane epruvete, *b* - širina ispitivane epruvete poslije deformacije, l_0 - početna duljina epruvete i *l* -duljina epruvete poslije deformacije. Debljina lima se dobiva prema zakonu o konstantnosti volumena $l_0 \cdot b_0 \cdot t_0 = l \cdot b \cdot t$ = konstantno.

Anizotropija se otkriva pomoću ispitivanja vlačne čvrstoće te se označava koeficijentima r_0, r_{45} i r_{90}, prema izrazu (4) dobiva se srednja vrijednost koeficijenta normalne plastične anizotropije r_s:

$$r_s = \frac{r_0 + 2r_{45} + r_{90}}{4}, r_s = \frac{r_0 + 2r_{45} + r_{90}}{4}.$$

(4)

Na temelju relacije (4) za duboko izvlačenje metalnih limova tolerancija je r_s = 0,8 – 6, a za izotropne limove r_s = 1 (Davis 2004). Koeficijent ravninske anizotropije je mjerilo Δr koje govori kakvo je odstupanje normalne plastične anizotropije na kut α. Kut α predstavlja smjer odrezivanja epruvete iz lima u odnosu na smjer vučenja lima, tako da je $r = r(\alpha)$. Kada bi izraz (5) bio Δr = 0, materijal bi se u svim smjerovima jednako rastezao.

$$\Delta r = \frac{r_0 - 2r_{45} + r_{90}}{2}.\Delta r = \frac{r_0 - 2r_{45} + r_{90}}{2}. \quad (5)$$

Anizotropija ovdje ima značajnu ulogu pri izračunu faktora materijala *C* te eksponenta očvršćivanja *n* za ispitivani lim. Pri izračunu je potrebno uzeti u obzir orijentaciju ispitnih epruveta u smjerovima 0°, 45° i 90° kako bi se definiralo ponašanje lima u postupcima deformiranja. Pri tome se faktor materijala *C* te eksponent očvršćivanja *n* izračunavaju prema izrazu (6), izračun srednje vrijednosti vrijedi i za R_p i R_m, (Gologoranc, 1991):

$$(C, \mathrm{n}) = \frac{(x_0 + 2 \cdot x_{45} + x_{90})}{4}. \quad (6)$$

U ovome istraživanju provedeno je ispitivanje vlačne čvrstoće, testiranja su napravljena na kidalici Amsler (na *Strojniškom fakultetu u Ljubljani*, *Laboratorija za preoblikovanje*). Odabrana je veličina standardne epruvete za limove 250 x 30 mm prema EN ISO 6892-1. Metalni limovi su rezani vodenim mlazom te je izrezano 5 epruveta u svakome smjeru 0°, 45° i 90° u odnosu na smjer valjanja prema grafikonu 1. Grafikon 2 prikazuje rezultate ispitivanja epruveta, ovisno o kutu prema kojemu su rezane 0°, 45° i 90°. Može se primijetiti da se rezultati ne poklapaju.

Grafikon 2. Rezultati ispitivanja vlačne čvrstoće (krivulje naprezanje deformacija σ - ε)

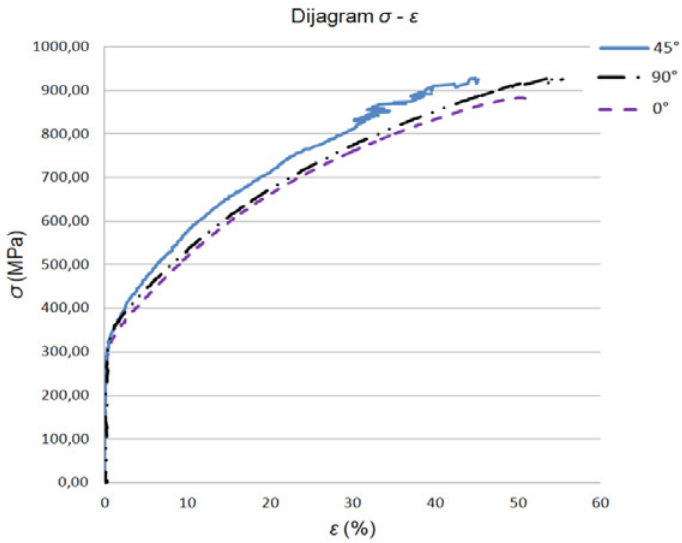

Izvor: obrada autora

Tablica 2 prikazuje mehanička svojstva, $R_{p0,2}$ naprezanje pri kojemu ostaju trajne deformacije od 0,2 % (ε = 0,002), $R_{p0,5}$ naprezanje pri kojemu ostaju trajne deformacije od 0,5 % (ε = 0,005), *A* je postotak produljenje epruvete u odnosu na smjer istezanja, A_{80} prikazuje izmjereno izduženje pri kojemu je došlo do loma, $\sigma_m = R_m$ predstavlja vlačnu čvrstoću, r_{10}, r_{20} predstavljaju vrijednost koeficijenta anizotropije pri produljenju od 10 i 20 % (budući da *r* ovisi o ukupnoj deformaciji, preporuka je da se koristi 20 %). Srednja vrijednost koeficijenta normalne plastične anizotropije (r_s) za ispitivani lim iznosi 0,864,

te prema toleranciji za standardne limove 0,7 - 2,8 ulazi u toleranciju materijala koji je pogodan za tehnologiju dubokog izvlačenja (Davis, 2004). Koeficijent ravninske anizotropije iznosi **Δr** **Δr** Δr = - 0,198, a takav rezultat nas upozorava da će rub čašice biti neravan.

Tablica 2. Mehanička svojstva dobivena ispitivanjem vlačne čvrstoće

Mehanička svojstva	Standard	0°	45°	90°
$R_{p0,2}$ (MPa)	240	297	300,93	322,73
$R_{p0,5}$ (MPa)		316,63	319,46	339,76
A (%)	40	42,2	44,33	45
A_{80}		49,4	54,7	53,06
$\sigma_m = R_m$ (MPa)	530 - 680	520,7	508,2	528,6
n		0,307	0,301	0,297
C (MPa)		1125,6	1092,6	1135,8
r_{10}		0,51	0,963	1,02
r_{20}		0,55	1,003	1,04
Srednja vrijednost koeficijenta normalne plastične anizotropije (r_s) = 0,864				
Koeficijent ravninske anizotropije Δr = - 0,198				
Rezultirajući faktor materijala C = 1111,65 (MPa)				
Rezultirajući eksponent očvršćivanja n = 0,3015				

Izvor: Kršulja (2012)

Na grafikonu 3 prikazana je rezultirajuća krivulja tečenja koja će se koristiti za simulaciju ponašanja materijala u softverskom rješenju Abaqus.

Grafikon 3. Rezultirajuća krivulja tečenja (krivulje naprezanje - deformacija σ - ϕ)

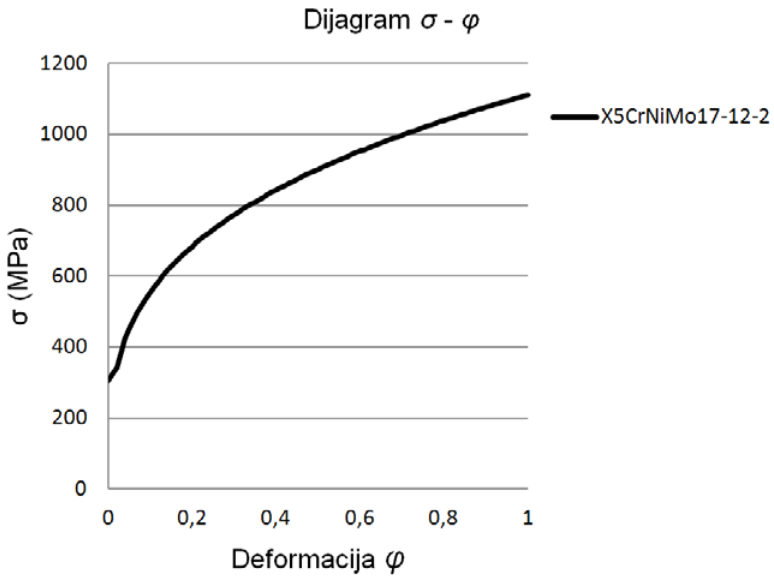

Izvor: obrada autora

Krivulja je izračunana prema Holloman-Ludwigovom relaciji 2a:

$$k_f = C \cdot \varphi = 111,65 \cdot \varphi ,3015$$

(MPa). (7)

Krivulja je rezultat anizotropije, međusobnog djelovanja zrna u mikrostrukturi koji pružaju zajednički otpor naprezanju.

4. PRORAČUN DIMENZIJA ALATA

Početni je oblik materijala za obradu ravna ploča koja se označuje kao platina (u obliku kruga ona se naziva rondela). Oblik ove razvijene ploče-platine može biti: krug, kvadrat, pravokutnik, elipsa ili specijalan oblik (zatvorena konturna krivulja) koja zavisi od oblika izvučenog izratka. Principijelno duboko izvlačenje proces je koji se provodi u više faza i kroz nekoliko alata, međutim, kod nekih vrsta limova i jednostavnih geometrija, moguće je do gotova izratka doći i u jednoj fazi izvlačenja. Pri tome obično nema promjene debljine lima, tj. pretpostavlja se da debljina lima ostaje konstantna. Ipak, u stvarnosti dolazi do smanjenja debljine stjenke u blizini dna posude, a pri rubu se događa zadebljanje lima. Na grafikonu 4 prikazano je deformacijsko stanje u procesu dubokog izvlačenja.

Grafikon 4. Deformacijsko stanje u procesu dubokog izvlačenja

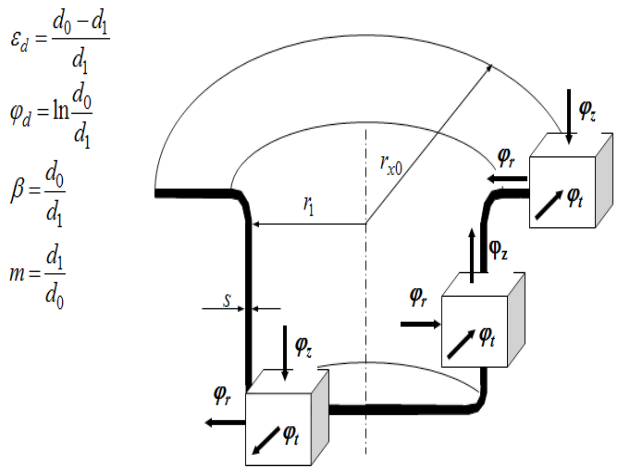

Izvor: Barišić, 2002

Na grafikonu 5 prikazane su čašice izrađene od materijala DC03 debljine 2 mm te predstavljaju konačan proizvod. U ovome istraživanju potrebno je izračunati geometriju alata kojom se postižu iste dimenzije proizvoda. S materijalom DC03 dimenzije su postignute u dva koraka (grafikon 5). Materijal DCO3 ima veću sposobnost oblikovanja i ponaša se prema rezultirajućoj krivulji:

$$k_f = C \cdot \varphi^n = 584 \cdot \varphi^{0,175} k_f = C \cdot \varphi^n = 584 \cdot \varphi^{0,175} \text{ (MPa)}, \quad (8)$$

testiranja na DC03 su napravljena na kidalici Amsler (*Strojniški fakultet u Ljubljani, Laboratorij za preoblikovanje*). U istraživanju prema literaturi (Kršulja, 2012) dokazano je da isto nije moguće s materijalom X5CrNiMo17-12-2, već je potrebno izvršiti obradu u tri koraka (grafikon 6). Obrada u tri koraka podrazumijeva izradu tri nova alata. Dobra je praksa, osim proračuna, izvršiti i simulaciju metodom konačnih elemenata kako bi se unaprijed ustanovilo ponašanje materijala i novih alata.

Grafikon 5. Geometrija lima DC03 u 2 koraka

Izvor: obrada autora

Grafikon 6. Geometrija lima X5CrNiMo17-12-2 u 3 koraka

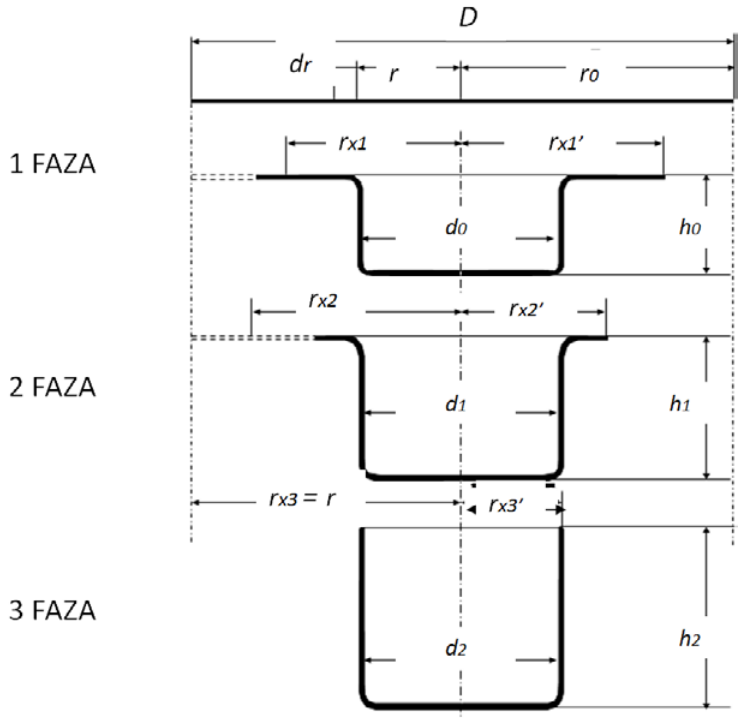

Izvor: obrada autora

Potrebne dimenzije konačne čašice jesu visina h = 36 mm, te promjer d_i = 34,5 mm. Potrebna ulazna rondela ima početnu debljinu 2 mm i iznosi D = 70,48 mm, a D = 71 mm je odabrana te se izračunava prema sljedećem izrazu (Musafia, 1969):

$$\mathbf{h_i = 0.25 \cdot \frac{D^2}{d_1} h_i = 0.25 \cdot \frac{D^2}{d_1}} h_i = 0{,}25 \cdot \frac{D^2}{d_i}. \quad (9)$$

Raspon kod dubokog izvlačenja za čelični lim u prvom izvlačenju odabire se tablično $\beta \approx$ 1,85 - 1,72 te $\beta \approx$ 1,33 - 1,28 u drugom izvlačenju (Musafia, 1969). Za stupanj izvlačenja kod prvog izvlačenja odabran je β = 1,66, te prema (10) iznosi da je unutarnji promjer d_0 = 43 mm.

$$\beta_{\mathbf{actual}} = \frac{\mathbf{D}}{\mathbf{d}} \beta_{\mathbf{actual}} = \frac{\mathbf{D}}{\mathbf{d}} \beta_{actual} = \frac{D}{d}. \quad (10)$$

Kod dubokog izvlačenja oblikovanje se provodi na dva načina: prvi način je bez upotrebe stezne naprave (držač, tlačni prsten), dok se njenom upotrebom ploča lima drži tijekom cijelog vremena obrade. Nakon obrade, lim se oslobađa iz stezne naprave, a viškovi potrebni za stezanje se kasnije odrezuju. Pritom držač (tlačni prsten) sprečava pojavu nabora na rubu izratka što je posljedica djelovanja posmičnog naprezanja na relativno tankostjene rondele. Kod relativno debelostjenih i plitkih rondela nema opasnosti od pojave nabora, tako da se u ovom slučaju proces izvodi bez upotrebe držača. Njegova neophodnost ovisit će, prema tome, o vrijednosti omjera d_0/s i d_1/d_0, a prema podacima iz literature (Barišić, 2002) može se odrediti na osnovi izraza:

$$\frac{100 \cdot s}{d_0} \geq 4{,}5 \cdot \left(1 - \frac{d_1}{d_0}\right), \tag{11}$$

iz čega slijedi da se za izvlačenje plitkih posuda, kada je lijeva strana jednadžbe veća ili jednaka desnoj, može raditi bez držača i s jeftinijim alatom. U tom slučaju, matrici se na ulaznoj strani daje oblik blagog konusa, što u izvjesnoj mjeri također pridonosi izbjegavanju nabora. U ovom istraživanju za $D = 71$, $s = 2$ te $d_0 = 43$ slijedi da je 2,81 > 1,777 te nije potreban držač lima.

Za drugo izvlačenje odabran je koeficijent β = 1,136, te je rezultirajući $d_1 = 38$ mm.

Treće izvlačenje je odabrano kako bi se postigle konačne dimenzije β = 1,11 te je konačna dimenzija $d_2 = 34{,}5^{+0{,}3}$ mm. Iako je raspon kod dubokog izvlačenja za čelični lim u prvom izvlačenju β ≈ 1,85 - 1,72, te β ≈ 1,33 - 1,28, u drugom izvlačenju za ispitani materijal stupanj veći od β = 1,66 uzrokovao je lom. Prema promjerima konačnih dimenzija izračunane su preporuke (Musafia, 1969) za konačnu geometriju matrice d_p za prvi, drugi i treći korak:

$$d_{p1} = 43^{+15}_{-10}\ \text{mm}, \quad \mathbf{d_{p1} = 45{,}5^{+0{,}15}_{-0{,}10}} \quad \mathbf{d_{p1} = 45{,}5^{+0{,}15}_{-0{,}10}} \quad \mathbf{d_{p2} = 36{,}5^{+0{,}15}_{-0{,}10}}$$

$$\mathbf{d_{p1} = 43^{+15}_{-10}} \qquad \mathbf{d_{p1} = 43^{+15}_{-10}}$$

$$\mathbf{d_{p2} = 36{,}5^{+0{,}15}_{-0{,}10}}$$

$$d_{p2} = 38^{+15}_{-10}\ \text{mm}, \quad \mathbf{d_{p3} = 36{,}5^{+15}_{-10}} \quad \mathbf{d_{p3} = 36{,}5^{+15}_{-10}}$$

$$\mathbf{d_{p2} = 38^{+15}_{-10}\ mm} \qquad \mathbf{d_{p2} = 38^{+15}_{-10}\ mm}$$

$$\mathbf{d_{p3} = 36.5^{+15}_{-10}\ mm} \quad \mathbf{d_{p3} = 36.5^{+15}_{-10}\ mm} \quad d_{p3} = 36{,}5^{+15}_{-10}\ \text{mm}.$$

Razmak između žiga i matrice moguće je izračunati iz više izraza, međutim, zbog poteškoća koje se javljaju kod jako tankih limova koji imaju manju debljinu od 0,3 mm, u ovome istraživanju izračunan z = 3 mm prema izrazu:

$$\mathbf{z = 1.5 \cdot s}\ \mathbf{z = 1.5 \cdot s}\ z = 1{,}5 \cdot s. \tag{12}$$

Najmanja potrebna sila koju je potrebno primijeniti da bi se proizveo proizvod, a da se ne koriste držači lima, izračunana je iz niza izraza 13 - 18 (prema Kuzman et al., 1989). Rezultirajuća sila F_M = 19101 N, prema podacima prikazanim u tablici 2 s mehaničkim svojstvima. A_0 = 282 mm^2; β = 1,65; n = 0,3015; C = 1111,65 MPa; σ_{fsr} = 463 MPa (prema Kršulja et al., 2012).

$$F_M = 0{,}71 \cdot \sigma_{fsr} \cdot A_0 \cdot \ln(0{,}7 \cdot \beta_1) \cdot \frac{1}{\eta_p}. \tag{13}$$

$$\sigma_{fsr} = \frac{R_p + \sigma_{fFM}}{2}.\sigma_{\mathbf{fsr}} = \frac{\mathbf{R_p + \sigma_{fFM}}}{\mathbf{2}}\sigma_{\mathbf{fsr}} = \frac{\mathbf{R_p + \sigma_{fFM}}}{\mathbf{2}} \tag{14}$$

$$\sigma_{fFM} = C \cdot \varphi_{FM}^{n} = C \cdot (\ln 0{,}7 \cdot \beta_1)^n.\sigma_{\mathbf{fFM}} = \mathbf{C \cdot \varphi_{FM}^{n} = C \cdot (\ln 0.7 \cdot \beta_1)^n}$$
$$\sigma_{\mathbf{fFM}} = \mathbf{C \cdot \varphi_{FM}^{n} = C \cdot (\ln 0.7 \cdot \beta_1)^n} \tag{15}$$

$$A_0 = \pi \cdot s \cdot (d_1 + s).\mathbf{A_0 = \pi \cdot s \cdot (d_1 + s)}A_0 = \pi \cdot s \cdot (\mathbf{d_1 + s}) \tag{16}$$

$$\beta_1 = \frac{\mathbf{D_0}}{\mathbf{d_1}}\beta_1 = \frac{\mathbf{D_0}}{\mathbf{d_1}}\ \beta_1 = D_0/d_1. \tag{17}$$

$$\eta_1 = 0{,}7.\eta_1 = \mathbf{0.7}\ \eta_1 = \mathbf{0.7} \tag{18}$$

Maksimalna potrebna sila žiga kako bi se izvršila deformacija: F_{FM} ·1,3 = 24,831 kN.

5. MODELIRANJE METODOM KONAČNIH ELEMENATA U SOFTVERU ABAQUS

Matematički proračun daje općenit odgovor na ponašanje materijala te ne uzima u obzir mehanička svojstva poput metode konačnih elemenata koja uzima u obzir krivulju naprezanje-deformacija (σ - ϕ), gustoću čeličnog lima = 7,850 (kg/m^3), Poissonov koeficijent (0,3), Youngovog modul elastičnosti (210 GPa), koeficijent trenja μ = 0,14 (mineralno ulje). Krivulja naprezanje-deformiranje aproksimirana je pomoću Holloman-Ludwigove relacije iz eksperimentalno dobivenih rezultata vlačnog testa (izraz (7) te je unesena u softver. Kao metoda izračuna korištena je funkcija ABAQUS/ Explicit koja ne zahtijeva izračunavanje uzastopnog sistema jednadžbi ili izračunavanje globalne

matrice krutosti. Umjesto toga, traži se dinamička ravnoteža od jednog inkrementa do drugog. U ovome istraživanju odabrana je simulacija ABAQUS/Explicit metodom zbog složenosti procesa obrade u kojemu dolazi do istovremenog pomaka 3 alata.

Metoda konačnih elemenata je matematička tehnika potpomognuta računalom. Konačni elementi mogu biti jednodimenzijski, dvodimenzijski ili trodimenzijski. U ovome radu bit će prikazano trodimenzijsko modeliranje s ljuskastim elementima (S4R), *engl.* „shell element", s pet točaka integracije debljine lima (Simpson metoda izračuna). Upotreba ljuskastih elemenata umjesto 3D solid elemenata omogućava brži proračun te manje zahtjevno računalo. Literatura (Abaqus/CAE User's Manual, 2010) upućuje na upotrebu ljuskastih elemenata čija upotreba u simulacijama daje dobar odnos točnosti i vremena proračunavanja interakcije elemenata. Čvorovi i elementi tvore mrežu konačnih elemenata koji opisuju ispitivano tijelo. Svaki element predstavlja dio fizičke strukture čiji ukupan broj utječe na gustoću mreže. Gustoća mreže utječe na rezultate koji se dobivaju analizom. Vrijeme potrebno za analizu ispitivanog tijela ovisi o količini informacija koju treba proračunati i snazi procesora koji se koristi. Optimalno vrijeme potrebno za proračun ponašanja modela ovisi o usporedbi dobivenih podataka s provedenim eksperimentalnim ispitivanjem.

Korištena je mreža s 1240 čvorova i 1200 elemenata, gdje je geometrija rondela dopustila 1166 linearnog četvrtastog elementa tipa S4R te 34 elementa linearno trokutastog tipa S3R.

Prema dobivenim podacima iz proračuna, postavljeni su alati prema grafikonu 7 u softverskom rješenju Abaqus. Simulacija je izvršena simultano u tri koraka bez zaustavljanja. Problem pomaka alata u simulaciju nakon izvršenog djelovanja sile smanjen je postavljanjem uske tolerancije između promjene aktivnih matrica te usklađivanjem brzina žiga.

Grafikon 7. Geometrija alata za prvo izvlačenje: matrica lijevo te žig desno

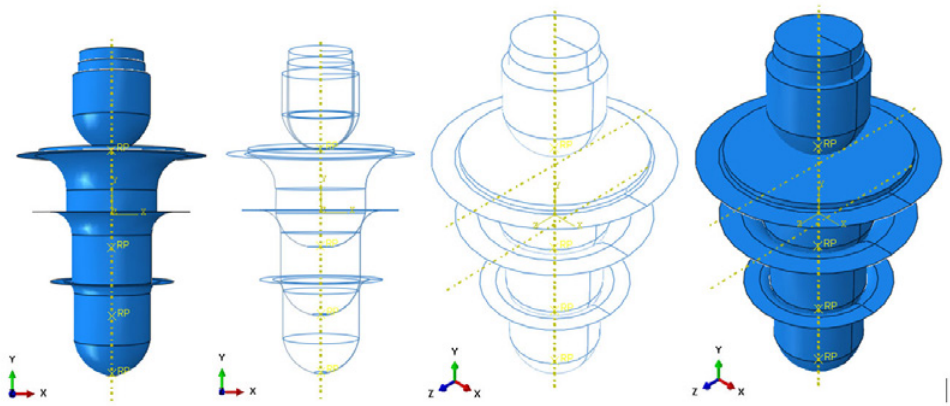

Izvor: obrada autora

U istraživanju (Kršulja et al., 2012) prikazan je analitički model izrade u 3 izvlačenja. Uvrštenjem tih dimenzija u numeričku simulaciju dolazi do kontrole analitičkih rezultata. Problem koji se pojavio je gužvanje lima. Dakle, simulacija je ukazala na pojavu gužvanja lima, *engl.* „wrinkling"; nastanak gužvanog lima može se vidjeti na grafikonu 8. Osim što obradak ostaje zaglavljen u alat, može doći i do oštećenja alata prilikom same obrade ili skidanja obratka iz alata. U nekim slučajevima dolazi i do trajnog oštećenja alata, što je jedan od dokaza zašto je simulacija dobra praksa u projektiranju alata.

Grafikon 8. Pojava gužvanja lima u operaciji dubokog izvlačenja

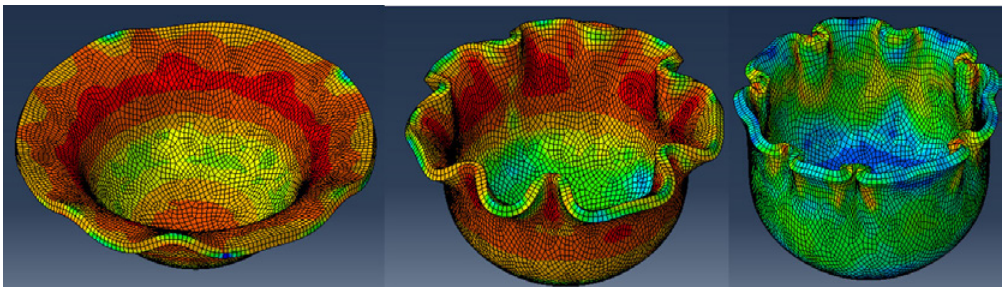

Izvor: obrada autora

Pomoću simulacije potrebno je pronaći idealan radijus alata žiga i matrice. Izračun idealnog odnosa ulaznog alata žiga i radijusa matrice varira zbog velikog odnosa faktora koji se proizvoljno uzima u jednadžbama za njihov izračun:

$$r_{ž} = (3 \div 4) \cdot r_m \, r_{ž} = (3 \div 4) \cdot r_m \,, \tag{19}$$

gdje je $r_ž$ radijus zaobljenja žiga i $r_m = d_p/2$ radijus zaobljenja matrice. Radijus zaobljenja žiga „$r_{ž}\, r_{ž}$ " nikako ne smije biti manji od radijusa matrice „$r_m\, r_m$ " jer inače postoji opasnost od prosijecanja lima od strane žiga. Radijus zaobljenja matrice za izvlačenje zavisi od oblika dijela i debljine lima. Za izračunavanje približne vrijednosti „$r_m\, r_m$ " može se koristiti izraz:

$$r_m = (5 \div 10) \cdot s_0 \, r_m = (5 \div 10) \cdot s_0 \,, \tag{20}$$

gdje je s_0 – s_0 – debljina lima.

Iz tog razloga upotrijebljena je simulacija kako bi se definirala optimalna alatna geometrija. Idealna kombinacija radijusa alata dobivena nakon provedenih simulacija prikazana je u tablici 3 te u grafikonima 9, 10 i 11. U početnim simulacijama, visina žiga bila je jednaka i u praksi je dovoljno da je $h_{ž2}$ =38 mm. U drugoj fazi, zbog jednake visine žiga kao u 3 fazi, od 38 mm dolazilo je do preklapanja žigova, ulaza žiga u materijal i rezanje ispitivanog materijala. Zato je za potrebe simulacije u trećoj fazi odabrana visina žiga $h_{ž3}$ = 43 mm.

Tablica 3. Rezultirajuća idealna kombinacija za provedenu simulaciju

Faze izvlačenja	$r_m/r_ž$ (mm)	$d_p/d_ž$ (mm)	$h_m/h_ž$ (mm)
1 Faza	15/ 20	43/37	40,5/33
2 Faza	10/15	38/32	46/38
3 Faza	5/15	36,5/30,5	41/43

Izvor: obrada autora

Na grafikonu 9 prikazana je geometrija matrice lijevo i žiga desno za prvu operaciju deformiranja.

Grafikon 9. Geometrija alata za prvo izvlačenje: matrica lijevo i žig desno

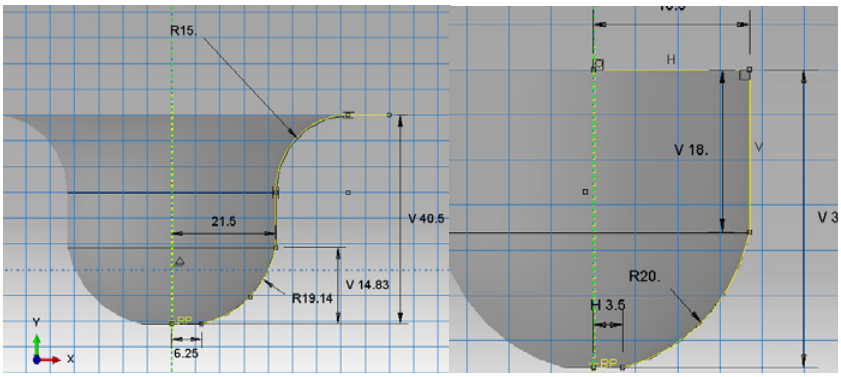

Izvor: obrada autora

Na grafikonu 10 prikazana je geometrija matrice lijevo i žiga desno za drugu operaciju deformiranja.

Grafikon 10. Geometrija alata za drugo izvlačenje: matrica lijevo i žig desno

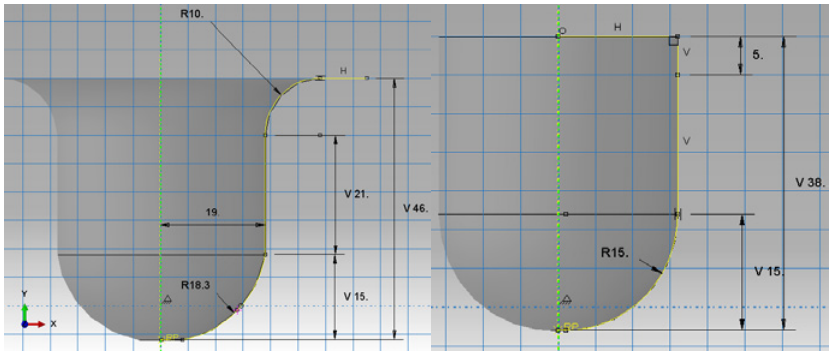

Izvor: obrada autora

Na grafikonu 11 prikazana je geometrija matrice lijevo i žiga desno za treću operaciju deformiranja.

Grafikon 11. Geometrija alata za treće izvlačenje: matrica lijevo i žig desno

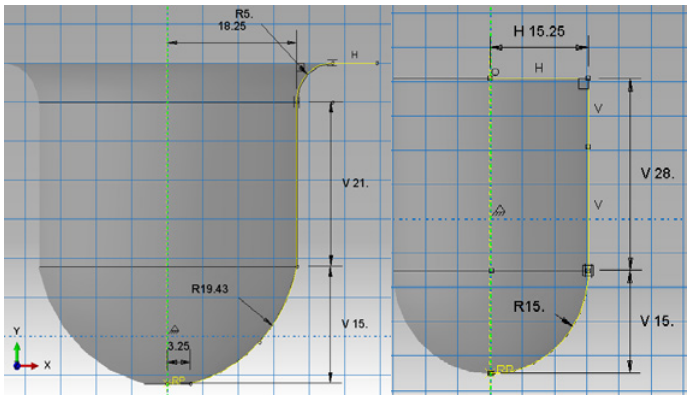

Izvor: obrada autora

6. REZULTATI SIMULACIJE

Na grafikonu 12 prikazano je rezultirajuće Von Mises stanje (izraz 21) naprezanja u prvoj fazi izvlačenja lima X5CrNiMo17-12-2.

$$\sigma_e = \frac{1}{\sqrt{2}}\sqrt{(\sigma_1-\sigma_2)^2+(\sigma_2-\sigma_3)^2+(\sigma_3-\sigma_1)^2}\,. \tag{21}$$

Prema podacima prikazanim na slici može se primijetiti da se najveće naprezanje 845 MPa pojavilo na rubovima čašice. Također, može se vidjeti linija nedeformiranog dijela na sredini čašice gdje naprezanje nije prelazilo 330 MPa.

Grafikon 12. Von Mises stanje naprezanja u prvoj fazi izvlačenja lima X5CrNiMo17-12-2

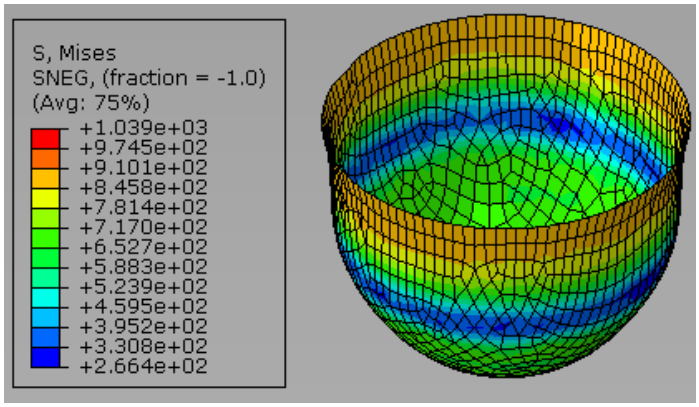

Izvor: obrada autora

Na grafikonu 13 prikazano je rezultirajuće Von Mises stanje naprezanja u drugoj fazi izvlačenja za lim X5CrNiMo17-12-2. Najveće naprezanje iznosilo je 1021 MPa što je jako blizu najviše dozvoljenog naprezanja od 1111,65 MPa.

Grafikon 13. Von Mises stanje naprezanja u drugoj fazi izvlačenja lima X5CrNiMo17-12-2

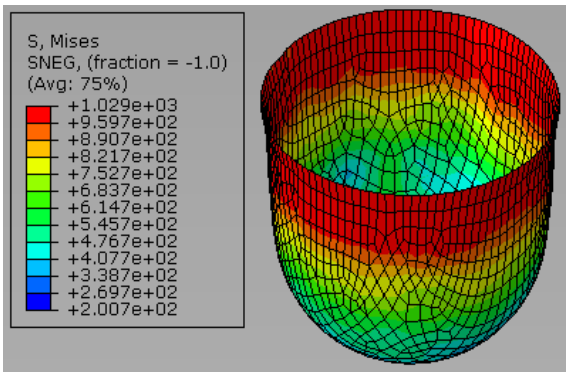

Izvor: obrada autora

Na grafikonu 14 prikazano je rezultirajuće Von Mises stanje naprezanja u trećoj fazi izvlačenja za lim X5CrNiMo17-12-2. Najveće naprezanje iznosilo je 1064 MPa, što je također jako blizu najviše dozvoljenog naprezanja od 1111,65 Mpa, ali još uvijek u granicama tolerancije.

Grafikon 14. Von Mises stanje naprezanje u trećoj fazi izvlačenja lima X5CrNiMo17-12-2

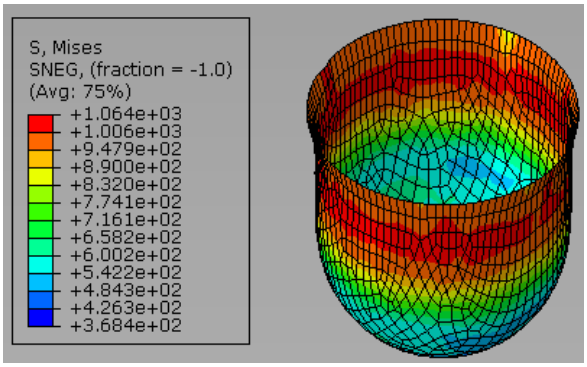

Izvor: obrada autora

Prema rezultatima na grafikonu 12, 13 i 14 može se primijetiti da nema pojave gužvanja materijala.

Na grafikonu 15 prikazano je ponašanje kinetičke energije tijekom simulacije u prvoj, drugoj i trećoj fazi. U prvoj fazi u $E_{k1} = 6 \cdot 10^3$ Joula, u drugoj fazi $E_{k2} = 4 \cdot 10^3$ Joula i u trećoj fazi $E_{k3} = 2{,}5 \cdot 10^3$ Joula. Prema grafikonu 15 može se vidjeti da je u prvoj fazi utrošena veća kinetička energija za postizanje deformacije nego u drugoj i trećoj fazi. Iako su pomaci u trećoj fazi manji nego u prve dvije, zbog očvrsnutog materijala potrebno je uložiti značajnu energiju kako bi se ostvarila deformacija.

Grafikon 15. Kinetičke energije tijekom simulacije

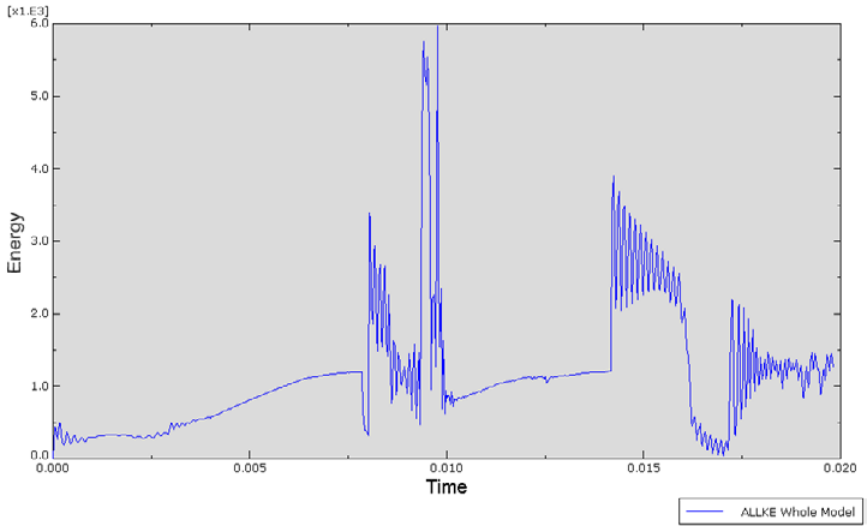

Izvor: obrada autora

7. ZAKLJUČAK

Cilj ovoga rada bio je usporediti analitički model sa simulacijom i identificirati radijuse alata i matrice potrebne kako bi se dimenzije konačnog proizvoda zadovoljile. Ispitana su kemijska svojstva materijala te je on zadovoljio standard. Ispitana su mehanička svojstva materijala te se može primijetiti kako materijal ima 306 prosječnu vrijednost granice tečenja, što je 66 MPa više od standarda. Ispitana vlačna čvrstoća iznosila je, u prosjeku, 519 MPa što je niže od propisanog standarda koji se kreće u rasponu od 530 - 680 MPa. Rezultirajući faktor materijal C iznosio je 1111,65 MPa, a eksponent očvršćivanja n = 0,3015 i nalazi se unutar standarda koji se za čelične limove kreće u rasponu od 0,1 do 0,5. Simulacija je pokazala kako uvjeti propisani matematičkim modelom dovode do nastanka greški, gužvanje lima te nastanak pukotine. Mala ušičavost je pretpostavljena prema dobivenom vlačnom testu budući da je Δr = - 0,198, međutim simulacija je pokazala da se pravilnim odabirom radijusa alata može izbjeći pojava ušičavosti. Ušičavost na predstavlja gubitak, to je dodatak materijala na ulaznoj rondeli koji se naknadno odrezuje. Matematički model ponudio je početni radijus matrice od 10 mm, a alata 30 mm, što je dovelo do pojave gužvanja. Literatura preporučuje kako radijus žiga treba biti tri do četiri puta veći od radijusa matrice. U ovome istraživanju pokazana je idealna kombinacija $r_m/r_ž$ =10/15, što je povećanje radijusa žiga od 33 % i ne slijedi preporuku prema proučenoj literaturi. U budućem istraživanju provest će se izrada alata i eksperiment izrade čašica u svakoj fazi dubokog izvlačenja. Usporedba rezultata simulacije i stvarnog eksperimenta potvrdit će vjerodostojnost proračuna i doprinijeti većem uplivu u ponašanje metala pri dubokom vučenju.

LITERATURA

Abaqus/CAE User's Manual (2010) *Documentation*, Dassault Systèmes Simulia Corp., Providence, RI, USA.

Aleksandrović, S. et al. (2010) „Utjecaj promjenjive sile držanja i nemonotonosti procesa dubokog vučenja na obradivost limova s prevlakama", *Strojarstvo: časopis za teoriju i praksu u strojarstvu*, 52(2).

Barišić, B. (2002) *Analiza procesa izvlačenja i istiskivanja primjenom stohstičkog i numeričkog modeliranja*, magistarski rad, Rijeka: Tehnički fakultet

Davis, J. R. (2004) *Tensile Testing*, ASM International

Filho, R. A. C, Marcondes, P. V. P. (2009) „Utjecaj dizajna žiga na proces oblikovanja lima", Engineering Review, 29 (1).

Gologranc, F. (1991) *Preoblikovanje: 1. dio*, Ljubljana: Fakulteta za strojništvo

Kršulja, M., Car, Z., Radelja, H. (2012) *Behaviour of X5CrNiMo17-12-2 Material During Deep Drawing Process*, Metalurgija, 51 (2), p. 203-206

Kuzman K., Pipan J., Kampuš Z. (1989) *Vaje iz tehnike preoblikovanja*, Ljubljana: Univerza Edvarda Kardelja, Fakulteta za strojništvo

Musafia, D. (1969) *Obrada metala plastičnom deformacij*om, Sarajevo: Svjetlost

Plančak M. et al. (2012) **„**Mjerenje kontaktnog trenja u obradama prostornog deformiranja"**,** *Tehnički vjesnik*, 19(4)

Povrzanović, A. (1996) *Odabrana poglavlja obrade metala deformiranjem*, Zagreb: Fakultet strojarstva i brodogradnje

Marko Kršulja [1]
Dario Bognolo [2]

Preliminary communication
UDK 539.37:519.6

SELECTION OF TOOL GEOMETRY IN REGARD TO MATERIAL BEHAVIOR DURING DEFORMATION PROCESS[3]

ABSTRACT

This paper analyzes the behavior of the X5CrNiMo17-12-2 steel plate during the deep drawing process. Mechanical and chemical properties obtained by spectrometry and standard tensile test are presented. The paper examines the basic calculation that gives good approximation of expected behavior during modeling of input specimen into final product. Based on the mechanical properties, simulation of material behavior was performed by using the method of finite elements in the ABAQUS software. The calculation results of the tool geometry mathematical model depending on steel plate behavior and simulations were compared.

Key words: *deformation, deep drawing, steel plate, FMA, modeling*

[1] PhD, Master of Science in Mechanical Engineering, Assistant, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: krsulja.marko@veleri.hr

[2] Master of Science in Mechanical Engineering, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: dbognolo@veleri.hr

[3] Received: 22. 2. 2014.; accepted: 5. 5. 2014.

Ivo Brozović [1]
Aleksandar Regent [2]
Matea Grgurević [3]

Pregledni rad
UDK 504.3.054:656.1

EMISIJE STAKLENIČKIH PLINOVA, OSOBITO IZ PROMETA

(Prilog analizi emisija stakleničkih plinova, osobito iz prometa)[4]

SAŽETAK

U radu su prikazani rezultati istraživanja glede emisija stakleničkih plinova izazvanih ljudskim djelatnostima, osobito predmetnih emisija podrijetlom iz prometa. Od početka industrijske revolucije do danas bilježimo stalan porast antropogenih emisija stakleničkih plinova koje povećavaju koncentraciju stakleničkih plinova (imisijske vrijednosti) u troposferi, čime *povećavaju intenzitet stakleničkog učinka. U radu su analizirani utjecaji antropogenih emisija bitnih stakleničkih plinova na svjetskoj razini od 1750. g. do danas. Posebno su izrađene usporedbe emisija stakleničkih plinova za tri zemlje, odnosno asocijacije: Republiku Hrvatsku, Europsku uniju i Sjedinjene Američke Države. Utvrđen je apsolutni porast emisija iz prometa u 2010. g. u odnosu na emisije iz 1990. g. u sve tri istra-*živane zemlje u rasponu od 19 *% (SAD), preko 21 % (EU) do 48 % (RH). Tome trendu najviše pridonose emisije iz cestovnog prometa (2010. g. s udjelom od 85 % do 95 % u ukupnim emisijama iz prometa), čiji je relativni udio porasta u odnosu na ukupne emisije iz prometa u 2010. g. u odnosu na 1990. g. bio u rasponu od 8 % (SAD), preko 43 % (EU) do 63 % (RH). S obzirom na relativno skroman stupanj motorizacije u mnogoljudnim zemljama s brzo rastućim gospodarstvima (Kina, Indija, Indonezija, Nigerija i dr.) za očekivati je porast ukupnih emisija stakleničkih plinova sljedećih desetljeća, kojemu će prvenstveno pridonijeti emisije iz cestovnog prometa. Time bi se mogli narušiti još uvijek relativno ugodni klimatski uvjeti za život ljudi na našem planetu. Rad završava osvrtom na moguća djelovanja glede smanjivanja očekivanih trendova emisija stakleničkih plinova i zaključcima.*

Ključne riječi: *stakleнički plinovi, promet, RH, EU, svijet.*

1. UVOD

Posljednjih smo desetljeća svjedoci znakovitih klimatskih promjena u različitim prostorima našeg planeta. Prevladavaju stavovi kako je čovjek sa svojim djelatnostima u dobroj mjeri pridonio tim promjenama. Emisije stakleničkih plinova od antropogenih djelatnosti, koje su u stalnom porastu od 1750. g. do danas, povećavaju koncentraciju stakleničkih plinova u atmo-sferi našeg planeta, osobito u prvom sloju atmosfere, tj. troposferi, koja obavija Zemljinu površinu u pojasu prosječne debljine od 8 do 14 km. Tako se povećava staklenički učinak atmosfere mimo prirodnih procesa kojima je milijunima godina stvaran današnji Zemljin omotač.

[1] Mr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* ivo.brozovic@veleri.hr
[2] Dr. sc., viši predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* aleksandar.regent@veleri.hr
[3] Student, Prirodoslovno-matematički fakultet, Sveučilište u Zagrebu, Republike Austrije 15, Zagreb, Hrvatska. *E-mail:* oleg.grgurevic@arhitekt.hr
[4] Datum primitka rada: 24. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

Slijedom navedenog, moglo bi uskoro doći do promjene danas još uvijek ugodnih klimatskih uvjeta za život ljudi na Zemlji (povećanje temperature zraka, dizanje morske razine i zagrijavanje mora, otapanje glečera, porast učestalosti intenziteta prirodnih nepogoda i katastrofa i sl.), te bitnog utjecaja na život ljudi s posljedicama velikih emigracijskih procesa iz obalnih područja i povećane opasnosti nastupanja većih sukoba u svijetu.

Emisije stakleničkih plinova iz prometa, s obzirom na njihove trendove u posljednja dva desetljeća, u ukupnim emisijama stakleničkih plinova dobrim dijelom povećavaju intenzitet stakleničkog učinka i njegove posljedice. Radi očekivanog porasta prometnih aktivnosti, odnosno potrošnje goriva u prometu narednih desetljeća, taj "pritisak", odnosno utjecaj prometa, *očigledno će* rasti. Stoga valja na svim razinama, a osobito na međunarodnoj, poduzeti odgovarajuće akcije glede smanjivanja emisija stakleničkih plinova *čije je* podrijetlo iz prometa.

2. KONCEPCIJA IZRADE (METODOLOGIJA)

U početku valja evidentirati plinove čije emisije mogu bitno utjecati na povećanje koncen-tracije stakleničkih plinova u atmosferi.

Slijedi utvrđivanje moguće veze između antropogenih emisija stakleničkih plinova i njihove koncentracije u troposferi, odnosno povećanja "prirodnog" stakleničkog učinka.

Sljedeći korak je identificiranje razvoja stakleničkih plinova od antropogenih djelatnosti i utvrđivanje udjela emisija stakleničkih plinova podrijetlom iz prometa u tim emisijama.

Na koncu slijedi procjena mogućih budućih trendova te kratak osvrt (s obzirom da je to tema za ozbiljan sljedeći rad) na poduzete mjere, kao i mjere koje bi valjalo poduzeti glede sma-njenja utjecaja prometa na staklenički učinak i njegove posljedice.

3. STAKLENIČKI PLINOVI I KLIMATSKE PROMJENE

Današnji izgled našeg planeta, kao i klimatski uvjeti koji omogućuju civilizaciju današnjice, rezultat su razvoja tijekom više stotina milijuna godina. Današnja je klima Zemlje još uvijek kontinuitet stabilizacije prilika koje su nastupile pred oko deset tisuća godina (klima, odgovarajući vegetativni pokrivač), od kada datira snažan razvoj ljudske vrste. Od tada do danas svjedoci smo triju velikih revolucija u razvoju čovječanstva: neolitske (stvaranje seoskih zajednica – oko 8000 g. prije Krista), urbane (stvaranje gradskih zajednica – oko 33 stoljeća prije Krista) i industrijske (od 1750. g. do danas), te postindustrijskog društva, na čijem smo začetku.

Zemljina atmosfera, kao višeslojni plinski omotač oko Zemlje, najvećim dijelom pridonosi klimatskim prilikama. Tzv. "staklenički plinovi", koji danas sudjeluju u tvorbi atmosfere s rela-tivno malim volumnim udjelom (manjim od 0,04 %, odnosno s manje od 4 dcl na $1m^{3,}$ odnosno 1000 litara zraka) "najzaslužniji" su za stakleničkih učinak Zemljine atmosfere, koji nastaje zadržavanjem odbijene Sunčeve emisije od površine Zemlje. Smatra se da staklenički plinovi, odnosno atmosfera, pridonose prosječnoj temperaturi na površini Zemlje za 33^{0}C *(što znači da temperatura na* Zemlji bez toga učinka ne bi bila +15^{0}C, već -18^{0}C).

Isključivši utjecaj vodene pare, danas možemo govoriti o tri skupine stakleničkih plinova. U prvoj se skupini nalaze najznačajniji plinovi, tj. ugljični dioksid (CO_2), metan (CH_4) i didušikov oksid (N_2O). Druga je skupina tzv. F-plinova[5] koje ne nalazimo u prirodi, već su rezultat ljudskih djelatnosti (sintetički plinovi), a osnovni su im predstavnici CFC-plinovi (npr. tetrafluorometan i heksafluorometan), HCFC-plinovi (klorofluorougljikovodici) i sumporni heksafluorid (SF_6). Treća su skupina tzv. indirektni staklenički plinovi, koji pridonose stvaranju (ali i razgradnji) ozona (koji u troposferi predstavlja vrlo nestabilan staklenički plin), od kojih valja istaknuti ugljični monoksid (CO), dušikove okside (NO_x) te nemetanske lako hlapljive uljikovodike (NMVOC ili NMHOS).

S obzirom na značaj za staklenički učinak kao rezultat ljudskih djelatnosti, posljednjih su desetljeća u rakurs promatranja uzeti plinovi prve i druge skupine.

Tablica 1. Koncentracija važnijih stakleničkih plinova u troposferi 1750. g. i 2012. g.

Staklenički plin/ koncentracije	Koncentracija u troposferi		Promjena koncentra-cije 2010. u odnosu na 1750. g.	Relativni staklenički potencijal
	1750. g.	2012. g.		
CO_2	280 ppm	393 ppm	+40,4%	1
CH_4	700 ppb	1.800 ppb	+157,0%	25
N_2O	270 ppb	323 ppb	+20,4%	298
Ozon (O_3)	25 ppb	34 ppb	+36,0%	?
CFC 11 (CCl_3F)	0	237 ppt	(100,0%)	4.750
CFC 12 (CCl_2F)	0	531 ppt	(100,0%)	10.900
HCFC 22 ($CHClF_2$)	0	226 ppt	(100,0%)	1.810
Halon (CBrCLf3)	0	7.140 ppt	(100,0%)	65
SF_6	0	3.200 ppt	(100,0%)	22.800

- ppm = parts per milion = milijunti volumni udio promatranog plina u zraku biosfere – 10^{-6}
- ppb = parts per bilion = milijarditi volumni udio promatranog plina u zraku biosfere – 10^{-9}
- ppt = parts per trilion = trilijarditi volumni udio promatranog plina u zraku biosfere – 10^{-12}
- Relativni staklenički potencijal predstavlja doprinos promatranog plina stakleničkom učinku u odnosu na doprinos ugljičnog dioksida

Izvor: Blasing (2013)

Iz podataka tablice 1 *očigledan je porast koncentracije stakleničkih plinova posljednjih 250 godina u troposferskom sloju atmosfere. P*rema nekim računicama (na osnovu povećane koncentracije plinova dodatno vrednovane stakleničkim potencijalom), u tom je razdoblju došlo do povećanja mogućeg stakleničkog učinka za više od 40 %.

S obzirom na snažan porast emisija stakleničkih plinova u promatranom razdoblju (od 1750.- 2012. g.), opće je prihvaćen stav da su antropogene djelatnost temeljni razlog povećanja intenziteta stakleničkog učinka i posljedica koje se njemu pripisuju.

[5] Ovi plinovi snažno utječu na destrukciju ozona u stratosferskom sloju zemljine atmosfere.

Sika 1. Antropogene emisije ugljičnog dioksida u teragramima (Tg) od 1900. do 2007. g.

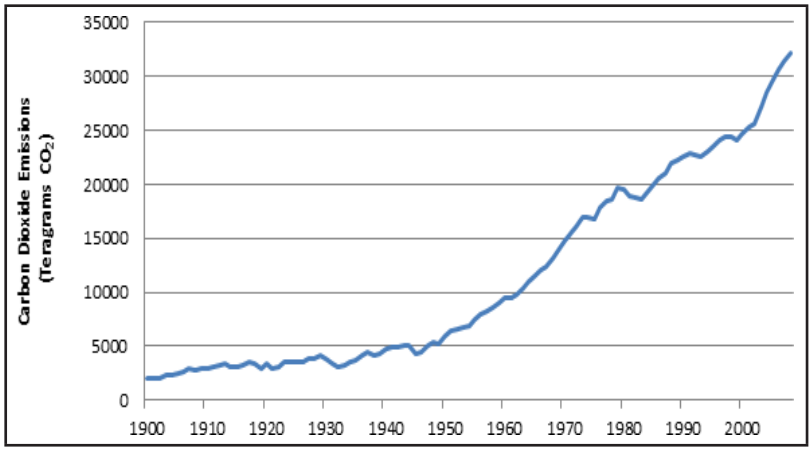

Izvor: *EPA, Global Greenhouse Gas Emissions Data* (2013).

Tablica 2. Stvarni doprinos pojedinih plinova stakleničkom učinku - kao rezultat ljudskih djelatnosti – prema različitim područjima svijeta

Staklenički plin/ doprinos	**Doprinos stakleničkom učinku u različitim područjima svijeta**			
	Svijet – prema IPCC-u (2007.)	**SAD (2010.)**	**EU (2010.)**	**RH (2010.)**
CO_2	**76 %**	**83,5 %**	**82 %**	**74,0 %**
CH_4	**14 %**	**10,0 %**	**9 %**	**11,7 %**
N_2O	**8 %**	**4,5 %**	**7 %**	**12,6 %**
F-plinovi	**2 %**	**2,0 %**	**2 %**	**1,7 %**
Ukupno	**100 %**	**100 %**	**100 %**	**100 %**

Izvori:

- za svijet (IPCC, 2007): *EPA, Global Greenhouse Gas Emissions Data* (2012).
- za SAD: *Inventory of U. S. Greenhouse Gas Emissions and Sinks 1990-2010* (2012), tablice 2-1 (str. 2-3 i 3-4).
- za EU: *Annual European Union greenhouse Gas inventory 1990-2010 and inventory report 2012* (2012), tablice ES-4.
- za RH: *Izvješće o inventaru stakleničkih plinova na području Republike Hrvatske za razdoblje 1990.-2010* (2012), tablica: A1.2-9.

Doprinos emisijama najvažnijih stakleničkih plinova stakleničkom učinku (2010. g.) koji potje-*ču od ljudskih djelatnosti prikazan je u Tablici 3.*

Pri tome, emisijama ugljičnog dioksida najviše pridonose emisije koje potječu iz djelatnosti proizvodnje energije i rafinerijskih procesa (39 %), industrijskih procesa (21 %), prometa (17 %), grijanja i drugih energetskih potreba u kućanstvima i sl. (9 %), šumskih požara (11 %) te ostalih djelatnosti (3 %).

Emisije metana dijelom potječju iz emisija kod proizvodnje i transporta goriva (oko 38 %), uzgoja stoke, osobito goveda (31 %), te otpada i ostalih procesa (oko 18 %).

Emisijama didušikova oksida najviše pridonose emisije iz poljoprivrednih djelatnosti (oko 66 %) te otpada i izgaranja (potrošnje) goriva (po 17 %).

F-plinovi rezultat su emisije plinova koji se koriste u rashladnim sustavima, uređajima za gašenje požara, proizvodnje aluminija, magnezija i dr.

Globalno gledajući, na svjetskoj razini, znakovite antropogene emisije stakleničkih plinova potječu iz proizvodnje energije s udjelom od 35 %, industrije 18 %, prometa 13 %, poljopri-vrednih djelatnosti 11 %, otpada s 4 %, a za ostatak su zaslužni šumski požari (3 %) te truljenje drva, tresetišta i sl. (udio od 8 %).

Povećane antropogene emisije stakleničkih plinova ne pridonose u cijelom iznosu povećanju stakleničkog učinka i ne odražavaju se linearnim povećanjem stakleničkog učinka na cijeloj Zemljinoj površini. Naime, najveći relativni udio antropogenih emisija stakleničkih plinova kompenziraju ogromne mase oceanskih mora (oko 30 %), dijelom povećani intenzitet fotosinteze zelenih biljaka i drugi procesi u biosferi, a udio nešto manji od 50 % pridonosi povećanju koncentracije stakleničkih plinova u troposferi (Glavač, 2001:74).

Klimatske promjene, kojih smo svjedoci posljednjih desetljeća, osobito se ogledaju kroz:

- povećanje prosječne temperature na Zemljinoj površini,
- povećanje temperatura oceana i povećanje razina soli u njima, uslijed čega se naglo mijenjaju uvjeti života u oceanima, a mijenja se i intenzitet glavnih morskih struja,
- širenje površina pustinja, a smanjenje površine šuma,
- otapanje glečera[6],
- potencijalnu opasnost porasta površine mora u sljedećih 50 godina, što bi moglo uzrokovati ugrozu za 1/6 svjetskog stanovništva, s nesagledivo teškim posljedicama za cijeli svijet,
- smanjenje snježnog pokrivača u sjevernim dijelovima (u 40 godina u prosjeku za 10 cm godišnje),
- povećanu učestalost padavina,
- povećanu učestalost prirodnih nepogoda (uragani, tajfuni, suše, poplave i dr.).

Neki od tih procesa, kao i očekivanja (scenariji) koja se zasnivaju na trendovima emisija stakleničkih plinova, prikazani su na sljedećim slikama (2, 3, 4 i 5).

[6] Prema istraživanjima britanskih znanstvenika (podatak iz listopada 2009. g.), nastavi li se trend otapanja leda zabilježen posljednjih 15 godina, sav led na području sjevernog pola Zemlje otopit će se u sljedećih 20 godina. U razdoblju od 1990. do 2010. g. smanjila se ledena površina Arktika za gotovo 50 %.

Slika 2. Porast prosječne temperature na površini Zemlje (ordinata – u ^{0}C) od 1950. do 2010. g. i različite prognoze do 2030. g.

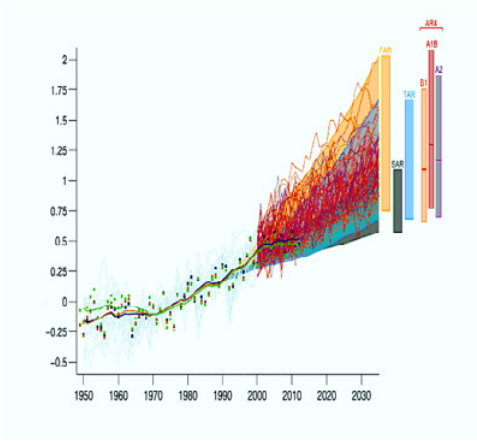

Izvor: *Fifth Assessment Report – IPCC, Introduction* (2013), Figure 1.4. (str. 131).

Slika 3. Porast koncentracije ugljičnog dioksida (ordinata u ppm) u atmosferi Zemlje od 1950. do 2010. g. i različite prognoze do 2030. g.

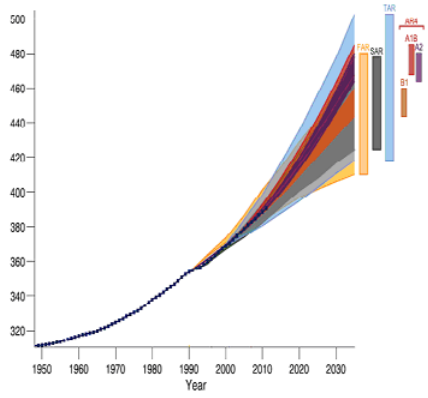

Izvor: *Fifth Assessment Report – IPCC, Introduction* (2013), Figure 1.5. (str. 132).

Slika 4. Prosječni porast razine mora (ordinata u cm) od 1950. do 2010. g. i različite prognoze do 2030. g.

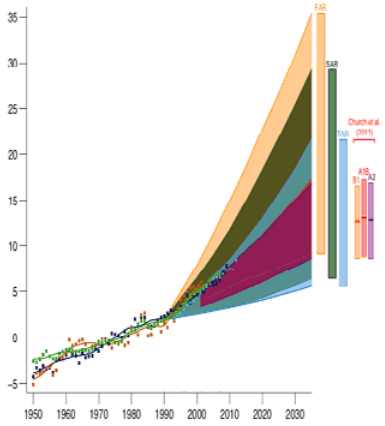

Izvor: *Fifth Assessment Report – IPCC, Introduction* (2013), Figure 1.10. (str. 137).

Slika 5. Smanjenje ledene površine u sjevernoj hemisferi od 1980. do 2010. g. i različite prognoze do 2030. g.

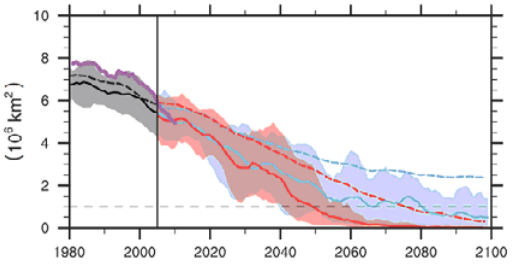

Izvor: *Fifth Assessment Report – IPCC, Technical Sum-mary* (2013), Figure TS-17 (str. 92).

4. ANTROPOGENE EMISIJE STAKLENIČKIH PLINOVA, OSOBITO IZ PROMETA 1990. I 2010. G.

U ovom će se poglavlju obraditi trendovi emisija stakleničkih plinova u razdoblju od 1990. do 2010. g. u svijetu, Republici Hrvatskoj (u daljnjem tekstu: RH), Europskoj uniji (u daljnjem tekstu: EU) i Sjedinjenim Američkim Državama (u daljnjem tekstu: SAD).

4.1 Ukupne emisije stakleničkih plinova antropogenog podrijetla

Podaci o emisijama stakleničkih plinova antropogenog podrijetla razlikuju se prema pojedi-nim izvorima. Tako su, primjerice, ukupne emisije ugljičnog dioksida prema "CDIAC" (United States Department of Energy Carbon Dioxide Information Analysis Center) za 2010. g. u svijetu iznosile 33.509 milijuna tona (*List of countries by Carbon dioxide emissions* – Wikipedia, od 05. 11. 2013.), a prema izvoru "EDGAR" (*Emissions database for global atmospherich research* – European Commission, od 05. 02. 2014.), ukupne su emisije stakleničkih plinova u 2010. g. iznosile 50.101 milijuna tona, te bi izračunati udio ugljičnog dioksida iznosio tek 67 % u odnosu na stvarno utvrđen udio od 76 % ili više (tablica 2). S obzirom na ocjenu da su podaci CDIAC-a nepotpuni (nisu obuhvaćene sve zemlje, odnosno područja svijeta) ubuduće ćemo se referirati na podatke EDGAR-a (obuhvaćene su 223 zemlje, odnosno područja svijeta).

Tablica 3. Antropogene emisije stakleničkih plinova 1990. i 2010. g. u Tg $CO2_{eq}$ (milijuni tona $CO2_{eq}$)

	1990. g.				2010. g.			
	Područje (zemlja)/ emisije	Emisije Tg $CO2_{eq}$	Udio u svjetskoj emisiji %	Redo-slijed	Emisije Tg $CO2_{eq}$	Udio u %	Redo-slijed	Promjena 2010. u odnosu na 1990. g. u %
1.	SAD	6.115,9	16,0	1.	6.174,9	12,3	2.	+9,6
2.	EU (27)	5.584,0	14,6	2.	4.720,1	9,4	3.	-15,4
3.	Kina	3.869,6	10,1	3.	11.181,8	22,3	1.	+277,0
4.	Rusija	3.582,3	9,3	4.	2.510,2	5,0	5.	-30,0
5.	Brazil	1.605,1	4,2	5.	1.620,7	3,2	7.	+9,7
6.	Indija	1.376,3	3,6	6.	2.697,1	5,4	4.	+95,6
7.	Japan	1.302,0	3,4	7.	1.378,7	2,8	8.	+5,9
8.	Indonezija	1.168,4	3,1	8.	1.945,6	3,9	6.	+66,5
	Ukupno 1. do 8.	24.603,6	64,3		32.223,7	64,3		+31,0
	Ostale zemlje	13.654,1	35,7		17.877,7	35,7		+31,0
	Ukupno svijet	38.257,7	100,0		50.101,4	100,0		+31,0
	RH	31,50	0,080		28,60	0,056		-9,1

Izvori:

- *Emissions database for global atmospherich research (EDGAR)* - European Commission – za sve emisije osim za EU i RH
- *Annual European Union greenhouse Gas inventory 1990-2010 and inventory report 2012* (2012), Table ES.6 (str. VIII) i *Annual European Union greenhouse Gas inventory 1990-2010 and inventory report 2012.* - „Greenhouse EU27_Summary2. xls", od 25. 9. 2013. - za EU
- *Izvješće o inventaru stakleničkih plinova na području Republike Hrvatske za razdoblje 1990.- 2010.* (2012.), Tablica 2.2-1 (str. 19) – za RH.

Ukupne emisije stakleničkih plinova u 2010. g. u odnosu na 1990. g. povećane su u svijetu za 31 % (tablica 3). Prvo mjesto u tim emisijama 1990. g. zauzimao je SAD, a od 2005. g. na dalje Kina. Osam zemalja, odnosno asocijacija (EU) emitira oko 64 % cjelokupnih stakleničkih plinova u svijetu. Visokorazvijene industrijske zemlje smanjile su emisije u promatranom razdoblju (npr. EU za 15 %) ili su one blago povećane (u SAD za 9 %, u Japanu za 6 %). Zemlje u fazi snažnog gospodarskog rasta u promatranom razdoblju bitno su povećale emisije – Indija za 96 %, Kina čak za 277 %. Dok je 1990. g. udio Kine u svjetskim emisijama iznosio tek jednu desetinu, 2010. g. u Kini je emitirana gotovo četvrtina svih emisija stakleničkih plinova u svijetu.

Emisije stakleničkih plinova u RH smanjene su 2010. g. u odnosu na 1990. g. za 9 %, te je time smanjen i udio RH u ukupnoj svjetskoj emisiji s 0,08 % (1990.) na 0,056 % (2010.).

4.2 Emisije stakleničkih plinova iz prometa

4.2.1 Usporedna analiza za RH, EU i SAD

Na svjetskoj razini procjenjuju se emisije stakleničkih plinova iz prometa s udjelom od 13 % (www.epa.gov/chlimatechange/ghgemissions/global.html, od 06. 11. 2013., izvorno: IPCC – 2007.). S obzirom da nam detaljniji podaci glede prometa na svjetskoj razini nisu dostupni, obradit ćemo kretanja stakleničkih plinova podrijetlom iz prometa za RH, EU i SAD.

Tablica 4 Emisije stakleničkih plinova u Republici Hrvatskoj prema pojedinim prometnim granama (vrstama) 1990. g. i 2010. g.[7] - u Gg CO_2eq (tisuće tona $CO2_{eq}$)

Vrsta prometa/ godina/ plin	1990. g.				2010. g.			
	CO_2	CH_4	N_2O	Ukupno	CO_2	CH_4	N_2O	Ukupno
Cestovni	3.559,0	33,0	38,6	3.630,6	5.637,4	14,7	62,0	5.714,1
Željeznički	138,1	0,2	0.4	138,7	89,3	0,1	0,2	89,6
Pomorski i riječni	133,0	0,2	0,3	133,5	115,1	0,2	0,3	115,6
Zračni	154,7	0,0	1,4	156,1	81,1	0,0	0,7	81,8
Promet ukupno	3.984,8	33,4	40,7	4.058,9	5.922,9	15,0	63,2	6.001,1
Sveukupne emisije	23.093,0	3.462,0	3.946,0	30.501,0	21.179,0	3.590,0	3.349,0	28.118,0
Udio pro-meta %	17,3 %	1,0 %	1,0 %	13,3 %	28,0 %	0,4 %	1,8 %	21,3 %
Ukupno s fugit. emis.				31.449,0				28.598,0
Udio pro-meta %				12,91 %				20,98 %

Izvor: izrađeno na osnovu podataka iz *Izvješća o inventaru stakleničkih plinova na području Republike Hrvatske za razdoblje 1990. – 2010.* (2012), Tablice: A1.2-9, A1.2-10, A1.2-11, A2.2-12, A2.2-13, A1.2-14.

[7] U tablici nisu posebno prikazani ostali staklenički plinovi, tj. F-plinovi (HFC-i, PFC-i i SF6), čije su emisije iz prometa gotovo zanemarive, a ukupno su (iz svih djelatnosti) iznosile u 1990. g. 948 Gg CO2eq, a 2010. g. 480 Gg CO2eq – op. autora.

Tablica 5. Kretanje emisija stakleničkih plinova iz međunarodnog pomorskog i zračnog prometa[8] (RH) - u Gg CO_2eq (tisuće tona $CO2_{eq}$)

	1990. g.	1995. g.	2000. g.	2005. g.	2010. g.
Bunkeri aviona	346	188	171	228	246
Bunkeri brodova	109	102	57	79	20
Ukupno	455	290	228	307	266

Izvor: Izvješće o inventaru stakleničkih plinova na području Republike Hrvatske za razdoblje *1990. – 2010.* (2012), tablica 3.2-2.

Ukupne su emisije stakleničkih plinova (CO_2eq) u RH bile manje u 2010. godini u odnosu na 1990. godinu za 9 %.

Istom su predmetne emisije iz prometa porasle za čak 48 %. Udio prometa u ukupnim emisijama CO_2eq 1990. g. bio je 13 %, a 2010. g. iznosio je već 21 %.

Porastu emisija iz prometa isključivo je pridonio cestovni promet (s porastom od 58 %), dok su kod svih ostalih prometnih grana, uslijed smanjene prometne aktivnosti, zabilježene manje emisije 2010. g. negoli 1990. g.: kod željezničkog prometa za 35% manje, pomor-skog i riječnog za 13%, a kod zračnog prometa za čak 48% manje.

Tablica 6. Emisije stakleničkih plinova na području Europske unije prema pojedinim prometnim granama 1990. g. i 2010. g. - u Gg CO_2eq (tisuće tona $CO2_{eq}$)

Vrsta prometa/ godina/ emisije	1990. g.			2010. g.			Promjena 2010. g. u odnosu na 1990. g. %
	Emisija Gg CO_2eq	Udio u ukupnoj emisiji %	Udio u emisijama iz prometa %	Emisija Gg CO_2eq	Udio u ukupnoj emisiji %	Udio u emisijama iz prometa %	
Cestovni	707.512	12,67	94,32	868.215	18,39	95,50	22,71
Željeznički	13.364	0,24	1,78	7.018	0,15	0,77	-47,49
Pomorski i riječni	15.967	0,29	2,13	17.083	0,36	1,88	6,99
Zračni	13.262	0,24	1,77	16.834	0,36	1,85	26,93
Promet ukupno	**750.105**	**13,43**	**100,00**	**909150**	**19,26**	**100,00**	**21,20**
Sveukupne emisije	**5.583.990**			**4.720.118**			**-15,47**

Izvor: Izrađeno na osnovu podataka iz: *Annual European Union greenhouse Gas inventory 1990. - 2010. and inventory report 2012.*: „Greenhouse EU27_Summary2.xls", od 25. 9. 2013.

[8] Emisije stakleničkih plinova iz međunarodnog pomorskog i zračnog prometa, koje se smatraju pripadajućim određenoj državi, ne prikazuju se prema metodologiji obračuna IPCC-a, odnosno Izvješćima u bilanci ukupnih emisija stakleničkih plinova neke države. Valja ih izračunati i prikazati zasebno, a zasnivaju se na tzv. „bunke-rima" brodova i zrakoplova (tj. napunjenom gorivu sa svrhom međunarodnog prometa), uz pretpostavku isto-značnog (proporcionalnog) obavljanja prometnih aktivnosti drugih zemalja na području RH i sl. - op. autora.

Tablica 7. Emisije stakleničkih plinova na području Sjedinjenih Američkih država prema pojedinim prometnim granama 1990. g. i 2010. g. - u Gg CO_2eq (tisuće tona)

Vrsta prometa/ godina/ emisije	1990. g.			2010. g.			Promjena 2010. g. u odnosu na 1990. g. %
	Emisija Gg CO_2eq	Udio u ukupnoj emisiji %	Udio u emisijama iz prometa %	Emisija Gg CO_2eq	Udio u ukupnoj emisiji %	Udio u emisijama iz prometa %	
Cestovni	1.235.300	20,00	79,8	1.556.900	22,82	84,7	+26,0
Željeznički	39.000	0,63	2,5	46.300	0,68	2,5	+18,7
Pomorski i riječni	45.100	0,73	2,9	43.300	0,63	2,4	-4,0
Zračni	181.200	2,93	11,7	143.900	2,11	7,8	-20,6
Naftovodi i maziva	47.700	0,77	3,1	48.200	0,71	2,6	+1,0
Promet ukupno	1.548.300	25,06	100,0	1.838.600	26,95	100,0	+18,7
Sveukupne emisije	6.175.200			6.821.800			+10,5

Izvor: *Inventory of U. S. Greenhouse Gas Emissions and Sinks 1990. - 2010.* (2012), Washington: U. S. Environ-mental Protection Agency (EPA), Tab. 2-13 (str. 2-7) i Tab. 2-15 (str. 2-22).

Ukupne su emisije stakleničkih plinova (CO_2eq) 2010. g. u odnosu prema emisijama iz 1990. g. smanjene na području EU za 15 %, a na području SAD povećane za 10 %. Međutim, predmetne emisije iz prometa povećane su i u EU i SAD (u EU za 21 %, u SAD za 19 %, u RH za 48 %). Udio emisija iz prometa u ukupnim emisijama iz prometa povećao se 2010. g. u odnosu na 1990. g. i u EU i u SAD (u EU s 94,3 na 95,5 %, u SAD s 80 % na 85 %).

S obzirom da je istom razdoblju povećana emisija CO_2eq 2010. u odnosu na 1990. g. iz cestovnog prometa i u EU i u SAD (u EU za 23 %, u SAD za 26 %), definitivno valja zaključiti o enormnom doprinosu cestovnog prometa emisijama stakleničkih plinova. Naime, emisije iz svih ostalih grana imale su bitno manji trend porasta ili su bile čak manje 2010. g. negoli 1990. g. (npr. emisije u željezničkom prometu u Europi smanjene su za 47 %, a u zračnom prometu u SAD za 21 %).

Tablica 8. Udio emisija iz prometa u emisijama stakleničkih plinova (2010.) i trendovi promjena udjela 2010. u odnosu na 1990. g. u RH, EU i SAD - u %

Vrste prometa/ emisije	Udio u ukupnim emisijama 2010. g. u %			Promjena udjela 2010. g. u odnosu na 1990. g. u %		
	RH	EU	SAD	RH	EU	SAD
Cestovni	19,98	18,39	22,82	+73,08	+45,15	+11,40
Željeznički	0,31	0,15	0,68	-29,02	-37,50	+7,94
Pomorski i riječni	0,40	0,36	0,63	-4,94	+24,14	13,70
Zračni	0,29	0,36	2,11	-42,34	+50,0	-27,99
Naftovodi i maziva	NP[1]	NP	0,71	NP	NP	-7,80
Promet ukupno	20,98	19,26	26,95	+62,59	+43,41	+7,50
Stakleni̇čki ukupno	-	-	-	-9,07	-15,47	+10,47

Izvor: izrađeno na temelju podataka iz tablica 4, 6. i 7

Udio emisija stakleničkih plinova podrijetlom iz prometa u ukupnim emisijama stakleničkih plinova bio je 2010. g. najmanji u EU (19,3 %), slijedi RH (21,0 %), a u SAD je bio najveći (27 %).

Pritom je cestovni promet ukupnim emisijama iz prometa sudjelovao u SAD s 85 %, a u RH i EU s podjednakim udjelom od 95 %.

Porast udjela emisija iz prometa u 2010. u odnosu na 1990. g. najveći je u RH (porast za 63 %), slijedi EU (za 43%) i SAD (za 7,5%). Tome porastu najviše je pridonio porast emisija iz cestovnog prometa, koji je zabilježen u sve tri zemlje (asocijacije): najviše u RH za 73%, slijedi EU za 43% i SAD za 11,4%.

Smanjenje udjela emisija iz željezničkog prometa 2010. u odnosu na 1990. g. najveće je u EU (za 38%), slijedi RH (za 29%), a u SAD su emisije nešto povećane (za 8%). Predmetno smanjenje udjela bilježi se kod emisija iz zračnog prometa u RH (za 42%) i u SAD (za 28%), dok je taj udio u EU znatno povećan (za 50%).

4.2.2 Osnovne poruke glede emisija iz prometa i drugo

Udio stakleničkih plinova iz prometa u porastu je od 1990. do 2010. g. Najvećim dijelom tome pridonosi cestovni promet, čiji je udio u odnosu na ostale prometne grane u stalnom porastu, tako da danas u EU i RH sve ostale prometne grane sudjeluju u stakleničkom učinku od prometa s manje od 5 %, a u SAD s udjelom od 15 %. Osim toga, u cestovnom se prometu zadnjih 20 godina redovito bilježi porast emisija stakleničkih plinova, čak i u onim područjima svijeta u kojima je došlo do smanjenja ukupnih emisija stakleničkih plinova antropogenog podrijetla.

To upućuje da bi, glede prometa, osnovne napore trebalo usmjeriti prema smanjenju emisija iz cestovnog prometa.

Glede kazanog, iz različitih razloga (visoke cijene goriva, potreba smanjenja emisija onečišćujućih tvari, smanjenje emisije stakleničkih plinova), automobilska je industrija u zadnje vrijeme, a osobito zadnjeg desetljeća, bitno smanjila specifičnu potrošnju goriva kod osobnih vozila. Slijedom toga, smanjene su i specifične emisije stakleničkih plinova, osobito ugljičnog dioksida, kod osobnih vozila (tablica 9).

Tablica 9. Prosječna emisija ugljičnog dioksida iz osobnih vozila 2000. i 2010. g. i utvrđeni standardi za 2020. g. - u gramima CO_2/km

Zemlja/ godina	2000. g. gCO_2/km	2010. g. gCO_2/km	Promjena 2010/2000. g. %	Plan za 2020. g. gCO_2/km	Promjena 2020/2000. g. %
SAD	270	230	-15%	170	-37%
EU	260	220	-15%	140	-54%
Kina	?	180	?	130	?
Japan	170	130	-24%	105	-38%

Izvor: *The Emissions GAP Report* (2012), Nairobi:
United Nations Environment Programme (UNEP), Figure 4.2 (str. 40).

4.3 Očekivanja glede budućih emisija stakleničkih plinova

Na osnovu do sada provedenih analiza i usporedbi, možemo, glede daljnjeg razvoja emisija stakleničkih plinova, zaključiti:

1. Povećanje ukupnih emisija stakleničkih plinova na svjetskoj razini.
   Bez obzira na stagnaciju porasta emisija u industrijski najrazvijenim zemljama, za očekivati je porast emisija u zemljama s intenzivnim gospodarskim razvojem (Kina, Indija, Indone-zija, Brazil, Nigerija i dr.), što će pridonijeti povećanju ukupnih emisija u svijetu.

2. Povećanje ukupnih emisija iz prometa.
   Bez obzira na određene procese smanjenja trenda porasta ili čak apsolutnog smanjenja emisija iz željezničkog, pomorskog i riječnog te zračnog prometa, povećanjem broja cestovnih motornih vozila, koje se prije svega očekuje u zemljama s relativno malim stupnjem motorizacije, ali i stalno rastućim gospodarstvima, trend porasta emisija iz prometa mogao bi sljedeće desetljeće biti čak i veći nego u prethodna dva desetljeća.

3. Na procese iz točke 2 moglo bi dijelom (osim utjecaja mjera poduzetih na svjetskoj razini) utjecati povišenje cijene fosilnih goriva, osobito derivata nafte, slijedom objektivnih ili namjerno izazvanih poruka o smanjenju svjetskih zaliha[9].

4. Čak i u slučaju kada ne bi došlo do povećanih emisija stakleničkih plinova (što nije za očekivati, barem u sljedećem desetljeću), koncentracija stakleničkih plinova u troposferi znakovito će porasti – sa svim posljedicama koje taj proces izaziva (vidjeti poglavlje 3).

Kao dodatnu potvrdu gore navedenih konstatacija, valjalo bi navesti dvije važne okolnosti: očekivanje glede porasta cestovnih vozila s jedne i neuspjele međunarodne dogovore oko daljnjih mjera smanjenja stakleničkih plinova s druge strane.

Broj cestovnih vozila u svijetu porastao je u razdoblju od 1990. g. s 583 milijuna na 1,015 milijardi u 2010. g. (tablica 10), tj. za 74 % (u istom je razdoblju svjetsko stanovništvo povećano tek za 30 %)[10]. Pritom je značajniji bio porast broja teretnih vozila (i autobusa): za 123 % u odnosu na porast osobnih vozila koji je iznosio 59 %, a teretna vozila radi svoje potrošnje goriva emitiraju do nekoliko puta više stakleničkih plinova od osobnih. Porast broja vozila u promatranom je razdoblju bio manji u visokorazvijenim zemljama (npr. u SAD za 27 %, EU za 49 %) negoli je to bilo na svjetskoj razini (74 %). U zemljama s dinamičkim gospodarskim razvojem taj je porast bio iznimno visok. Tako je cestama Kine „vozilo" gotovo 13 puta više vozila 2010. negoli 1990. g. (tablica 10). S obzirom da je stupanj motorizacije (broj vozila na 1.000 stanovnika) u tim mnogoljudnim zemljama manji od svjetskog prosjeka (tablica 10), za očekivati je daljnji trend porasta cestovnih vozila na svjetskoj razini. Primjerice, u Kini je stupanj motorizacije 2010. g. bio devet puta manji negoli u RH i četrnaest puta manji nego u SAD-u (tablica 10).

[9] Većina izvora govori o svjetskih zalihama nafte dostatnih za sljedećih 50 godina, a plina za sljedećih 100 do 150 godina. Međutim, riječ je prvenstveno o zalihama koje se procjenjuju na temelju dosad dostupnih tehnologija crpljena nafte i plina.

[10] Izračunano prema: Population Growth – Wikipedia, http://en.wiki/File: Population_Curve.svg, od 10. 11. 2013. (izvorno prema UN population statistics).

Emisije stakleničkih plinova po stanovniku u zemljama sa snažnim gospodarskim uzletom još uvijek su relativno male u odnosu na emisije u visokorazvijenim zemljama. Tako su pred-metne emisije u Kini 2010. g. iznosile 6,2 t ugljičnog dioksida po stanovniku, u Indiji 1,7, u Indoneziji 2,0, u Brazilu 2,2, dok je emisija u SAD iznosila 17,6 t, u Njemačkoj 9,3, u Rusiji 12,0, u Saudijskoj Arabiji 18,2, u Australiji 16,0 i u Kanadi 18,2 t (*List of countries by carbon dioxide emissions* – Wikipedia, 05. 10. 2013.). S obzirom da je svjetski prosjek iznosio 4,9 t ugljičnog dioksida po stanovniku, za očekivati je porast emisija stakleničkih plinova u pojedinim zemljama, što će, s obzirom na njihovu veličinu, odnosno broj stanovnika (2013. g. Kina: 1,39 milijardi stanovnika, Indija: 1,25 milijardi, Indonezija: 250 milijuna, Nigerija: 174 milijuna, Brazil: 200 milijuna (prema: *World Population Prospects,* 2013: 51-60.) imati znakoviti utjecaj na porast emisija stakleničkih plinova na svjetskoj razini.

S druge strane, valja uvažiti okolnost da su svi pokušaji glede dogovora (nakon tzv. „Proto-kola iz Kyota") oko konkretnih mjera za smanjenje stakleničkih plinova na međunarodnoj razini posljednjih godina doživjeli neuspjeh (vidjeti poglavlje 5).

Tablica 10. Broj cestovnih vozila i stupanj motorizacije 1990. i 2010. g. (svijet, SAD, Kina, EU, RH)

Područje (zemlja)/ vozila	Vrsta cestovnih vozila	1990. g.		2010. g.		Odnos broja vozila 2010/1990. u %
		Broj vozila	Voz./1000 stanovnika	Broj vozila	Voz./1000 stanovnika	
Svijet	Osobna v.	444.900.000		707.764.000		+59,1
	Autobusi i teretna v.	138.082.000		307.497.000		+122,7
	Ukupno	582.982.000	110,4	1.015.261.000	147,2	+74,1
EU	Osobna v.	163.050.000		238.762.000		+46,4
	Autobusi i teretna v.	20.238.000		34.911.000		+72,5
	Ukupno	183.288.000	389,7	273.673.000	548,2	+49,3
SAD	Osobna v.	143.550.000		118.947.000		-17,1
	Autobusi i teretna v.	45.106.000		120.865.000		+168,0
	Ukupno	186.656.000	744,7	239.812.000	772,6	+27,1
Kina	Osobna v.	1.897.000		34.430.000		+1.715,0
	Autobusi i teretna v.	4.314.000		43.590.000		+910,4
	Ukupno	6.211.000	5,4	78.020.000	58,2	+1.156,2
RH	Osobna v.	1.120.000		1.492.000		+ 33,2
	Autobusi i teretna v.	87.000		168.000		+93,1
	Ukupno	1.207.000	258,3	1.660	387,5	+37,5

Izvori: za podatke o broju vozila
- za svijet, SAD i Kinu: *Transportation Energy Data Book – Edition 31* (2012), Tab. 3.2., 3.3. i 3.6.
- za EU: *EU Transport in figures – Statistical Pocketbook 2012* (2012), Tab. 2.6.2.
- za RH: *Izvješće o proračunu emisija onečišćujućih tvari u zrak na području Republike Hrvatske za 2011. godinu* (2013), Tab. 3.1-1.

za podatke o broju stanovnika
- za svijet, EU, SAD i Kinu: *Population Growth – Wikipedia*, 10. 11. 2013.
- za RH: Wertheimer-Baletić, A. (2013), *Dugoročni demokratski procesi u Hrvatskoj – izazov za 21. stoljeće*, poglavlje 1., tablica 1.

5. OSVRT NA MJERE ZA SMANJENJE EMISIJA STAKLENIČKIH PLINOVA

Nakon što je u drugoj polovici dvadesetog stoljeća postao očigledan prinos ljudske djelatnosti globalnom zagrijavanju mimo uobičajenih prirodnih procesa, započele su aktivnosti na ograničavanju antropogenih utjecaja na klimatske promjene. Međunarodna klimatska politika započinje se sustavno voditi od 1979. g., nakon prve Svjetske konferencije o klimi, kada je u Genevi usvojen Svjetski klimatski program. Opća skupština UN proglasila je 1988. g. „klimatske promjene zajedničkom brigom čovječanstva". Tada su skupština UN i Svjetska meteorološka organizacija (WMO) zajednički osnovali međuvladino tijelo za klimatske promjene (*Intergovernmental Panel on Climate Change* odnosno IPCC). Uslijedila je Međunarodna konferencija o klimatskim promjenama 1988. g. u Torontu.

1992. g. održana je svjetska konferencija o zaštiti okoliša i razvoja u Rio de Janeiru, te je tom prilikom donijeta *Okvirna konvencija UN o promjeni klime* (*United Nations Framework Convention on Climate Change*, odosno UNFCCC). Nakon toga se, u pravilu jednom godišnje, održavaju sjednice stranaka, odnosno članica UNFCC-konvencije (*Conferences of the Parties*, odnosno COP).

Najvažniji sporazum postignut je 1997. g. na 3. konferenciji COP održanoj u japanskom gradu Kyotu. Tom je prilikom usvojen tzv. *Protokol iz Kyota* (uz UNFCC-konvenciju). Kyot-skim protokolom zemlje-potpisnice su se obvezale da će u razdoblju od 2008. do 2012. godine smanjiti emisije stakleničkih plinova za pprosječno 5,2 % godišnje u odnosu na emisije iz 1990. g. SAD i neke druge zemlje, iako potpisnice protokola, nisu godinama nakon toga ratificirale sporazum, radi procjene kako bi njegova primjena mogla bitno naštetiti gospodarskom razvoju njihovih zemalja i standardu građana. Protokolom je predviđeno da će neke zemlje ili asocijacije smanjiti predmetne emisije za više od 5,2 % (npr. zemlje EU u prosjeku 8 %, što je EU dodatno rasporedila na pojedine članice), neke za manje od 5 %, a primjerice Indiji, Kini i Brazilu (odnosno tzv. zemljama u razvoju) nisu određena nikakva ograničenja glede emisija. Protokolom je predviđeno i trgovanje emisijskim kvotama stakleničkih plinova. Protokol je stupio na snagu 16. 02. 2005. g. kada su ga ratificirale zemlje članice COP-a s ukupnim udjelom od 55 % u svjetskoj emisiji stakleničkih plinova.

Republika Hrvatska je Kyotski protokol ratificirala tek 2007. g., nakon dugotrajnih pregovora o razini emisije stakleničkih plinova u baznoj 1990. godini. Hrvatskoj su priznate posebne okolnosti u kojima je bila 1990. g. (kao dio Jugoslavije koristila je energiju iz termoelektrana koje su se nalazile na prostorima izvan Hrvatske, odnosno u BiH i Srbiji i slijednog ratnog stanja), te joj je odobrena dodatna emisija stakleničkih plinova u baznoj godini u iznosu od 3,5 milijuna tona, što se dodalo dotadašnjoj kvoti od 31,12 milijuna tona (ukupno 34,62 mili-juna tona u 1990. godini).

Nakon toga, do 2012. g. nije, bez obzira na ozbiljna upozorenja IPCC-a glede povećanja koncentracija stakleničkih plinova u troposferi i sljednog porasta temperature i povišenja razine mora, postignut niti jedan konkretan dogovor glede smanjenja predmetnih emisija. Naime, znanstvenici su utvrdili da bi kod povećanja koncentracije od 490 do 535 ppm stakleničkih plinova u troposferi, a što će se dogoditi ukoliko se antropogene emisije 2020. g. u odnosu na emisije iz 2000. g. ne smanje za 30 do 60 %, došlo do povećanja prosječne temperature na zemlji za 2,4 do 2,8 ^{0}C (*Climate Change 2007*: 67). Isto tako su procijenili da bi godišnja svjetska emisija od 40.000 Gt stakleničkih plinova (2010.

g. je već iznosila preko 50.000 Gt – vidjeti tablicu 3) uzrokovala povećanje prosječne temperature na Zemljinoj površini 2050. g. za 4 ^{0}C (*Climate Change 2007*: 66).

2012. g. na 18. sjednici COP-a donijet je sporazum kao nastavak na Protokol iz Kyota, kojim je utvrđeno 15 % prosječno godišnje smanjenje stakleničkih plinova u razdoblju od 2013. do 2020. g. u odnosu na emisije iz 1990. g. Međutim, ne samo da neke članice COP-a nisu potpisale predmetni sporazum, već se do danas nisu stekli uvjeti za njegovo stupanje na snagu (izostala je ratifikacija stranaka COP-a).

Na sljedećim sjednicama COP-a postignuti su tek ovkvirni dogovori oko nekih mjera, ali bez konkretnih izvršnih instrumenata. Najznačajniji je pritom okvirni dogovor (Durban, 2010. g.) oko ustroja Međunarodnog klimatskog fonda (*Green Climate Fund*), kojim bi se pomoglo najviše ugroženim zemljama pri ublažavanju negativnih posljedica klimatskih promjena u njihovim zemljama[11].

Europska unija je za sada jedina zemlja ili asocijacija (osim, primjerice, Kalifornije), koja je poduzela djelotvorne mjere za smanjenje antropogenih emisija stakleničkih plinova[12].

2007. g. čelnici EU podržali su sljedeće ambiciozne ciljeve: smanjenje emisija stakleničkih plinova 2010. g. u odnosu na 1990. g. za 20 %, povećanje udjela obnovljivih izvora energije u ukupnoj energetskoj potrošnji za 20 % te povećanje energetske učinkovitosti, odnosno smanjenje ukupne energetske potrošnje za 20 % (*plan: 20-20-20*). Europski parlament je ovaj paket mjera usvojio u travnju 2009. g. usvajanjem 6 zakonodavnih mjera, od kojih je naj-važnija odluka *No 406/2009/EC od 23. 4. 2009. g.* (*L 140/36*, objavljena 05. 6. 2009. g.), kojim se pojedinim članicama određuju dodatni predmetni udjeli smanjenja emisija. Ovim je dokumentom, osim toga, utvrđena potreba smanjenja emisija stakleničkih plinova 2050. u odnosu na 1990. g. za 50 %.

U ožujku 2011. g., Europska je komisija utvrdila *Plan za preobrazbu Europske unije u konkurentno gospodarstvo s malom razinom ugljika* (*COM(2011) 112 final*, od 08. 3. 2011.), kojim je utvrđen cilj smanjenja emisija stakleničkih plinova 2050. u odnosu na 1990. g. u rasponu od 79 do 82 % te odgovarajući raspored godišnjeg smanjenja prema desetljećima od 2020. do 2050. g.

Međutim, 22. siječnja 2014. g. Europska je komisija objavila tzv. „Drugi energetsko-klimatski paket", u kojem se podaci ne odnose na 2050. g., a kojim je utvrđen cilj glede smanjenja emisija u EU 2030. g. u odnosu na 1990. g. za 40 % te povećanje udjela obnovljivih ener-getskih izvora na barem 27 %. Očekuje se usvajanje ovog paketa od strane Europskog parlamenta u prvom tromjesečju 2014. g.

S obzirom na očekivane trendove porasta broja cestovnih vozila u svijetu (vidjeti poglavlje 4.3., odnosno tablicu 10) i rastućeg udjela emisija stakleničkih plinova iz prometa, smanjenje emisija stakleničkih plinova iz prometa na svjetskoj razini, dok ne dođe do nekih znakovitih, ali i neočekivanih okolnosti, bit će „nemoguća misija".

S druge strane, Europska je unija 28. 3. 2011. g. donijela „Bijelu knjigu" glede razvitka prometa do 2050. g. (White paper 2011), kojom je putem niza mjera koje valja poduzeti u prometu, utvrđen

[11] Predviđen je promptni predmetni iznos od 30 milijardi USD i godišnji iznos od 100 milijardi USD.

[12] Na području EU smanjene su emisije stakleničkih plinova 2012. g. u odnosu na emisije iz 1990. g. za 18 %.

sljedeći cilj: smanjenje emisija stakleničkih plinova 2050. u odnosu na 1990. g za 60 %. Tome valja pridodati odrednicu iz *Plana za preobrazbu Europske unije u konkurentno gospodarstvo s malom razinom ugljika* (vidjeti ranije), kojom je utvrđena emisija stakleničkih plinova iz prometa u 2030. u odnosu na 1990. g. od + 20 % do -9 %, a 2050. g. u odnosu na 1990. g. za -54 % do -67 % (Table 1, str. 6 dokumenta). Međutim, udio emisija stakleničkih plinova emitiranih na području EU u stalnom je smanjenju u odnosu na svjetske emisije, te se sukladno tome stalno smanjuje doprinos i utjecaj EU glede svjetske emisije stakleničkih plinova (predmetni je udio 1990. g. iznosio 14,6 %, 2010. g. 9,4 %, a 2013. g. oko 8 %).

Pojačanim korištenjem raspoloživih nekonvencionalnih energetskih resursa, umjesto fosilnih goriva u prometu (prirodni plin, biološka goriva, hibridni pogon i sl.), ne mogu se znakovito ublažiti negativni utjecaji prometa na okoliš. Tek širokom primjenom energije Sunca (solarna energija) mogle bi se bitno ublažiti posljedice čovjekova djelovanja na klimu našega planeta.

Preostaje razmišljanje o našem budućem ponašanju. Naime, jesmo li kadri relativno lagodni život visokog standarda uskoro zamijeniti skromnijim ili ćemo nastaviti s dosadašnjim pona-šanjem i budućim generacijama prepustiti borbu za preživljavanje na našem planetu.

6. ZAKLJUČCI

Emisije stakleničkih plinova antropogenog podrijetla od početka industrijskog doba do danas u stalnom su porastu. Posljednja dva desetljeća došlo je do znakovitog povećanja tih emisija. Istodobno je zabilježen porast koncentracije stakleničkih plinova (imisijske vrijednosti) u troposferskom sloju Zemljine atmosfere. Slijedom povećanja predmetne koncentracije dolazi do povećanja intenziteta stakleničkog učinka u odnosu na Zemljinu površinu, odnosno do znakovitih promjena klimatskih prilika na Zemlji, mimo uobičajenih prirodnih procesa.

Emisije stakleničkih plinova podrijetlom iz prometa u dobroj mjeri utječu na porast koncen-tracije tih plinova u troposferi. Na svjetskoj razini predmetni udio prometa iznosi barem 13 % (2007.), dok su kod istraživanih zemalja ustanovljeni predmetni udjeli 2010. godine u rasponu od 19 % (EU), preko 21 % (RH) do 27 % (SAD). Istom je ustanovljen apsolutni porast emisija iz prometa u 2010. g. u odnosu na 1990. g. u rasponu od 19 % (SAD), preko 21 % (EU) do 48 % (RH).

Tome trendu najviše doprinose emisije stakleničkih plinova iz cestovnog prometa, čiji se udio 2010. g. u ukupnim emisijama iz prometa kretao od 85 % (SAD), do 95 % (EU i RH). Nadalje je utvrđen i relativni porast udjela emisija iz cestovnog prometa u ukupnim emisijama iz pro-meta 2010. g. u odnosu na 1990. g. u rasponu od 8 % (SAD), preko 43 % (EU) do 63 % (RH).

S obzirom na relativno skroman stupanj motorizacije (broj cestovnih vozila na tisuću stanov-nika) 2010. g. u mnonogljudnim zemljama s brzo rastućim gospodarstvima (npr. u Kini je 2010. g. iznosio 58,2 vozila na 1000 stanovnika i bio je 9 puta manji nego u RH i 14 puta manji nego u SAD, pri čemu je Kina brojila 1,35 milijardi stanovnika), za očekivati je narednih desetljeća znakoviti porast emisija stakleničkih plinova iz cestovnog prometa koji će pridonijeti cjelokupnoj svjetskoj emisiji stakleničkih plinova.

Osim toga, ustanovljeno je da su specifične emisije stakleničkih plinova u zemljama sa snažnim gospodarskim uzletom relativno skromne u odnosu na emisije u visokorazvijenim zemljama. Primjerice, u Kini je emisija ugljičnog dioksida 2010. g. iznosila 6,2 tone po stanovniku, u Indiji 1,7, Indoneziji 2,0 i Brazilu 2,2 t/st., dok je predmetna emisija u SAD iznosila 17,6 t/st., Australiji 16,0, Kanadi 18,2 i Rusiji 12,0 t/st. To smatramo dodatnim podatkom radi kojega se može očekivati daljnji porast emisija stakleničkih plinova u svijetu.

Posljedice povećane koncentracije stakleničkih plinova u troposferi ogledaju se mnogostru-kom djelovanjem na klimu Zemlje, npr. putem povećanja prosječne temperature na Zemljinoj površini, povećanja temperatura oceana i povećanja razina soli u njima, uslijed čega se nag-lo mijenjaju uvjeti života u oceanima, a mijenja se i intenzitet glavnih morskih struja, putem širenja površina pustinja, a smanjenja površine šuma, otapanjem glečera i porastom razine mora, smanjenjem snježnog pokrivača u sjevernim dijelovima, povećanom učestalošću padavina, povećanjem učestalosti „prirodnih" tajfuna (uragani, tsunami, suše, poplave i dr.).

Slijedom navedenih procesa realno je očekivati, ukoliko se na međunarodnoj razini ne postignu odgovarajući dogovori s ciljem smanjenja antropogenih emisija stakleničkih plinova, emigracijske procese iz obalnih područja, a nije moguće isključiti lokalne, ali i sukobe većih razmjera u svijetu.

Najvažniji sporazum međunarodnih razmjera postignut je na 3. konferenciji zemalja članica Okvirne konferencije UN o zaštiti klime u japanskom gradu Kyotu, kojim su se zemlje potpis-nice obvezale da će u razdoblju od 2008. do 2012. godine godišnje u prosjeku smanjiti emisije stakleničkih plinova za 5,2 % u odnosu na emisije iz 1990. g. Bez obzira na potpise predstavnika vlada pojedinih zemlja, provedba protokola bila je veoma otežana jer pojedine zemlje nisu niz godina ratificirale protokol, smatrajući kako bi njegova primjena mogla znakovito naškoditi razvoju njihovih gospodarstava. Protokol je stupio na snagu 16. 2. 2005. g., kada su ga ratificirale zemlje s ukupnim udjelom od 55 % u svjetskoj emisiji stakleničkih plinova.

Bez obzira na znakovita upozorenja svjetske organizacije za zaštitu klime (IPCC) o potrebi smanjenja emisija stakleničkih plinova za 50 % do 2050. g. (u odnosu na emisije iz 1990. g.) na svjetskoj razini, kako se prosječna temperatura na našem planetu ne bi do kraja stoljeća povećala za više od 2 ^{0}C, do sada na međunarodnoj razini (nakon protokola iz Kyota) nije postignut niti jedan konkretan dogovor.

Ipak, ohrabruju dokumenti Europske unije, osobito tzv. „klimatski paketi", kojima je utvrđeno potrebno smanjenje stakleničkih plinova na području EU za 2 0% u 2030. g., odnosno za 40 % do 2030. u odnosu na 1990. g., kao i niz drugih mjera glede ograničavanja emisija ugljičnog dioksida iz prometa.

LITERATURA

Annual European Union greenhouse Gas inventory 1990. – 2010. and inventory report 2012 (2012), Copenhagen: European Environment Agency (EEA).

Annual European Union greenhouse Gas inventory 1990. -2010. and inventory report 2012: „Greenhouse EU27_Summary2. xls" //http:www.eea.europa.eu//publications/european-union-green-house-gas-inventory–2012 (25. 9. 2013.)

A roadmap for moving to a competitive low carbon economy in 2050 (2011) – Communications from the Commissions to the European Parliament and the Council – COM (2011) 112 final, Brussels (8. 3. 2011.)

Blasing, T., J. (2013) *Recent Greenhouse Gas Concentration* //http://cdiac.ornl.gov/pns-/current_ghg.html (15. 11. 2013.)

Climate Change 2007: Synthesis Report (IPCC, 2007), Valencia: Intergovernmental Panel on Climate Change, November 2007. //https:www.ipcc.ch/pdf/assses-sment-report/ar4/syr/ar4_syr.pdf, od 12. 8. 2012.)

Decision No 406/2009/EC of the European Parliament and of the Council of 23 April 2009 on the effort of Member States to reduce their greenhouse gas emissions to meet the Community's greenhouse gas emission reduction commitments up to 2020. - Official Journal of the European Union L 140/3 (15. 6. 2009.)

EPA, Global Greenhouse Gas Emissions Data //htto:www.epa.gov/climatechange/ghgemis-sions/global.html

(6. 11. 2013.)

Emissions database for global atmospherich research (EDGAR) - European Commission //http:jrc.ec.europa.eu/ overwiew.php?v =GHGts1990-2010. (12. 2. 2014.)

EU Transport in Figures – Statistical Pocketbook 2012 (2012), Luxembourg: Publications Office of European Union.

Fifth Assessment Report: Introduction – Intergovermental Panel on Climate Change (IPCC, 2013)

//https:www.ipcc.ch/report/ar5/wg1 →Report by Chapters →Chapter 1: Introduction (16. 2. 2014.)

Fifth Assessment Report: Technical Summary – Intergovermental Panel on Climate Change (IPCC, 2013)

//https:www.ipcc.ch/report/ar5/wg1 →Report by Chapters →Technical Summary (27. 12. 2013.)

Glavač, V. (2001) *Uvod u globalnu ekologiju,* Zagreb: Hrvatska sveučilišna naklada i Ministarstvo zaštite okoliša i prostornog uređenja RH.

Inventory of U. S. Greenhouse Gas Emissions and Sinks 1990-2010 (2012), Washington: U. S. Environmental Protection Agency (EPA).

Izvješće o inventaru stakleničkih plinova na području Republike Hrvatske za razdoblje 1990.-2010 (2012), Zagreb: Ministarstvo zaštite okoliša i prirode i Agencija za zaštitu okoliša.

Izvješće o proračunu emisija onečišćujućih tvari u zrak na području Republike Hrvatske za 2011. godinu (2013), Zagreb: Ministarstvo zaštite okoliša i prirode i Agencija za zaštitu okoliša.

List of countries by carbon dioxide emissions – Wikipedia (primarni izvor: United States Department of Energy Carbon Dioxide Information Analysis Center - CDIAC)

//http://en.wikipedia.org/wiki/List_of countries_by_carbon_dioxide_emissions (15. 11. 2013.)

Population Growth – Wikipedia (izvorno prema: UN population statistics)

//http://en.wiki/-File: Population_Curve.svg (10. 11. 2013.)

Roadmap to a Single European Transport Area – Towards a competitive and resource efficient transport system (White paper 2011), Brussels: European Commission COM/2011/ 144 final (28. 3. 2011.)

The Emissions GAP Report (2012), Nairobi: United Nations Environment Programme (UNEP).

Transport 2050: Commission outlines ambitious plan to increase mobility and reduce emissions (White paper 2011), Brussels: EU Press releases Database 28. 3. 2011

//http://europa.eu/rapid/press-release-IP-11-372_en.htm (10. 10. 2013.)

Transportation Energy Data Book, Edition 31 (2012), Oak Ridge: U.S. Department of Energy.

Wertheimer-Baletić, A. *Dugoročni demokratski procesi u Hrvatskoj – izazov za 21. stoljeće*

//http://nacinalni-forum.hr/default.aspx?id=58. (10. 11. 2013.)

World Population Prospects - The 2012 Revision (2013), N. York: United Nations (UN) – Department of Economic and Social Affairs.

Ivo Brozović [1]
Aleksandar Regent [2]
Matea Grgurević [3]

Preliminary communication
UDC 504.3.054:656.1

GREENHOUSE GAS EMISSIONS, ESPECIALLY FROM TRAFFIC

(Contribution to the analysis of greenhouse gas emissions, especially from traffic)[4]

ABSTRACT

This paper presents the results of studies on the greenhouse gas emissions caused by human activities, especially the emissions originating from transport. Since the beginning of the industrial revolution until today a steady increase has been recorded in anthropogenic greenhouse gas emissions which increase the concentration of greenhouse gases (imission values) in the troposphere and thereby increase the intensity of the greenhouse effect. This paper analyzes the impacts of anthropogenic emissions of relevant greenhouse gases on a global level from 1750 until today. In particular, comparison has been made in view of greenhouse gas emissions for the three countries (associations): Croatia, the European Union and the United States. The results have shown an absolute increase in emissions from transport in 2010 compared to emissions in 1990 in all three entities studied, ranging from 19% (U.S.) to 21% (EU) and 48% (Croatia). The biggest contributor to this trend are emissions from road transport (2010 with a share of 85% to 95% in total emissions from transport) whose relative share of increase in total emissions from transport in 2010 with regard to 1990 was in the range from 8% (U.S.), to 43% (EU) and up to 63% (Croatia). Given the relatively modest level of motorization in heavily populated countries with rapidly growing economies (China, India, Indonesia, Nigeria etc.), an increase in total greenhouse gas emissions can be expected over the coming decades, with the highest percentage of emissions coming from road transport. This could undermine the climate conditions on our planet which are still relatively favorable for life. The paper ends with a discussion on possible action regarding the reduction of expected trends in greenhouse gas emissions and with the conclusions.

Key words: *greenhouse gas emissions, traffic, Croatia, EU, world.*

[1] MSc, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: ivo.brozovic@veleri.hr
[2] PhD, Senior Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: aleksandar.regent@veleri.hr
[3] Student, Faculty of Science, University of Zagreb, Republike Austrije 15, Zagreb, Croatia. E-mail: oleg.grgurevic@arhitekt.hr
[4] Received: 24. 2. 2014.; accepted: 5. 5. 2014.

Milorad Milojica[1]
Kristina Dundović[2]

Stručni rad
UDK 331.462:627.09(497.5 Rijeka)

PRIMJENA POISSONOVE RAZDIOBE U STATISTIČKOJ OBRADI OZLJEDA NA RADU U TRGOVAČKOM DRUŠTVU „LUKA RIJEKA“[3]

SAŽETAK

Unapređivanje sigurnosti pri radu može se smatrati općim ciljem statističke obrade podataka o nezgodama pri radu. U okviru tog općeg, mogu se posebno istaknuti specifični ciljevi, kao što je dobivanje valjanih i pouzdanih informacija na temelju kojih upravljački menadžment u poduzeću može voditi racionalnu politiku unapređivanja i upravljanja sigurnošću. Vjerojatnost da nastupi ozljeda na radu u određenom vremenskom intervalu jednaka je omjeru broja ozlijeđenih radnika i ukupnog broja radnika u promatranoj populaciji. Iskustvo općenito pokazuje da je vjerojatnost ozljeda u periodu od jedne godine vrlo mala, te da je ozljeda na radu stoga "rijedak događaj". Kako se ozljeda na radu može ponoviti, odnosno budući da jedan radnik može doživjeti jednu, dvije, tri i više istovrsnih ili različitih ozljeda, može se promatrati razdioba broja ozljeda (frekvencija) po radnicima. Obično se pretpostavlja da je razdioba broja ozljeda dobro opisana teorijskom Poissonovom razdiobom. U pripremi ovog rada izvedena su istraživanja koja se temelje na godišnjem Izvješću o Zaštiti na radu Službe zaštite na radu Luke Rijeka gdje je korištena Poissonova distribucija kao statistička metoda pri analizi ozljeda na radu. Cilj ovog rada je ukazati na potrebu sustavnih istraživanja sa svrhom daljnjeg smanjenja ozljeda na radu u lučkim procesima. Primjenom statističke metode prilikom analize ozljeda na radu dobili smo smjernice za sustavno istraživanje ozljeda, kako bi se „rijedak događaj" (kako se u praksi definira ozljeda na radu) u potpunosti pokušao eliminirati.

Ključne riječi: *zaštita na radu, statistička obrada, ozljede na radu, učestalost ozljeda, Poissonova distribucija*

1. UVOD

Sigurnost na radu ima posebno značajnu ulogu u radu lučkih sustava.

Strategija postignuća cilja „bez ozljeda na radu" zasniva se na: stalnom osposobljavanju zaposlenih uz precizna zaduženja i odgovornosti svih sudionika u procesu rada, naročito voditelja poslova: grupovođa, disponenata, organizatora rada, nadzornika, planera, voditelja službi i direktora. Sve se ovo treba ostvariti primjerenom organizacijom rada, ali i provedbom poslova zaštite na radu, što posebno uključuje analizu ozljeda na radu.

Podaci o nezgodama na radu u poduzeću „Luka Rijeka" d. d. obrađuju se na nekoliko razina primjene statistike.

[1] Dipl. ing. sig., rukovoditelj službe zaštite, Luka Rijeka d. d., Riva 1, Rijeka, Hrvatska. *E-mail:* znr@lukarijeka.hr
[2] Dipl. ing. sig., asistent, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* kristina.dundovic@veleri.hr
[3] Datum primitka rada: 13. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

A) razina predstavlja sređivanje raznih podataka o nezgodama u određene klase i utvrđivanje brojčanih odnosa u pojedinim klasama na temelju njihove učestalosti, npr. pokazivanje broja nezgoda po danima u tjednu, satima u tjednu, radnim jedinicama i sl.

B) razina predstavlja svođenje broja nezgoda na manji broj reprezentativnih vrijednosti, primjerice, izražavanje nezgoda u indeksima učestalosti i indeksima težine po radnim jedinicama i sl.

C) razina predstavlja ispitivanje i provjeravanje različitih hipoteza radi otkrivanja stupnja veze između različitih pojava, primjerice, provjeravanje postoji li i u kakvoj mjeri veza između učestalosti nezgoda i stupnja kvalificiranosti radnika, radnog iskustva itd.

U ovom radu autori obrađuju podatke o nezgodama pri radu na A razini. Cilj ovog rada je primjenom odgovarajuće statističke metode, prikazati analizu ozljeda na radu te na taj način ukazati na potrebu sustavnih istraživanja sa svrhom daljnjeg smanjenja ozljeda na radu u lučkim procesima. Postavljena je hipoteza: sustavna istraživanja ozljeda na radu vode značajnom smanjenju ozljeda. Detaljnom analizom pruža se stručnjacima zaštite na radu mogućnost da detektiraju uzrok i izvor ozljede te spriječe njezino ponavljanje.

Posebnu poteškoću u proučavanju nezgoda čini nemogućnost neposrednog prenošenja iskustva na sličnu situaciju. Naime, na prvi pogled minimalna razlika u uvjetima rada može biti veoma značajna u pogledu učestalosti nezgoda. Tako se u identičnim objektivnim prilikama rada dvije skupine radnika mogu značajno razlikovati po učestalosti nezgoda, što može nastati kao posljedica razlike u stavovima prema mjerama zaštite na radu ili zbog drugih subjektivnih razloga.

Ovaj rad temelji se na godišnjem izvješću o zaštiti na radu Luke Rijeka (Milojica, 2013) gdje je korištena Poissonova distribucija kao statistička metoda pri analizi ozljeda na radu. U pripremi ovoga rada izvedena su istraživanja koja se odnose za period od tri godine, tj. od 2011. do 2013. godine.

2. METODOLOGIJA ISTRAŽIVANJA

U ovom radu kao statistička metoda uzeta je Poissonova distribucija koja podrazumijeva raspodjelu rijetkih slučajnih događaja kod kojih je vjerojatnost pojavljivanja vrlo mala.

Ona izražava vjerojatnost broja događaja ako se oni pojavljuju u fiksnom vremenskom periodu s poznatom prosječnom brzinom pojavljivanja i vremenski su nezavisni od prošlog događaja.

Za razliku od normalne distribucije koja je potpuno definirana aritmetičkom sredinom i standardnom devijacijom, Poissonova distribucija je potpuno definirana aritmetičkom sredinom jer je njena varijanca jednaka aritmetičkoj sredini.

Kada je N (ukupan broj) vrlo velik, Poissonova distribucija se približava binomnoj, ali je razlika u tome što kod binomne raspodjele znamo koliko se puta neki događaj pojavio, ali i koliko se puta nije pojavio, a kod Poissonove raspodjele znamo samo koliko se puta neki događaj pojavio.

3. DISTRIBUCIJA BROJA OZLJEDA NA RADU U DIONIČKOM DRUŠTVU „LUKA RIJEKA“ ZA PERIOD OD 2004. DO 2013. GODINE

Iz tablice je vidljivo da se broj zaposlenih iz godine u godinu smanjivao i da je dolazilo do pada apsolutnog broja ozljeda . U promatranom razdoblju u *2013. godini dogodio se najmanji broj ozljeda na radu, tj. 8 % manje* nego u 2012. godini i *6 % manje* ozljeda na 1.000 zaposlenih u odnosu na 2012. godinu. Isto je zorno prikazano u grafikonu 1.

Tablica 1. Prikaz broja ozljeda na radu u poduzeću „Luka Rijeka” d. d. za period od 2004. do 2013. god.

god.	*broj zaposlenih (na dan 31. 12.)*	*broj ozljeda na radu*	*broj ozljeda na 1.000 zaposlenih*
2004.	1 079	91	84
2005.	994	69	69
2006.	968	63	65
2007.	956	63	65
2008.	958	59	62
2009.	934	50	54
2010.	872	38	44
2011.	768	32	42
2012.	724	25	35
2013.	704	23	33

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Grafikon 1. Kretanje broja ozljeda na radu u „Luka Rijeka“ d. d. za razdoblje od 10 godina

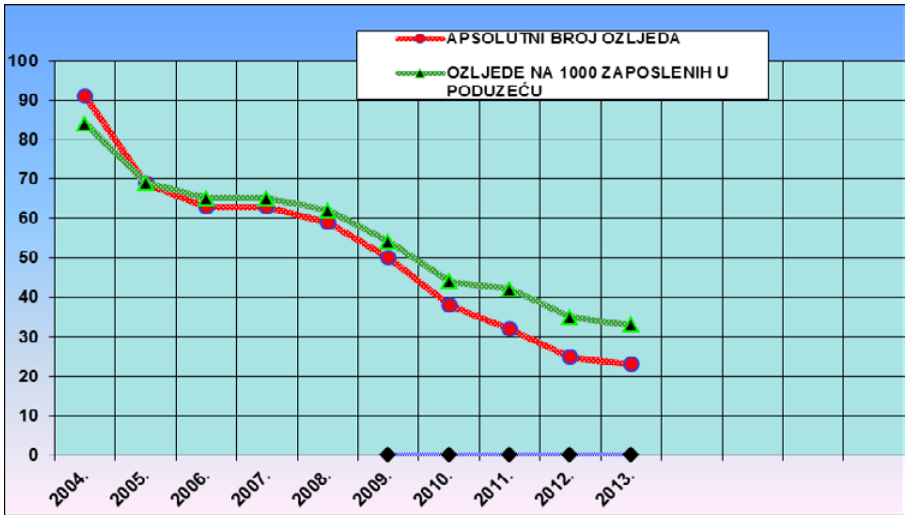

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

4. ISPITIVANJE PRIMJENJIVOSTI POISSONOVE RAZDIOBE

Obično se pretpostavlja da je razdioba broja ozljeda dobro opisana teorijskom Poissonovom razdiobom. U pripremi ovoga rada izvedena su proučavanja koja se odnose za period od tri godine, tj. od 2011. do 2013. godine.

4.1 Primjena c^2 testa

c^2 (hi–kvadrat) test isključivo se primjenjuje na podacima predstavljenim frekvencijama dobivenim brojenjem (f) ili teorijskim izračunavanjem (f_t) prema nekom modelu distribucije frekvencija (normalna, binomna, Poissonova, negativno binomna).

Vrijednost c^2 mjera je odstupanja stvarnih, opažanih frekvencija (f) od teorijskih očekivanih (f_t).

Provjereno je razlikuje li se broj stvarnih frekvencija (ozljeda) u Luci Rijeka statistički značajno od teorijskih očekivanih ozljeda. Provjeravalo se pomoću hi–kvadrat testa.

Vrijednost c^2 izračunava se izrazom:

$$\chi^2 = \frac{(f - f_t)^2}{f_t}$$

Vrijednost Poissonove razdiobe izračunava se izrazom:

$$P_{(X)} = \frac{m^x \cdot e^{-m}}{x!}$$

$\bar{x}$ gdje je : $m =$

$$m = \frac{\sum f \cdot x}{\sum f}$$

c^2 (hi–kvadrat) testom provjereno je razlikuje li se distribucija broja ozljeda na radu u trgovačkom društvu Luka Rijeka u posljednje tri godine značajno od frekvencije teorijske očekivane Poissonove distribucije ozljeda.

Vrijednosti stvarnih frekvencija prikazane su u tablici 2.

Tablica 2. Razdioba broja radnika (f) po broju ozljeda (x) u dioničkom društvu Luka Rijeka od 2011. do 2013. godine

godina	*broj radnika*		
	bez ozljeda	*s jednom ozljedom*	*s dvije ozljede*
2011.	738	28	2
2012.	700	23	1
2013.	683	19	2
å	2120	70	5
$\overline{x}$	707	23,3	1,67

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

4.2 Izračunavanje teorijskih frekvencija Poissonove razdiobe

Teorijska frekvencija f (0) izračunava se izrazom:

$\log f_t = (\log n - k \cdot \overline{x})$ gdje je:

$\overline{x}$ = prosječna vrijednost rijetkih slučajeva

k = konstanta koja iznosi 0,4343

n = ukupan broj (å f) slučajeva

$$m = \frac{\sum f \cdot x}{\sum f} = \frac{32}{768} = 0{,}0417$$

$\log f f_t = (\log 768 - 0{,}4343 \cdot 0{,}0417)$

$\log f f_t = (\log 768 - 0{,}0181)$

$\log f f_t = 2{,}8673$

$f f_t = 736{,}72$ (neozlijeđeni radnici)

Teorijske frekvencije svake sljedeće vrijednosti (x) od 1 na više dobivaju se izrazom:

$xf_t = \frac{(x-1) \cdot f_t \overline{x}}{x}$ gdje je:

$(x-1) \cdot f_t$ = teorijska frekvencija prethodne vrijednosti (x)

$$f_t = \frac{\phi f_t \bar{x}}{1} = \frac{736{,}72 \cdot 0{,}0417}{1} = 30{,}72 \text{ (radnici s jednom ozljedom)}$$

$$f_t = \frac{1 f_t \bar{x}}{2} = \frac{30{,}72 \cdot 0{,}0417}{2} = 0{,}64 \text{ (radnici s dvije ozljede)}$$

Uz poznatu vrijednost m (m = 0,0417) moguće je izračunati bilo koju vrijednost P(x) Poissonove distribucije za x = 0,1,2,3, ...

$$P_{(x)} = \frac{m^x \cdot e^{-m}}{x!}$$

$$P_{(0)} = \frac{0{,}0417^0 \cdot e^{-0{,}0417}}{0!} = 0{,}9592$$

$$P_{(1)} = \frac{0{,}0417^1 \cdot e^{-0{,}0417}}{1!} = 0{,}0399$$

$$P_{(2)} = \frac{0{,}0417^2 \cdot e^{-0{,}0417}}{2!} = 0{,}0008$$

ANALIZA PODATAKA ZA 2011. GODINU

Tablica 3. Prikaz razdiobe broja radnika (f) po broju ozljeda (x) u Luka Rijeka d. d. (teorijske frekvencije f_t, c^2 vrijedost, pripadne vjerojatnosti $P_{(x)}$)

broj ozljeda (x)	*f*	*f . x*	f_t	$P_{(x)}$	$f - f_t$	$(f - f_t)^2$	$\frac{(f - f_t)^2}{2}$
0	738	0	736,72	0,9592	1,28	1,638	0,82
1	28	28	30,72	0,0399	-2,72	7,398	3,70
2	2	4	0,64	0,0008	1,44	2,074	1,04
å	768	32	768	0,9999	0		5,56

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Na temelju izračunatog stupnja slobode 1 (ss = k - 2) gdje je:

k = broj kategorija (u ovom primjeru to je broj različitih ishoda (k = 3), pa za ovaj primjer broj stupnjeva slobode iznosi: ss = k - 2 = 3 - 2 =1)

Prema dostupnim podacima iz relevantne literature (Šrekl, 1997) očitane su granične c^2 vrijednosti. Za 1 % rizika pogreške u zaključivanju granična vrijednost iznosi 6,64, a za 5 % rizika vrijednost je 3,84. Izračunata vrijednost iznosi 5,56, dakle između tabličnih vrijednosti, pa se može tvrditi, uz rizik pogreške u zaključivanju manji od 5 % a nešto veći od 1 %, da ne postoji statistički značajna razlika između empirijskih i teorijskih frekvencija, te da se razdioba ozljeda pokorava zakonu Poissonove distribucije, što je vidljivo na grafikonu 2.

Grafikon 2. Teorijskih frekvencija (f_t) Poissonove razdiobe za m = 0,0417 i dobivenih frekvencija (f) ozljeda na radu za 2011. godinu

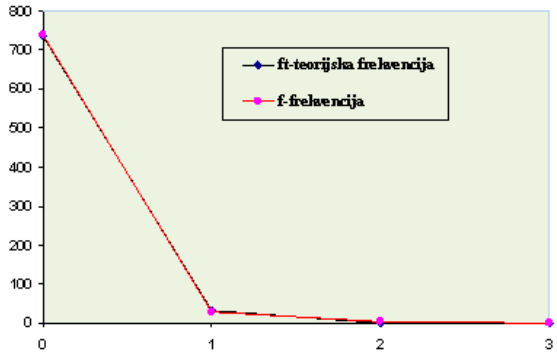

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

ANALIZA PODATAKA ZA 2012. GODINU

Tablica 4. Prikaz razdiobe broja radnika (f) po broju ozljeda (x) Luka Rijeka d. d. (teorijske frekvencije f_t, c^2 vrijedost, pripadne vjerojatnosti $P_{(x)}$) za 2012. godinu

broj ozljeda(x)	f	$f . x$	f_t	$P_{(x)}$	$f - f_t$	$(f - f_t)^2$	$\frac{(f - f_t)^2}{2}$
0	700	0	699,52	0,9660	0,480	0,230	0,0003
1	23	23	24,13	0,0333	-1,130	1,277	0,053
2	1	2	0,42	0,0006	0,650	0,422	1,006
å	724	25	724	0,9999	0		1,06

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

$c^2 = 1{,}06$

ss = 3 – 2 = 1 ⟶ iz tablice: za 1 % rizika 6,64

za 5 % rizika 3,84

Na temelju izračunatog stupnja slobode 1, prema dostupnim podacima iz relevantne literature (Šrekl, 1997) očitane su granične c^2 vrijednost. Za 1 % rizika pogreške u zaključivanju, granična vrijednost iznosi 6,64, a za 5 % rizika vrijednost je 3,84. Izračunata vrijednost iznosi 1,06, dakle manja $c^2 < c^2_g$ pa se može tvrditi da nema statistički značajnijih razlika između dobivenih i teoretski očekivanih frekvencija.

ANALIZA PODATAKA ZA 2013. GODINU

Tablica 5. Prikaz razdiobe broja radnika (f) po broju ozljeda (x) u Luka Rijeka d. d. (teorijske frekvencije f_t, c^2 vrijedost, pripadne vjerojatnosti $P_{(x)}$) za 2013. godinu

broj ozljeda (x)	f	$f \cdot x$	f_t	$P_{(x)}$	$f - f_t$	$(f - f_t)^2$	$\frac{(f - f_t)^2}{2}$
0	683	0	681,35	0,9679	1,650	2,72	0,004
1	19	19	22,21	0,0316	-3,210	10,30	0,464
2	2	2	0,36	0,0005	1,560	2,43	6,75
å	704	23	704	1,0	0		7,22

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

$c^2 = 7{,}22$

ss = 3 – 2 = 1 ⟶ iz tablice: za 1 % rizika 6,64

za 5 % rizika 3,84

Prema dostupnim podacima iz relevantne literature (Šrekl, 1997) očitane su granične c^2 vrijednosti. Za 1 % rizika pogreške u zaključivanju, iznosi 6,64, a za 5 % rizika je vrijednost 3,84. Izračunata vrijednost iznosi 7,22, dakle veća je od tabličnih vrijednosti, pa se može tvrditi da postoji statistički značajnija razlika između empirijskih i teoretski očekivanih frekvencija.

ANALIZA PODATAKA ZA RAZDOBLJE OD 2011. DO 2013. GODINE

Tablica 6.. Prikaz razdiobe broja radnika (f) po broju ozljeda (x) u Luka Rijeka d. d. (teorijske frekvencije f_t, c^2 vrijedost, pripadne vjerojatnosti $P_{(x)}$) za razdoblje od 2011. do 2013. godine

broj ozljeda (x)	*f*	*f . x*	f_t	$P_{(x)}$	$f - f_t$	$(f - f_t)^2$	$\frac{(f - f_t)^2}{2}$
0	707	0	706,15	0,9646	0,85	0,72	0,001
1	23,33	23,33	25,42	0,0347	-2,09	4,37	0,17
2	1,67	3,40	0,457	0,0006	1,24	1,54	3,42
å	732	26,6	732	0,9999	0		3,59

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

$c^2 = 3,59$

ss = 3 – 2 = 1 → iz tablice: za 1 % rizika 6,64

za 5 % rizika 3,84

Grafikon 3. Teorijske frekvencije (f_t) Poissonove razdiobe za m= 0,036 i dobivenih frekvencija (f) ozljeda na radu za razdoblje od 2011. do 2013. godine

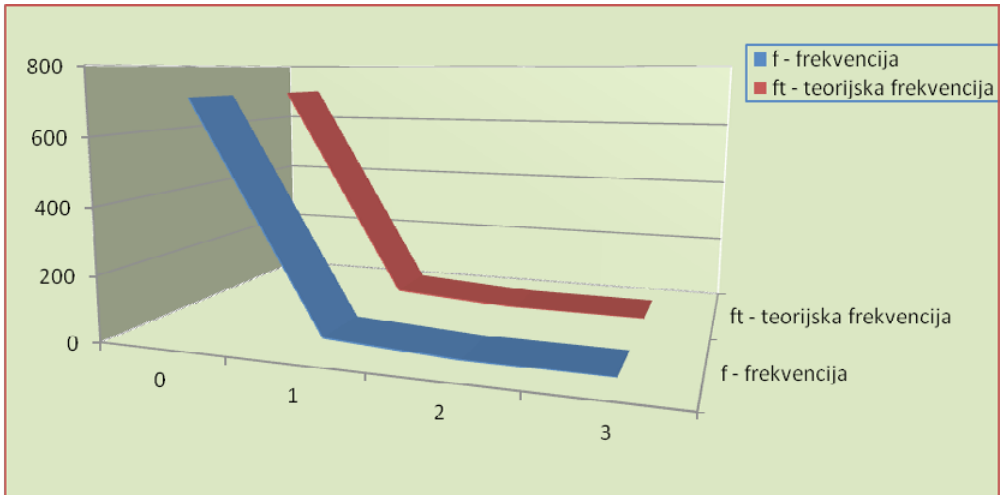

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Zbroj relativnih kvadratičnih odstupanja frekvencija u posljednjem stupcu tablice 6 daje vrijednost $c^2 = 3,59$, dok granična vrijednost varijable c^2 distribuirane po Poissonovoj razdiobi na razini značajnosti 0,05 za 1 stupanj slobode iznosi 3,84, a na razni značajnosti 0,01 je 6,64. Budući da je $c^2 < c^2_g$ zaključuje se da nema značajnijih razlika između empirijskih i teorijskih frekvencija, te se razdioba broja ozljeda pokorava zakonu Poissonove razdiobe.

5. RASPODJELA OZLJEDA NA RADU

Tablica 7. Ozljede na radu po satima rada unutar jedne smjene u 2013. god. u poduzeću „Luka Rijeka“ d. d.

smjena	*sati rada*				*dolazak /odlazak/*
	0 - 2	*2 - 4*	*4 - 6*	*6 - 8*	
I.	2	7	4	4	
II.	3	2	0	0	1/0/
III.	0	0	0	0	
å	5	9	4	4	1

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Grafikon 4. Učestalost ozljeda po satima rada za 2013. godinu

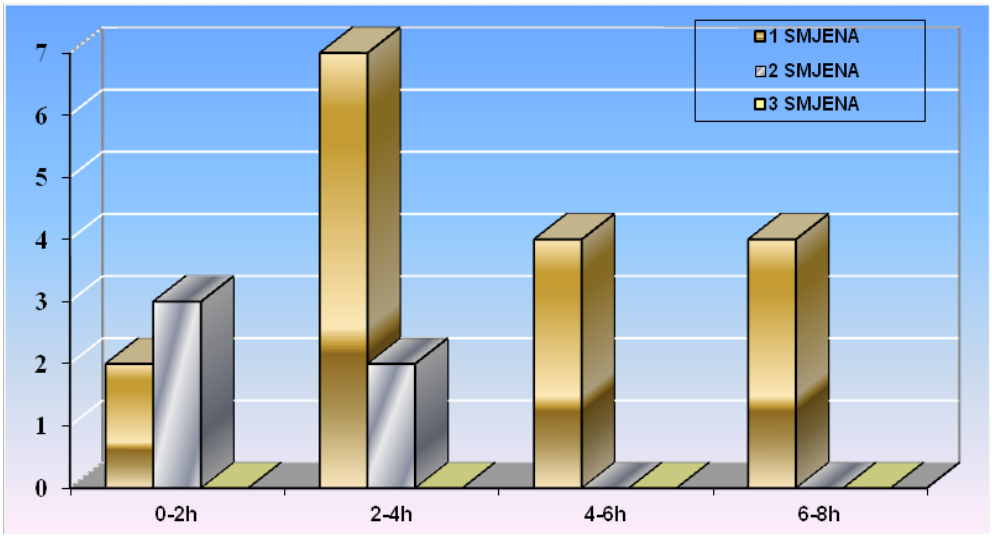

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Iz tablice 7 vidljivo je da se, sveukupno gledajući, u 2013. godini ozljede nisu ravnomjerno događale od 0 do 8 sati rada.

Iz grafikona 4 vidi se da se najveći broj ozljeda na radu dogodio u prvoj smjeni između 2 i 4 sata rada, a u drugoj smjeni između 0 i 2 sata rada.

U trećoj radnoj smjeni nije bilo ozljeda na radu.

Opažene frekvencije učestalosti ozljeda (navedene u tablici 7) uspoređene su s teorijskim frekvencijama koje su određene u skladu sa statističkom hipotezom, da su ozljede na radu podjednako raspoređene po satima rada. Za utvrđivanje razlika i značajnosti razlika primijenjen je c^2 test.

Tablica 8. Učestalost ozljeda na radu po satima rada u I. smjeni za 2013. godinu

frekvencija učestalosti ozljeda (f)	f_t	$f-f_t$	$(f-f_t)^2$	$(f-f_t)^2/f_t$
2	4,25	-2,25	5,06	1,19
7	4,25	2,75	7,56	1,78
4	4,25	-0,25	0,06	0,01
4	4,25	-0,25	0,06	0,01
17	17	0		c^2=2,99

Izvor: obrada autora

Uz broj stupnjeva slobode SS = k - 1 = 3 prema dostupnim podacima iz relevantne literature (Šrekl, 1997) očitane su granične vrijednosti c^2. Nalazimo vrijednost 7,82 za 5 % rizika i vrijednost 11,34, za 1 % rizika pogreške u zaključivanju. Izračunata vrijednost iznosi 2,99, dakle manja je od tabličnih vrijednosti, pa se može utvrditi da ne postoji statistički značajna razlika između distribucije broja ozljeda na radu u I. smjeni rada i teorijskih očekivanih frekvencija.

Tablica 9. Učestalost ozljeda na radu po satima rada u II. smjeni za 2013. godinu

frekvencija učestalosti ozljeda (f)	f_t	$f-f_t$	$(f-f_t)^2$	$(f-f_t)^2/f_t$
3	1,25	1,75	3,06	2,45
2	1,25	0,75	0,56	0,45
0	1,25	-1,25	1,56	1,25
0	1,25	-1,25	1,56	1,25
5	5	0		c^2 = 5,40

Izvor: obrada autora prema podacima dobivenim iz Izvješća
Službe zaštite na radu Luke Rijeka za 2013. godinu

Prema dostupnim podacima iz relevantne literature (Šrekl, 1997) broj stupnjeva slobode je k = 3, a granična vrijednost c^2 na razini značajnosti od 0,05 iznosi 7,82 i vrijednost 11,34 za 0,01. Izračunata vrijednost iznosi 5,40, dakle manja je od tabličnih vrijednosti, pa se može tvrditi da ne postoji statistički značajna razlika između distribucije broja ozljeda na radu koje su se dogodile u II. smjeni rada i teorijskih frekvencija.

Tablica 10. Učestalost ozljeda na radu po satima rada ukupno za I. i II. smjenu u 2013. godini.

frekvencija učestalosti ozljeda (f)	f_t	$f-f_t$	$(f-f_t)^2$	$(f-f_t)^2/f_t$
5	5,50	-0,50	0,25	0,05
9	5,50	3,50	12,25	2,23
4	5,50	-1,50	2,25	0,41
4	5,50	-1,50	2,25	0,41
22	22	0		$c^2 = 3,10$

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Postavlja se H_0 (nul - hipoteza) i tvrdi da je učestalost ozljeda na radu po satima rada u ove dvije smjene podjednako raspoređena.

Izračunata c^2 vrijednost je 3,10, broj stupnjeva slobode k = 3, kod očitanja iz tablice prema dostupnim podacima iz relevantne literature (Šrekl, 1997) dobiju se vrijednosti za 0,01 (11,34), a za 0,05 (7,82). Prema ovome može se zadržati postavljena H_0 –hipoteza i tvrditi da opažana razlika učestalosti ozljeda na radu po satima rada, promatrajući dvije smjene, statistički nije značajna.

6. UČESTALOST OZLJEDA NA RADU PO DANIMA U TJEDNU

Prilikom prikaza učestalosti ozljeda na radu po danima u tjednu broj prisutnih radnika izveden je tako da se uzelo u obzir otprilike 10 % odsutnih radnika zbog slobodnih dana, godišnjih odmora te bolovanja u radnim danima.

Isto tako, zbog djelatnosti koju Luka Rijeka obavlja, uzelo se u obzir otprilike 20 % prisutnih radnika tijekom vikenda.

Tablica 11. Ozljede na radu po danima u tjednu za razdoblje od 2004. do 2013. godine u poduzeću „Luka Rijeka" d. d.

GODINA	*PON*	*UTO*	*SRI*	*ČET*	*PET*	*SUB*	*NED*
2004.	24	16	13	13	14	5	6
2005.	18	9	14	11	12	4	1
2006.	17	8	11	13	10	3	1
2007.	16	10	10	7	9	4	7
2008.	18	9	13	7	8	1	2
2009.	9	11	11	9	6	2	2
2010.	5	11	8	4	8	0	2
2011.	8	9	6	4	5	0	0
2012.	5	6	2	5	5	1	1
2013.	4	6	4	3	5	1	0
UKUPNO	124	95	92	76	82	21	22

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Grafikon 5. Učestalost ozljeda po danima u tjednu za 2013. god. u Luka Rijeka d. d.

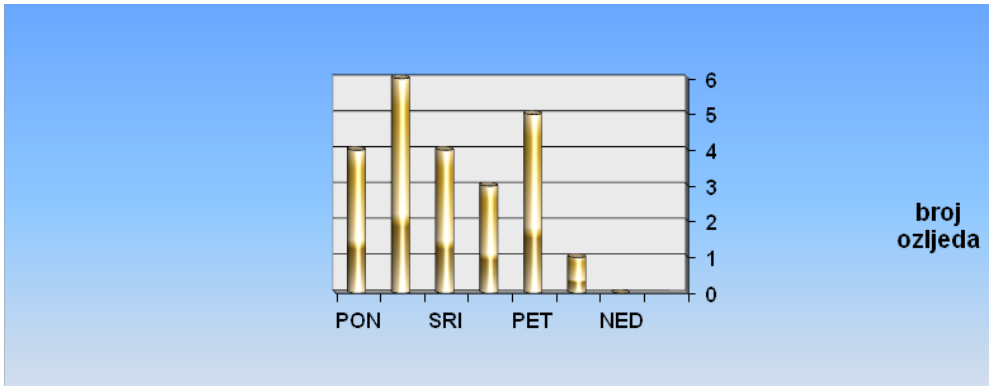

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Iz tablice 11 vidljivo je da se najveći ukupni broj ozljeda u promatranom razdoblju dogodio ponedjeljkom. Posljednjih 5 godina promatranog razdoblja najveći broj ozljeda događa se utorkom.

Iz grafikona 5 vidi se da se najveći broj ozljeda u 2013. godini, odnosno 48 % od ukupnog broja ozljeda, dogodio utorkom i petkom.

Tablica 12. Učestalost ozljeda po danima u tjednu za 2013. godinu

frekvencija učestalosti ozljeda (f)	f_t	$f-f_t$	$(f-f_t)^2$	$(f-f_t)^2/f_t$
4	3,286	0,71	0,50	0,15
6	3,286	2,71	7,34	2,23
4	3,286	0,71	0,50	0,15
3	3,286	-0,286	0,08	0,02
5	3,286	1,71	2,92	0,89
1	3,286	-2,29	5,24	1,59
0	3,286	-3,286	10,79	3,29
23	23	0		$c^2 = 8,23$

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Uz broj stupnjeva slobode k = 6, granična vrijednost c^2 na razini značajnosti od 0,05 iznosi 12,59 i vrijednost 16,81, za 0,01. Izračunata vrijednost iznosi 8,23, dakle manja je od tabličnih vrijednosti, pa se može tvrditi da ne postoji statistički značajna razlika između distribucije broja ozljeda na radu, koje su se dogodile po danima u tjednu, i teorijskih frekvencija.

7. PRIKAZ BROJA OZLJEDA PO MJESECIMA

Zbog djelatnosti koju Luka Rijeka obavlja, a to je prekrcaj brodova koji uplovljavaju u luku, prisutan je stalni kontinuitet obavljanja poslova, a to znači da je prisutan podjednak broj radnika po mjesecima, s obzirom na to da su isključeni kolektivni godišnji odmori.

Granična vrijednost c^2 na razini značajnosti od 0,05 , kao i ona na razini od 0,01 veća je od izračunate vrijednosti koja je 5,84. Budući da $c^2 < c^2_g$ zaključuje se da nema statističkih značajnijih razlika između broja ozljeda na radu koje su se dogodile po mjesecima i teorijskih frekvencija, te se razdioba broja ozljeda pokorava zakonu Poissonove razdiobe. Prema tome, odbacuje se nul-hipoteza i tvrdi da opažena razlika učestalosti ozljeda po mjesecima u ovom slučaju nije statistički značajna.

Tablica 13. Prikaz ozljeda na radu po mjesecima za razdoblje od 2004. do 2013. god. u poduzeću Luka Rijeka d. d.

Godina	Mjesec												*prosjek*
	I.	II.	III.	IV.	V.	VI.	VII.	VIII.	IX.	X.	XI.	XII.	
2004.	10	8	9	10	9	4	6	9	5	11	7	3	7,7
2005.	4	6	3	5	7	10	5	7	5	5	8	4	5,7
2006.	8	4	8	7	3	2	7	2	6	7	5	4	5,3
2007.	6	5	9	7	2	5	12	6	4	4	1	2	5,3
2008.	9	2	3	2	3	9	4	6	7	5	4	4	4,8
2009.	4	7	3	4	7	4	3	5	2	4	4	3	4,1
2010.	3	4	5	2	3	4	1	2	2	1	7	4	3,2
2011.	2	6	4	4	2	4	2	3	2	3	0	0	2,7
2012.	0	3	1	2	2	2	3	2	2	1	5	2	2,1
2013.	3	1	1	2	1	1	4	3	1	3	2	1	1,9

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Grafikon 6. Prikaz ozljeda na radu po mjesecima za 2013. god. u poduzeću Luka Rijeka d. d.

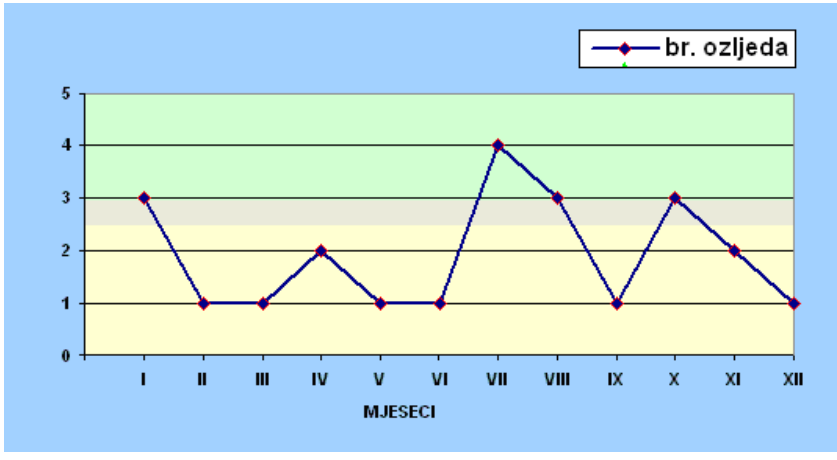

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

Tablica 14. Učestalost ozljeda po mjesecima za 2013. godinu

frekvencija učestalosti ozljeda (f)	f_t	$f - f_t$	$(f - f_t)^2$	$(f - f_t)^2 / f_t$
3	1,92	1,08	1,17	0,61
1	1,92	-0,92	0,85	0,44
1	1,92	-0,92	0,85	0,44
2	1,92	0,08	0,006	0,003
1	1,92	-0,92	0,85	0,44
1	1,92	-0,92	0,85	0,44
4	1,92	2,08	4,33	2,25
3	1,92	1,08	1,17	0,61
1	1,92	-0,92	0,85	0,44
3	1,92	1,08	1,17	0,61
2	1,92	0,08	0,006	0,003
1	1,92	-0,92	0,85	0,44
23	23	0		c^2=5,84

Izvor: obrada autora prema podacima dobivenim iz Izvješća Službe zaštite na radu Luke Rijeka za 2013. godinu

8. ZAKLJUČAK

Istraživanje primjenjivosti Poissonove razdiobe na empirijsku razdiobu broja ozljeda izvedeno je za sve radnike Luke Rijeka u razdoblju od 2011. do 2013. godine. Za svaku godinu provjereno je razlikuje li se statistički značajnije broj stvarnih frekvencija (ozljeda) od teorijski očekivanih ozljeda. Provjeravalo se pomoću c^2 (hi–kvadrat) testa. Ozljede na radu pripadaju rijetkim događajima i za njih se može reći da se raspodjeljuju u obliku tzv. Poissonove distribucije. Poissonova distribucija, slično kao i normalna distribucija, teorijski je model raspodjele nekih obilježja ili događaja. Normalna distribucija je, međutim, simetrična i odnosi se na obilježja koja su isto tako raspodijeljena u populaciji. Poissonova razdioba je uglavnom asimetrična, što je uzrokovano nejednakom vjerojatnošću ostvarivanja nekog događaja, kao što su ozljede na radu. Naime, najvećem broju radnika dogodit će se, u određenom periodu na radu, samo jedna ozljeda, puno manjem broju radnika u istom će se razdoblju rada dogoditi dvije, tri ili više ozljeda. Ozljede u Luci Rijeka mogle bi se distribuirati po Poissonovoj krivulji kada na njih ne bi djelovali nikakvi vanjski ili unutarnji čimbenici, a njih je teško izbjeći. Pod ovim čimbenicima podrazumijeva se organizacija rada pri izvođenju radnog procesa, uređenje mjesta rada, tj. uvjeti rada koji su za luku karakteristični, s obzirom na to da se radi o aktivnostima rada na otvorenom prostoru, zatim osposobljenost radnika za rad na siguran način, ispunjavanje zahtjeva za rad na poslovima s posebnim uvjetima rada u pogledu općih zdravstvenih, psihičkih i psihofizioloških sposobnosti i sl. Radi toga se Poissonova

distribucija može primijeniti pri analizi rijetkih događaja kao što su ozljede na radu. Ovi čimbenici su ujedno i ograničenja, odnosno problemi na koje smo naišli prilikom istraživanja. Oni se ne mogu u potpunosti otkloniti, ali se može posvetiti posebna pozornost na njih kako bi se smanjio njihov negativan učinak. Primjenom statističke metode, prilikom analize ozljeda na radu dobili smo smjernice za sustavno istraživanje ozljeda kako bi se „rijedak događaj" (kako se u praksi definira ozljeda na radu) u potpunosti pokušao eliminirati. Koristeći Poissonovu distribuciju najbolje smo se približili analizi ozljeda s obzirom na to da je ozljeda na radu događaj koji se u praksi rijetko događa, a upravo Poissonova distribucija služi za raspodjelu vrlo rijetkih događaja, kod kojih je vjerojatnost pojavljivanja vrlo mala. S obzirom na sve navedeno smatramo kako analiza ozljeda na radu primjenom Poissonove distribucije može biti temelj, odnosno smjernica za buduća sustavna istraživanja ozljeda na radu po kojoj bi se trebali voditi stručnjaci zaštite na radu kako bi postigli svoj glavni cilj - sigurnost je na prvom mjestu.

LITERATURA

Milojica, M. (2013) *Izvješće o zaštiti na radu, zaštiti od požara i zaštiti okoliša za 2013. godinu,* Rijeka: Služba zaštite na radu Luka Rijeka d. d.

Šošić, I., Serdar, V. (1997) *Uvod u statistiku,* Zagreb: Školska knjiga

Šrekl, J. (1997) *Izbrana poglavlja iz matematike*, Ljubljana: FKKT, Odd za tehniško varnost

Pravilnik o evidenciji, ispravama, izvještajima i knjizi nadzora s područja zaštite na radu (N.N. br. 52/84).

Milorad Milojica [1]
Kristina Dundović [2]

Professional paper
UDC UDK 331.462:627.09(497.5 Rijeka)

APPLICATION OF THE POISSON DISTRIBUTION IN THE STATISTICAL ANALYSIS OF OCCUPATIONAL INJURIES IN THE COMPANY "LUKA RIJEKA"("THE PORT OF RIJEKA")[3]

ABSTRACT

Improving safety at work can be considered as the general objective of statistical analysis of accidents at work. Within this general objective, specific goals can be singled out such as obtaining valid and reliable information on the basis of which company's management can put in place an efficient policy of improving the safety management system. The likelihood that an injury will occur in a given time interval is equal to the number of injured workers and the total number of workers in the observed group. Experience generally shows that the probability of injury in the period of one year is much less than one, therefore work related injuries can be considered as "a rare event". As work related injuries can occur again considering the fact that one worker can suffer one, two, three or more identical or different injuries, the distribution of the number of injuries (frequency) can be observed per workers. It is usually assumed that the distribution of the number of injuries is well described by the Poisson distribution. Studies carried out in the preparation of this work, were based on the annual Report on Safety at Work of the Safety at Work Department in Luka Rijeka ("The Port of Rijeka") where the Poisson distribution was used as a statistical method in analyzing occupational injuries. The objective of this work is to highlight the need for systematic research with the aim of further reducing work related injuries in the port processes. By applying the statistical method in the analysis of work related injuries we received guidelines for the systematic study of injuries so that the "rare event" (definition of injury in practice) could be completely eliminated.

Key words: *safety at work, statistical analysis, occupational injury, incidence of injuries, the Poisson distribution*

[1] Graduate Engineer in Occupational Safety, Head of Safety at Work Department in "Luka Rijeka" ("The Port of Rijeka"), Riva 1, Rijeka, Croatia. E-mail: znr@lukarijeka.hr

[2] Graduate Engineer in Occupational Safety, Assistant, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: kristina.dundovic@veleri.hr

[3] Received: 13. 2. 2014.; accepted: 5. 5. 2014.

Tatjana Gregorović [1]
Dario Bognolo [2]
Marko Kršulja [3]

Stručni rad
UDK 622.647.2

PRORAČUN I ODABIR PARAMETARA TRANSPORTNE TRAKE[4]

SAŽETAK

U ovome radu prikazan je proračun transportne trake za kontinuirani prekrcaj robe. Odabran je materijal ugljena prašina, te duljina transportne trake od 300 metara uz promjenu visine od 10°. Zadan je učin od 150 tona satnog kapaciteta, proračunati svi potrebni funkcionalni dijelovi prema standardima te konačan rezultirajući učin. Prikazan je postupak odabira brzine transportne trake, širine trake, proračun pogonske snage, odabir dimenzija pogonskog bubnja i nosivih valjaka. Korišten je standardni model proračuna. Sile koje se javljaju u procesu su proračunate te je korištena metoda kontrole proračuna obilaskom po konturi.
Ključne riječi: *transportna traka, ugljena prašina, nosač valjaka, prekrcaj*

1. UVOD

Transportne trake svrstavaju se u kontinuirana transportna sredstva. Koriste se za prijenos komadne ili sipke robe (> 10.000 t/h) na različite udaljenosti (do 200 km). Mogu transportirati materijal horizontalno ili pod određenim kutom. Na grafikonu 1 prikazana je shema transportne trake sa svim pripadajućim dijelovima.

U ovome radu prikazat će se proračun transportne trake za ugljenu prašinu, postupak proračuna osnovnih parametara transportne trake, poput brzine, sile koje djeluju na valjcima i pogonskom bubnju, potrebna snaga za pokretanje transportne trake. Kontrola proračuna izvest će se metodom obilaska po konturi. Traka se proračunava prema standardima koji zadovoljavaju potrebe iskrcaja brodova koji prevoze rasuti sipki teret za termoelektrane na ugljen.

[1] Studentica, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska.
[2] Dipl. ing. strojarstva, predavač, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* dbognolo@veleri.hr
[3] Dr. sc., dipl. ing. strojarstva, asistent, Veleučilište u Rijeci, Vukovarska 58, Rijeka, Hrvatska. *E-mail:* krsulja.marko@veleri.hr
[4] Datum primitka rada: 22. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

Grafikon 1. Shematski prikaz transportne trake

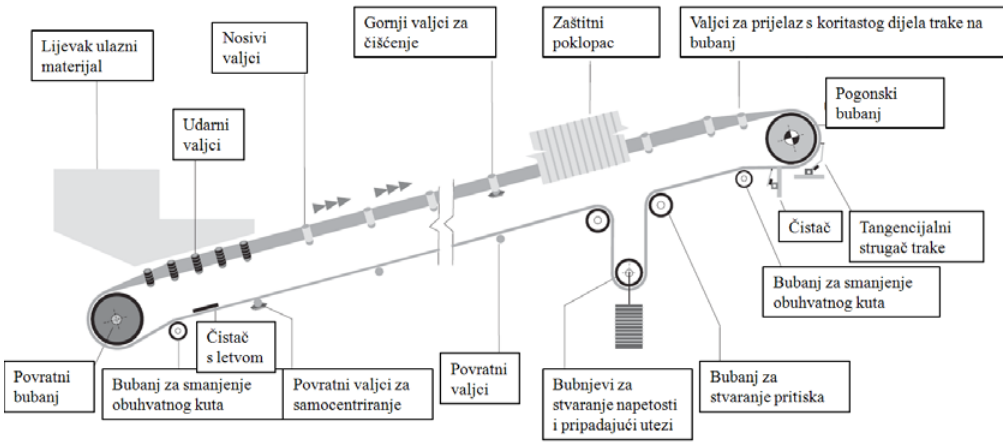

Izvor: Rulmeca (2003)

2. PARAMETRI POTREBNI ZA KONSTRUKCIJU TRANSPORTNE TRAKE

Cilj ovoga istraživanja je proračunati i analizirati međusobni utjecaj parametara koji utječu na odabir i dizajn transportne trake. Početni parametri iz kojih se izračunava cjelokupna transportna traka jesu: transportna dužina L = 300 m, prosječni nagib trase β = 10 %, satni kapacitet prekrcane robe (učin) Q = 150 t/h te odabrani transportirani materijal ugljena prašina.

Dizajn transportne trake počinje s evaluacijom karakteristika materijala koji se transportira. Presjek prenošenog materijala računa se prema sljedećem izrazu:

$$A = \frac{1}{k_1 \cdot k_2} \cdot \frac{Q}{3600 \cdot \rho \cdot v} = 0{,}0139A = \frac{1}{k_1 \cdot k_2} \cdot \frac{Q}{3600 \cdot \rho \cdot v} = 0{,}0139 \text{ (m}^2\text{)}, \quad (1)$$

gdje je:

- ρ = 0,4 - 2,4 t/m^3 - ugljena prašina - odabrana srednja vrijednost 1,4 t/m^3 (Korman, 2014),
k_1 = 0,9 - koeficijent smanjenja teoretskog kapaciteta zbog neravnomjernog nasipavanja,
k_2 = 0,95 - koeficijent smanjenja teoretskog kapaciteta zbog nagiba transportera (Gregorović, 2014:3), v = 1,70 - 3,35 m/s => odabrana srednja vrijednost 2,5 m/s - brzina gibanja trake (Mavrin, 1999).

Na grafikonu 2 prikazan je shematski presjek transportne trake odabrane u istraživanju za prijenos ugljene prašine. Prema slici, b je stvarna širina transportne trake, b_1 aktivna širina trake, a l_1 označava potrebnu širinu nosivog valjka.

Grafikon 2. Presjek odabrane transportne trake

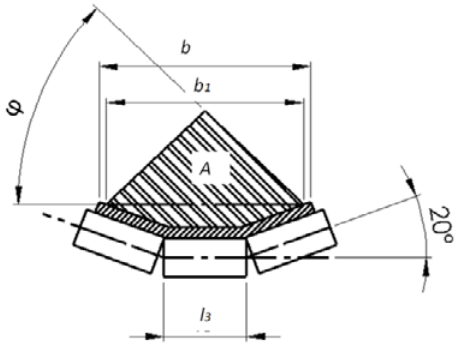

Izvor: obrada autora

Aktivna širina trake:

$$b_1 = \sqrt{\frac{A \cdot 3600}{f}} = 0{,}327 b_1 = \sqrt{\frac{A \cdot 3600}{f}} = 0{,}327 \text{ (m)}, \tag{2}$$

gdje je f = 465 - faktor oblika trake, tj. presjeka materijala odabran je koritasti oblik, λ = 20° (Gregorović, 2014:5).

2.1 Snaga za pogon transportera

Snaga se izračunava prema izrazu:

$$P_{bo} = F_{bo} \cdot v P_{bo} = F_{bo} \cdot v \text{ (W)}, \tag{3}$$

gdje je: $P_{bo} P_{bo}$ - snaga na osovini pogonskog bubnja (W), $F_{bo} F_{bo}$ - vučna sila na obodu pogonskog bubnja (N). Vučna sila se izračunava prema:

$$F_{bo} = g\left[c \cdot f \cdot L \cdot \left(G_t + \frac{Q}{3{,}6 \cdot v}\right) \pm \frac{Q \cdot H}{3{,}6 \cdot v}\right] F_{bo} = g\left[c \cdot f \cdot L \cdot \left(G_t + \frac{Q}{3{,}6 \cdot v}\right) \pm \frac{Q \cdot H}{3{,}6 \cdot v}\right] \text{ (N)}, \tag{4}$$

gdje je:

- c = 1,29 - faktor povećanja vučne sile koji uzima u obzir sporedne otpore u pogonu transportera, odabire se prema ukupnoj dužini L transportera. Zadana je dužina L = 300 metara te prema Korman (2014), slijedi L = 320 => c = 1,29. Koeficijent trenja u ležajevima bubnjeva i valjaka, odabrano za ugljenu prašinu prema f = 0,023 (Rulmeca, 2003). G_t - masa pokretnih dijelova transportera (trake, valjaka) po jednom metru dužine transportera (kg/m), te se izračunava prema sljedećem izrazu:

$$G_t = 2 \cdot q_t + g_v^{'} + g_v^{''}\ G_t = 2 \cdot q_t + g_v^{'} + g_v^{''} \text{ (kg/m)}, \quad (5)$$

gdje je:

- $q_t q_t$ - masa trake (kg/m), $g_v^{'} g_v^{'}$ - masa rotirajućih dijelova nosećih valjaka po jednome metru dužine transportera (kg/m), $g_v^{''}\ g_v^{''}$ - masa rotirajućih dijelova povratnih valjaka po jednome metru dužine transportera (kg/m).

Masa trake $q_t\ q_t$ izračunava se prema sljedećem izrazu:

$$q_t = b \cdot (q_u + q_0) q_t = b \cdot (q_u + q_0) \text{ (kg/m)}, \quad (6)$$

gdje je:

- $q_u q_u$ - masa svih uložaka u traci (kg/m^2), $q_0 q_0$ - masa gumene obloge trake (kg/m^2).

2.2 Vrsta tkanine za transportnu traku

Radi potrebe zadatka odabrano platno za koje je pretpostavljeno da će dati dobre rezultate pri transportu odabrane mase. Oznaka platna je RP 250 (R - Rayon, PA - Polyamid) širine *b* = 400 mm iz tablice 1 i 2. Upotrijebljeno je pet platna koja će se spojiti u zajedničku traku (Korman, 2014).

Tablica 1. Prekidna čvrstoća platna

Vrsta platna	Prekidna čvrstoća (N/m)		Težina platna (gr/m^2)	Debljina platna (gr/m^2)
	Uzdužno	Poprečno		
RP - 250	245175	78456	1800	2,3

Izvor: Korman (2014)

Tablica 2. Ukupna debljina uložaka (mm)

Vrsta platna	Broj uložaka						
	2	3	4	5	6	7	8
RP - 250	4,60	6,90	9,20	11,50	13,80	16,10	18,40

Izvor: Korman (2014)

Iz odabranog slijedi da je masa svih uložaka za odabranu traku jednaka $q_u = 1800 \cdot 5 = 9000$ $q_u = 1800 \cdot 5 = 9000$ gr/m^2 = 9 kg/m^2.

Odabrana je kvaliteta obloge M za transportnu traku prema tablici 3, za ugljenu prašinu potrebno je imati traku otpornu prema većim naprezanjima i velikom habanju. Za odabrani M 4/2 (4 mm debljina gornjeg sloja gume i 2 mm debljina donjeg sloja gume) = 6 mm debljine, masa gumene obloge trake je $q_0 q_0$ = 6,72 kg/m^2. Masa trake $q_t\ q_t$:

$$q_t = b \cdot (q_u + q_0) = 0{,}4 \cdot (9 + 6{,}72) = 6{,}288$$
$$q_t = b \cdot (q_u + q_0) = 0{,}4 \cdot (9 + 6{,}72) = 6{,}288\,(\text{kg/m}).$$

Tablica 3. Masa gumenih obloga (kg/m^2)

Debljina obloge (mm)	Kvaliteta gumene obloge				
	M	N	VM	NZ	G
4/2 = 6	6,72	6,78	7,98	7,74	8,34

Izvor: Korman (2014)

Promjer nosivog valjaka odabran je iz tablice 4, uzimajući u obzir kako odabran v = 2,5 m/s i b = 400 mm slijedi da je odgovarajući promjer nosivog valjaka Ø jednak 65 milimetara.

Tablica 4. Promjer nosivi valjaka u ovisnosti o širini trake i brzini trake

v (m/s)	Širina trake b (mm)									
	300	400	500	650	800	1000	1200	1400	1600	1800
2,09	51	65	90	108	108	100	108	108	133	133
2,62	65	65	90	108	108	108	108	108	133	159

Izvor: Korman (2014)

2.3 Noseći valjci

Izraz pomoću kojega se izračunava masa rotirajućih dijelova valjaka po jednome metru dužine transportera je:

$$g'_v = \frac{q'_v \cdot n'}{L} g'_v = \frac{q'_v \cdot n'}{L} (\text{kg/m}), \qquad (7)$$

gdje je: $q'_v q'_v$ - masa rotirajućih dijelova nosećih valjaka u jednome slogu, prema tablici 5 za promjer nosivog valjka od 65 milimetara, širinu trake od b = 400 milimetara i trodijelne valjke slijedi $q'_v\ q'_v$ = 4,6 kg, n' - broj nosivih slogova, L - ukupna duljina transportera.

Tablica 5. Približne mase nosećih i povratnih valjaka u kilogramima

Promjer nosećih valjaka (mm)	Tip nosećih valjaka	Širina trake b (mm)									
		300	400	500	650	800	1000	1200	1400	1600	1800
63	Vodoravan Dvodijelni Trodijelni	2,2 3,0 3,8	2,6 3,4 4,6	3,0 3,8 4,6	3,7 4,5 5,9	4,4 5,2 6,0	5,4 6,2 7,0				

Izvor: Korman (2014)

Broj nosećih slogova valjaka računa se prema:

$$n' = \frac{L-l_v}{l'} + \frac{l_v}{l_1'} = \frac{300-8}{1,5} + \frac{8}{0,75} = 401,2 n' = \frac{L-l_v}{l'} + \frac{l_v}{l_1'} = \frac{300-8}{1,5} + \frac{8}{0,75} = 401,2$$

=> 402 komada, (8)

gdje je: $l_v l_v$ = 8 m - dužina utovarnog dijela transportera, $l'l'$ => zbog nasipne gustoće od 1,4 t/m^3 i širine trake od *b* = 400 mm prema tablici 6 slijedi $l'l'$ = 1,5 m, l_1' - slijedi da je 0,5 ·*l'* = 0,5·1,5 = 0,75 metara udaljenost slogova na utovarnome mjestu.

Tablica 6. Razmak slogova nosećih valjaka *l'*

Širina valjaka	< 1,2 (t/m^3)	1,2 - 2,0 (t/m^3)	> 2,0 (t/m^3)
300, 400, 500, 650	1,65	1,50	1,40
800	1,50	1,35	1,25
1000	1,35	1,20	1,10
1200, 1400, 1600, 1800	1,20	1,00	0,80
2000, 2200	1,00	0,80	0,70

Izvor: Rulmeca (2003)

Slijedi da je masa rotirajućih dijelova nosećih valjaka prema izrazu (7) $g_v' = g_v' =$ 6,164 kg/m. Masu povratnih valjaka može se dobiti prema:

$$g_v'' = \frac{q_v''}{l''} g_v'' = \frac{q_v''}{l''} \text{ (kg/m)}, \quad (9)$$

gdje je: $g_v'' g_v''$ - masa rotirajućih dijelova povratnih valjaka po jednome metru dužine transportera (kg/m), - $q_v'' q_v''$ - masa povratnih valjaka u jednome slogu prema tablici 5 za vodoravne valjke promjera 60 mm slijedi $q_v'' q_v''$ = 2,6 kg, $l''l''$ - (2 do 3) ·$l'l'$= 2 ·1,5 = 3 m => razmak slogova povratnih valjaka. Prema Rulmeci (2003) postoji preporuka korištenja udaljenosti od 3 m. Iz dobivenih podataka vrijedi za masu povratnih valjaka $g_v'' = 0,866\, g_v'' = 0,866$ kg/m.

Budući da su izračunati svi dijelovi, izračunavaju se prema izrazu (5) $G_t = 19,606 G_t = 19,606$ kg/m. Konačni satni kapacitet izračunava se prema sljedećem izrazu:

$$Q = 3600 \cdot A \cdot v \cdot \rho = 175 Q = 3600 \cdot A \cdot v \cdot \rho = 175 \text{ (t/h)} \quad (10)$$

što čini razliku naspram planiranog satnog kapaciteta *Q* = 150 t/h od + 16,76 %. Visina spuštanja ili podizanja tereta (visinska razlika) označava se sa *H* te slijedi iz izraza:

$H = L \cdot sin \cdot \beta$ = 300·sin10° = 52,094 metara. (11)

Vučna sila na obodu pogonskog bubnja se sada može izračunati te slijedi prema izrazu 4 $F_{bo} = 13{,}346\ F_{bo} = 13{,}346$ kN.

2.4 Snaga na osovini pogonskog bubnja

Slijedi da je snaga na osovini pogonskog bubnja jednaka:

$$P_{bo} = F_{bo} \cdot v = P_{bo} = F_{bo} \cdot v = 33{,}366 \text{ (kW)}. \quad (12)$$

Dodatna snaga zbog otpora uzrokovanih postavljanjem čistača:

$$P_d = 1{,}6 \cdot v \cdot b \cdot n'' = P_d = 1{,}6 \cdot v \cdot b \cdot n'' = 3{,}2 \text{ (kW)}, \quad (13)$$

gdje je: $n''n''$ broj čistača, odabrano $n'' = 2.n'' = 2$. Dodatna snaga zbog otpora uslijed bočnih vodilica:

$$P_v = 0{,}08 \cdot l_1 = 0{,}64\ P_v = 0{,}08 \cdot l_1 = 0{,}64 \text{ (kW)}, \quad (14)$$

gdje je: $l_1 l_1$= 8 metara - dužina vodilica. Potrebna snaga motora $P_m\ P_m$ za pogon transportera slijedi iz izraza:

$$P_m = \frac{P_{ef}}{\eta} = \frac{37{,}206}{0{,}85} = 43{,}771\ P_m = \frac{P_{ef}}{\eta} = \frac{37{,}206}{0{,}85} = 43{,}771 \text{ (kW)}, \quad (15)$$

$$P_{ef} = P_{b0} + P_d + P_v = 37{,}206\ P_{ef} = P_{b0} + P_d + P_v = 37{,}206 \text{ (kW)}, \quad (16)$$

gdje je: $P_{ef}\ P_{ef}$ - efektivna snaga motora za pogon transportera, η = 0,85 - koeficijent iskoristivosti mehaničkog prijenosa snage elektromotora na bubnju. Vučna sila u traci na bubnju iznosi:

$$F_b = \frac{P_{ef}}{v} = 14{,}882\ F_b = \frac{P_{ef}}{v} = 14{,}882 \text{ (kN)}. \quad (17)$$

Ukupna vučna sila u traci na punoj strani:

$$F_t = F_b \cdot \left(1 + \frac{1}{e^{\mu \cdot \alpha} - 1}\right) = 14882 \cdot (1 + 0{,}50) = 22323$$

$$F_t = F_b \cdot \left(1 + \frac{1}{e^{\mu \cdot \alpha} - 1}\right) = 14882 \cdot (1 + 0{,}50) = 22323 \text{ (N)} = 22{,}323\ 22{,}323 \text{ (kN)}. \quad (18)$$

gdje je: $\mu\mu$ = 0,30 prema tablici 7, odabran je bubanj koji je glatko brušen, ima suhu površinu i radi u suhoj atmosferi, α = 210° odabrani kut obuhvata trake oko bubnja iz čega slijedi baza prirodnog algoritma *e* = 2,718, tj. iz tablice za odabrano trenje i kut vrijednost izraza $\frac{1}{e^{\mu \cdot \alpha} - 1} \frac{1}{e^{\mu \cdot \alpha} - 1}$ jednaka je m = 0,50.

Tablica 7. Koeficijenti trenja između bubnja i trake

Tablica 40.

Koef. trenja μ	Vrijednosti izraza $\frac{1}{e^{\mu\cdot\alpha}-1}$ za kuteve α							Svojstva površine bubnja
	180°	210°	240°	270°	300°	330°	360°	
0,10	2,71	2,25	1,92	1,65	1,45	1,28	1,15	Bubanj glatko brušen, mokra površina
0,15	1,66	1,36	1,14	0,97	0,84	0,73	0,64	Bubanj obložen drvetom ili tkaninom, površina klizava-vlažna
0,20	1,15	0,93	0,76	0,64	0,54	0,46	0,40	Bubanj glatko brušen, vlažna površina
0,30	0,64	0,50	0,40	0,32	0,26	0,22	0,18	Bubanj glatko brušen, suha površina i suha atmosfera
0,35	0,50	0,30	0,30	0,24	0,19	0,15	0,12	Bubanj obložen drvetom, suha površina, suha atmosfera
0,40	0,40	0,23	0,23	0,18	0,14	0,11	0,09	Bubanj obložen tkaninom, suha površina, suha atmosfera

Izvor: Rulmeca (2003)

Prema tablici 7 za odabrani kut od 210° te faktor trenja od 0,3 faktor prijenosa snage na bubanj je m = 0,499. Rezultirajuća snaga jednaka je:

$$P = F_u \cdot v = 16{,}64\, P = F_u \cdot v = 16{,}64 \text{ (kW)}, \tag{19}$$

gdje je:

$$F_u = F_{bo} \cdot \frac{1}{e^{\mu\cdot\alpha}-1} = 6{,}659 F_u = F_{bo} \cdot \frac{1}{e^{\mu\cdot\alpha}-1} = 6{,}659 \text{ (kN)}. \tag{20}$$

Potrebni broj uložaka u traci slijedi prema:

$$z = \frac{9{,}8\cdot F_t}{b\cdot\sigma_m} + 1 = 3{,}23 z = \frac{9{,}8\cdot F_t}{b\cdot\sigma_m} + 1 = 3{,}23, \tag{21}$$

gdje je: $\sigma_m \sigma_m$ prekidna uzdužna čvrstoća izračunata iz tablice 10 te slijedi $\sigma_m = 245175$ $\sigma_m = 245175$ N/m, a poprečna čvrstoća iznosi 78456 (N/m). Kako je ranije odabran broj uložaka iz tablice 2 z = 5, a potreban broj je z = 3, može se reći da odabrana traka zadovoljava.

2.5 Uređaj protiv kretanja unatrag

Kako bi se osiguralo ravnomjerni tijek materijala, izračunat će se obodna sila kako bi se utvrdilo je li potreban uređaj protiv kretanja mase unatrag. Teoretska masa materijala po metru transportera $q_m q_m$ može se izračunati iz sljedećeg izraza:

$$q_m = \frac{Q}{3{,}6 \cdot v} = 19{,}44 q_m = \frac{Q}{3{,}6 \cdot v} = 19{,}44 \text{ (kg/m)}. \quad (22).$$

Obodna sila F_{obv} F_{obv} za slučaj vodoravne trake može se dobiti iz sljedećeg izraza:

$$F_{obv} = g \cdot [c \cdot f \cdot L \cdot (G_t + q_m)] = 3409{,}45$$
$$F_{obv} = g \cdot [c \cdot f \cdot L \cdot (G_t + q_m)] = 3409{,}45 \text{ (N)}. \quad (23)$$

Uređaj protiv kretanja unatrag nije potreban ako je obodna sila $F_{obv} F_{obv}$ veća od sile koja je rezultat umnoška gravitacije, visine i teoretske mase materijala na transporteru, slijedi:

$F_{obv} F_{obv} > g \cdot H \cdot q_{m'}$ => 9,934,65 (N) > F_{obv} F_{obv}, (24)

obodna sila je manja te je potreban uređaj protiv kretanja unatrag.

2.6 Odabir promjera pogonskog bubnja

Promjer pogonskog bubnja izračunava se prema sljedećem izrazu:

$$D = \frac{360 \cdot F_b}{p \cdot \pi \cdot \alpha \cdot b} = 0{,}690 \; D = \frac{360 \cdot F_b}{p \cdot \pi \cdot \alpha \cdot b} = 0{,}690 \text{ (m)}, \quad (25)$$

gdje je: pp - tlak koji prijenosi silu s bubnja na traku, $\alpha\alpha$ - ranije odabrani obuhvatni kut od 210°. Iz tablice 8 odabrana je vrsta prediva i time moć prenošenja sile slijedi p_{min} = 29400 N/m^2.

Tablica 8. Tlak koji prenosi silu na pogonski bubanj ovisno o vrsti prediva

Vrsta prediva	Tlak koji prenosi silu (N/m^2).
Pamuk	p = 15700 do 19600
Rejon, perlon	p = 24500 do 29400
Čelik	p = 49050 do 58850

Izvor: Korman (2014)

U ovome radu odabrane su vrijednosti prema Rulmeci (2003). Vrijednosti za promjer D i dužinu L bubnja propisane su standardom, dok vrijednosti l_1 za razmak ležajeva služe samo kao orijentacija te slijedi da je za pogonski bubanj tip A za dobiveni promjer $D = 0{,}690$ $0{,}690$ m prema standardu odabrano D = 800 mm. Kontrolira se postoji li zadovoljavajući odnos između promjera D i broja uložaka za rad u površinskim uvjetima: $D_A = D$ = 0,8 m > (0,125 - 0,18)·z = 0,125·5 = 0,65 m. D_A = 0,8 > 0,65 m te je vidljivo da odabrani promjer zadovoljava uvjet. Broj okretaja bubnja za pogonski bubanj tip A može se dobiti prema:

$$n = \frac{60 \cdot v}{\pi \cdot D_A} = 59{,}71 n = \frac{60 \cdot v}{\pi \cdot D_A} = 59{,}71 \text{ (min}^{-1}\text{)}. \quad (26)$$

Jedan od glavnih parametara pri određivanju životnog vijeka nosećih valjaka je brzina okretaja koja je u ovome istraživanju 50 min^{-1}, za to je važan dijagram balansiranja (Sandvik, 2014). Iznad 100 min^{-1} potrebno je statičko balansiranje, dok je s brzinama okretaja iznad 200 min^{-1} potrebno i dinamičko balansiranje. Očekivani rok trajanja nosivog valjka je 50 000 sati. Snaga po jednom okretaju bubnja:

$$s = \frac{P_{ef}}{n} = \frac{37{,}206}{59{,}71} = 0{,}623 s = \frac{P_{ef}}{n} = \frac{37{,}206}{59{,}71} = 0{,}623 \text{ (kW/(o/min)).} \tag{27}$$

Odabran je bubanj (tip A) sa sljedećim karakteristikama: D_A = 0,8 m, L = 1150 mm je širina bubnja na koju naliježe traka, l_1 = 1370 mm je širina bubnja s prirubnicama, s = 0,942 kW/(o/min), F_{maks} = 88290 N je maksimalna sila koju bubanj može prenijeti. Važno je da sila na osi odabranoga bubnja zadovolji uvjet $F_r < F_{maks}$ kako bi se materijal transportirao.

$$F_r = \sqrt{F_t^2 + F_0^2 - 2 \cdot F_t \cdot F_0 \cdot cos\alpha} = 16978{,}12$$

$$F_r = \sqrt{F_t^2 + F_0^2 - 2 \cdot F_t \cdot F_0 \cdot cos\alpha} = 16978{,}12 \text{ (N),} \tag{28}$$

gdje je: F_t - maksimalna vučna sila na punoj strani trake F_t = 22323 N, F_b - vučna sila u traci na bubnju F_b = 14882 N, F_0 - maksimalna vučna sila na praznoj strani trake => $F_0 = F_t - F_b$ = 7441 N. $F_r F_r$ = 16970 N < F_{maks} = 88290 N. Sile na osi zadovoljene su odabranim bubnjem.

2.7 Odabir bubnja bez pogona (tip B)

Uvjet koji mora biti zadovoljen je $D_B > (0{,}1 - 0{,}125) \cdot z = 0{,}125 \cdot 5 = 0{,}65 \Rightarrow D_B > 0{,}65$. Rezultanta sila za bubanj bez pogona:

$$F_r = F_0 \cdot \sqrt{2 \cdot (1 - cos\alpha)} = 14374 \, F_r = F_0 \cdot \sqrt{2 \cdot (1 - cos\alpha)} = 14374 \text{ (N).} \tag{29}$$

Odabire se bubanj (tip B) sa sljedećim karakteristikama: D_B = 800 m, L = 950 mm je širina bubnja na koju naliježe traka, l_1 = 1160 mm je širina bubnja s prirubnicama, F_{maks} = 32373 N je maksimalna sila koju bubanj može prenijeti.

3. KONTROLA PRORAČUNA METODOM OBILASKA PO KONTURI

Otpori W_t na punoj strani trake (grafikon 4) mogu se izračunati te slijedi:

$$W_t = g \cdot \left[(q_m + q_t) \cdot L \cdot f \cdot c \cdot cos\beta + g_v' \cdot L \cdot f \cdot c \pm (q_m + q_t) \cdot L \cdot sin\beta\right] = 15925$$

$$W_t = g \cdot \left[(q_m + q_t) \cdot L \cdot f \cdot c \cdot cos\beta + g_v' \cdot L \cdot f \cdot c \pm (q_m + q_t) \cdot L \cdot sin\beta\right] = 15925$$

(N). (30)

Otpori W_0 na praznoj strani trake:

$$W_0 = g \cdot (q_t \cdot L \cdot f \cdot c \cdot cos\beta + g_v'' \cdot L \cdot f \cdot c \mp q_t \cdot L \cdot sin\beta) = -2597{,}11$$
$$W_0 = g \cdot (q_t \cdot L \cdot f \cdot c \cdot cos\beta + g_v'' \cdot L \cdot f \cdot c \mp q_t \cdot L \cdot sin\beta) = -2597{,}11 \text{ (N)}. \quad (31)$$

Napinjanje trake u pojedinim točkama konture:

$$F_1 = \frac{W_t + 1{,}05 \cdot W_0}{e^{\mu \cdot \alpha'} - 1{,}05} = 9565{,}11 \; F_1 = \frac{W_t + 1{,}05 \cdot W_0}{e^{\mu \cdot \alpha'} - 1{,}05} = 9565{,}11 \text{ (N)}, \quad (32)$$

gdje je: $e^{\mu \cdot \alpha'} e^{\mu \cdot \alpha'} = 2{,}72^{0{,}3 \cdot 3{,}66} = 3$ i $\alpha' = \frac{2\pi}{360} \cdot \alpha = \frac{2 \cdot 3{,}14}{360} \cdot 210 = 3{,}66.$
$\alpha' = \frac{2\pi}{360} \cdot \alpha = \frac{2 \cdot 3{,}14}{360} \cdot 210 = 3{,}66.$

Grafikon 4. Otpori na punoj i praznoj strani trake te sile (1, 2, 3 i 4) napinjanja na bubnjevima

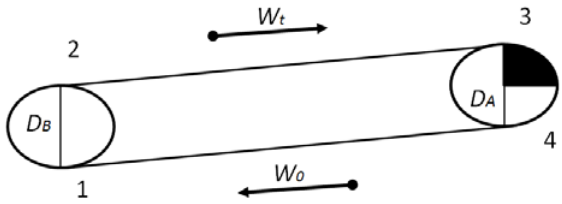

Izvor: obrada autora

Tablica 9 prikazuje konačne sile (grafikon 4) napinjanja na bubnjevima.

Tablica 9. Sile napinjanja na bubnjevima

Točka	Oznaka sile
1	$F_1 = 9565{,}11$ 9565,11 N.
2	$F_2 = F_1 + W_0 = 6968$ 6968 N.
3	$F_3 = 1{,}05 \cdot F_2 = 7316$ N.
4	$F_4 = F_3 + W_t = 23241{,}4$ N.

Izvor: obrada autora

Potrebno je odrediti minimalnu silu napinjanja F_{min} kako bi se osigurao dozvoljeni progib trake f_{doz} između dva noseća sloga (grafikon 5). Progib trake f_{doz} između dvaju nosećih slogova računa se prema:

$$f_{doz} = 0{,}02 \cdot l' = 0{,}02 \cdot 1{,}5 = 0{,}03 \text{ (m)}. \quad (33)$$

$$F_{min} = g \cdot \frac{(q_t+q_m)\cdot l'^2}{8\cdot f_{doz}} = 2730{,}19 F_{min} = g \cdot \frac{(q_t+q_m)\cdot l'^2}{8\cdot f_{doz}} = 2730{,}19 \text{ (N)}. \quad (34)$$

Grafikon 5. Progib trake zbog težine gume i težine materijala na traci

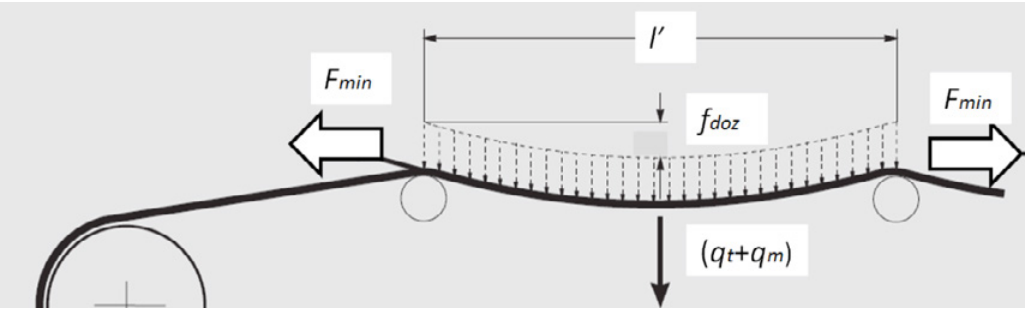

Izvor: Rulmeca (2003)

Između točaka 3 i 4 djeluju sile F_3 = 7316 N i F_4 = 23241,4 N koje su veće od F_{min} = 2730,19 N, što znači da napinjanje zadovoljava uvjet. Kontrola sigurnosti trake:

$$K' = \frac{b\cdot\sigma_m\cdot(z-1)}{F_{max}} = 16{,}87 . K' = \frac{b\cdot\sigma_m\cdot(z-1)}{F_{max}} = 16{,}87. \quad (35)$$

Uvjet da je K' > 9,8 je zadovoljen. Kontrola potrebnog broja uložaka:

$$z = \frac{9{,}8\cdot F_{max}}{b\cdot\sigma_m} = 2{,}322 z = \frac{9{,}8\cdot F_{max}}{b\cdot\sigma_m} = 2{,}322\,, \quad (36)$$

slijedi da je z < od 5 te je uvjet zadovoljen. Vučna sila po obodu pogonskog bubnja:

$$F_{b0} = F_4 - F_1 = 13{,}676 \text{ (N)}.$$

Snaga na obodu bubnja: $P_{b0} = F_{b0}\cdot v = 34{,}190$ (kW).

Snaga motora: $P_{ef} = P_{b0} + P_d + P_v = 38{,}03$ (kW).

$$P_m = \frac{P_{ef}}{\eta} = 44{,}74\, P_m = \frac{P_{ef}}{\eta} = 44{,}74 \text{ (kW)}.$$

Na grafikonu 6 prikazana je shema rezultirajućih sila na konturi transportne trake.

Grafikon 6. Progib trake zbog težine gume i težine materijala na traci

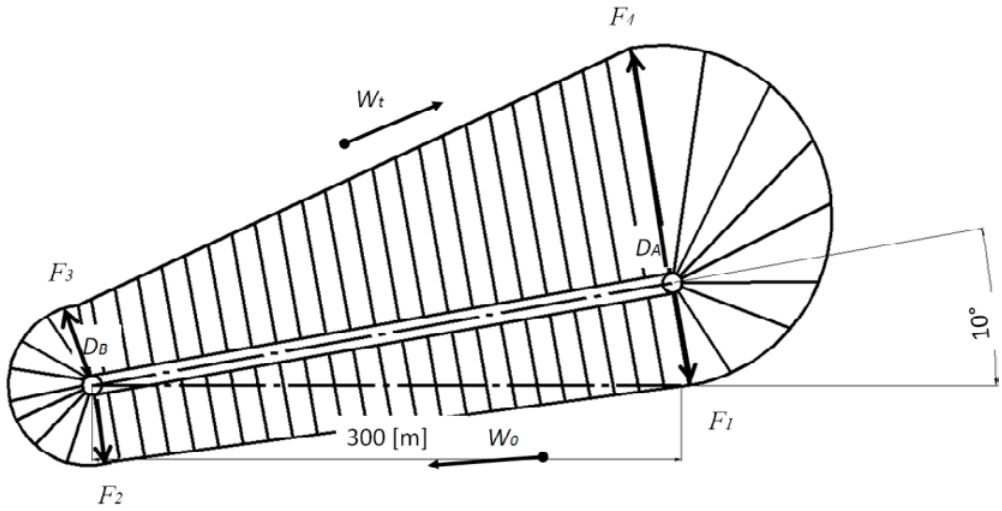

Izvor: obrada autora

4. ZAKLJUČAK

U radu je prikazan proračun trakastog transportera duljine 300 metara za prijenos minimalno 150 tona na sat ugljene prašine pri usponu od 10°. Proračun je napravljen za teške uvjete rada i za rad pri suhome zraku. U izradi proračuna koristila se stručna literatura te standardni katalozi. Proračunata je potrebna širina trake, noseći valjci, izračunata je snaga na osovini pogonskog bubnja. Napravljena je kontrola i ustanovljeno je da je potreban uređaj protiv kretanja unatrag. Izračunata je potrebna prijelazna duljina trake te je proračunat i odabran pogonski bubanj te bubanj bez pogona. Na kraju je provedena kontrola proračuna metodom obilaska po konturi, proračunom otpora i sila koje djeluju na traku. Utvrđeno je da je stvarni učin 175 tona po satu, da je potrebna snaga motora 43,74 kWh. Ustanovljeno je da je za odabrane parametre pri napinjanju potrebno zadovoljiti silu od F_{min} = 2730,19 N koja nastaje zbog težine trake i materijala. Težina materijala i trake koji zajedno na metar duljine imaju je 25,72 kilograma, tj. djeluju silom od 252 N. Budući da je minimalna sila koja djeluje na obodu 6968 N, taj uvjet je zadovoljen. Najveća sila na kraju transporta koja je potrebna da se povuče traka iznosi F_4 = 23241 N. Jedan od glavnih parametara pri određivanju životnog vijeka nosećih valjaka je brzina okretanja koja je u ovome istraživanju 50 min^{-1}. Iznad 100 min^{-1} potrebno je statičko balansiranje, dok je s brzinama okretaja iznad 200 min^{-1} potrebno i dinamičko balansiranje. Očekivani rok trajanja nosivog valjka je 50 000 sati.

LITERATURA

Mavrin, I. (1999) *Transporteri*, Zagreb: Fakultet prometnih znanosti

Korman T. (2014) *Vježbe proračun transportera s beskonačnom trakom*, Zagreb: Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet

Rulmeca (2003) *Rollers and components for bulk handling*, RULLI RULMECA S.p.A. 40 Edition, http://www.rulmecacorp.com/Conveyor_Idler_Roller_catalog/Complete_Idler_Roller_Catalog.pdf (12. 1. 2014.)

Sandvik (2014) *Selection of conveyor pulley*, Sandvik, 5/2000. http://construction.sandvik.com/sandvik/0120/Internet/Global/S003713.nsf/Alldocs/Products*5CConveyors*and*conveyor*components*5CPulleys*and*take*2Dup*devices*2AMedium*duty*dead*shaft*pulley/$file/Pulley-select.pdf (11. 1. 2014.)

Rulmeca (2014) Motorized Pulley Design Software, Rulmecacorp, http://www.rulmecacorp.com/Motorized_Pulley_Design_Software.htm (14. 1. 2014.)

Gregorović T. (2014) *Dizajn i odabir parametara transportne trake,* završni rad, 2014, Rijeka: Veleučilište u Rijeci

Tatjana Gregorović [1]
Dario Bognolo [2]
Marko Kršulja [3]

Professional paper
UDC 622.647.2

CALCULATION AND PARAMETER SELECTION FOR CONVEYOR BELT[4]

ABSTRACT

This paper presents the calculation for conveyor belt for continuous transportation of material. The investigated conveyor is designed for transportation of coal dust, the selected length of the conveyor belt being 300 meters with the rising angle of 10°. The required carrying capacity was 150 tons per hour. All necessary functional components of the conveyor belt were calculated according to the standards, as well as the desired final output. The paper describes the process of selecting conveyor belt speed, belt width, the calculation of operating power, the choice of dimensions of the drive drum and bearing rollers. The standard model for belt conveyor calculation was used. The forces occurring in the process were investigated and the method of force contour calculation was used for control.

Key words: *conveyor belt, coal dust, idlers, transportation*

[1] Student, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia.
[2] Master of Science in Mechanical Engineering, Lecturer, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: dbognolo@veleri.hr
[3] PhD, Master of Science in Mechanical Engineering, Assistant, Polytechnic of Rijeka, Vukovarska 58, Rijeka, Croatia. E-mail: krsulja.marko@veleri.hr
[4] Received: 22. 2. 2014.; accepted: 5. 5. 2014.

BIOTEHNIČKE ZNANOSTI

Slavica Dudaš [1]
Irena Šestan [2]

Izvorni znanstveni rad
UDK 582.998.12:635.03

UTJECAJ TEHNOLOGIJE UZGOJA PRESADNICA I PRIMJENE BIO-ALGEENA S-90 NA KVALITETU KADIFICE *TAGETES PATULA* L. 'ORANGE BOY'[3]

SAŽETAK

Sadnice kadifice 'Orange Boy' proizvedene su u negrijanom plasteniku u supstratu Humokomprovit H1, uz primjenu različitih tehnika uzgoja: izravna sjetva u kontejnere volumena sjetvenog mjesta 75 ml i 80 ml, kao i sjetvom omaške u jednostavne sjetvene stiroporne kontejnere uz dodatno pikiranje 15 dana nakon sjetve. Presađivanje presadnica obavljeno je u fazi prva dva lista 62 dana nakon sjetve u lončiće promjera 10 cm. Tijekom kultivacije obavljena su dva tretiranja Bio-algeenom S-90, 28 i 68 dana nakon sjetve, zalijevanjem u koncentraciji 0,5 % i folijarno otopinom 0,2 %. Praćenje porasta je obavljeno 35, 60 i 80 dana nakon sjetve, bonitiranjem visine biljke, broja formiranih listova po biljci, broja pupoljaka i otvorenih cvjetova, kao pokazatelje porasta i kvalitete sadnica kadifice. Tehnologija proizvodnje presadnica značajno utječe na kvalitetu sadnica. Presadnice proizvedene sjetvom u stiroporne kontejnere uz pikiranje zaostaju u razvoju i formiranju broja listova, pupoljaka i cvjetova u odnosu na presadnice izravno sijane u kontejnere sjetvenih mjesta volumena 75 i 80 ml. Primjena ekološkog sredstva za stimuliranje rasta presadnica Bio-algeen S-90 dva puta tijekom proizvodnog ciklusa i zalijevanjem 0,5 % i folijarno 0,2 %, nije pokazalo značajnije efekte niti na visinu biljaka i broj listova, niti na broj formiranih pupoljaka i otvorenih cvjetova.

Ključne riječi: *tehnologija uzgoja, negrijani plastenik, biostimulator,* Tagetes patula L., *'Orange Boy'*

1. UVOD

Kadifica *Tagetes patula* L. je jednogodišnja cvjetnica iz najbrojnije botaničke porodice glavočika ili *Asteraceae*. Zbog svoje široke rasprostranjenosti u hortikulturalnoj primjeni i mogućnosti uzgoja na različitim tlima, kadificu nazivaju kozmopolitskom ukrasnom vrstom koja je introducirana i naturalizirana diljem svijeta, a uzgaja se na svim kontinentima i u različitim klimatskim uvjetima (Hasanpouraghdam et al., 2011). Podrijetlom je iz Novog Meksika i Južne Amerike, gdje ju samoniklu nalazimo u prirodi. Inače, rod *Tagetes* obuhvaća oko 50 vrsta, većinom zeljastih, grmolikih ili polugrmolikih jednogodišnjih vrsta, ali i trajnica. Kadifice, najčešće zastupljene u hortikulturi,

[1] Dr. sc., predavač, Veleučilište u Rijeci, Poljoprivredni odjel, K. Huguesa 6, Poreč, Hrvatska. *E-mail:* slavica.dudas@veleri.hr
[2] Studentica, Veleučilište u Rijeci, Poljoprivredni odjel, K. Huguesa 6, Poreč, Hrvatska. *E-mail:* irensestan@veleri.hr
[3] Datum primitka rada: 13. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

podijeljene su u dvije osnovne grupe: američka visoka kadifica velikog cvijeta (*Tagetes erecta* L.) i francuska niska kadifica sitnijeg cvijeta (*Tagetes patula* L.). Široku primjenu kadifice omogućavaju jednobojni ili višebojni žuti, narančasti, žutosmeđi, crvenkasti jednostavni ili ispunjeni cvjetovi visoke dekorativne vrijednosti, kao i listovi svjetlo do tamnozeleni, neparno perasti, koji svojim oblikom podsjećaju na paprati.

Cijela biljka kadifice je aromatična. Sekretorne strukture bioaktivnih tvari su utvrđene u svim dijelovima biljke, započevši od kotiledona, stabljike, listova, cvjetova do korijena (Sacchetti et al. 2001). Znanstvena istraživanja u Iranu potvrđuju da su eteričnih ulja sjemena kadifice bogata bioaktivnim tvarima kao što su seskviterpenski i tiofenski spojevi koji potencijalno mogu naći primjenu kao biološka sredstva za zaštitu bilja, zbog svojih insekticidnih i nematocidnih svojstva (Hasanpouraghdam et al., 2011).

Istraživanja provedena u Venezueli pokazuju kako je sadržaj eteričnog ulja u nadzemnim biljnim dijelovima prosječno iznosio 0,17 % s identificiranih 30 sastojaka (Rondon et al., 2006).

O djelovanju aktivnih komponenti kadifice s baktericidnim, fungicidnim, insekticidnim, nematocidnim i larvicidnim efektom govori cijeli niz znanstvenih istraživanja (Sacchetti et al., 2001, Rondon et al., 2006, Jankowska et al., 2009, Hasanpouraghdam et al., 2011), stoga su započeta i istraživanja s naglaskom na evaluaciju pozitivnih efekata uzgoja kadifice u konsocijaciji s povrćarskim kulturama, npr. s kupusom (Jankowska et al., 2009).

U Hrvatskoj je kadifica široko raširena i omiljena kultura s primjenom u parkovima, na balkonima, a visoki tipovi rijetko se uzgajaju za rez. Osim u dekorativne svrhe, kadifica je prisutna i u ekološkoj proizvodnji, u vrtovima i raznim konsocijacijama zbog svoje aromatičnosti i pozitivnog djelovanja na druge biljke. Kadifica je poznata biljna vrsta koja u konsocijaciji s povrćarskim kulturama, pogotovo iz botaničke porodice *Solanaceae*, djeluje nematocidno, izlučevine korijena djeluju antagonističko na nematode. Znanstveno su to potvrdili kanadski istraživači Sturtz i Kimpinski (2004), utvrdivši da bakterije izolirane iz korijena kadifice *T. patula* i *T. erecta* signifikantno smanjuju gustoću populacije nematoda u zoni korijena krumpira.

Kadifica kod nas dominira kao cvjetnica i sadnice su iz godine u godinu u ponudi u velikom broju, započevši od proljeća u pojedinačnim lončićima ili kontejnerima od 4 ili 6 lončića. U uzgoju nije previše zahtjevna, sam uspjeh proizvodnje i kvaliteta sadnica prvenstveno ovisi o kvaliteti sjemena, supstratu, klimatskim uvjetima, gnojidbi i drugim faktorima. Cilj ovog istraživanja je bio ispitati utjecaj tehnologije uzgoja i primjene Bio-algeena S-90, ekološkog sredstva na bazi morskih algi *Ascophyllum nodosum*, za stimuliranje rasta i razvoja biljaka, na porast i kvalitetu sadnica kadifice.

2. MATERIJAL I METODE

Pokus je proveden 2009. godine u negrijanom plasteniku Veleučilišta u Rijeci, Poljoprivrednog odjela u Poreču. U pokusu je korišteno certificirano sjeme kadifice sorte 'Orange boy'. Kadifice su uzgajane u supstratu Humokomprovit H-1, u kombinaciji s ekološkim stimulatorom rasta biljaka Bio-algeen S 92 na bazi morskih algi *Ascofyllum nodosum*. Presadnice su uzgajane u kontejnerima JP3040/54H s 54 sjetvenih mjesta, volumena pojedinačnog lončića od 75 ml kontejnerima PL2838/48 s 48 sjetvenih mjesta podijeljenih u osam pojedinačnih jedinica sa 6 sjetvenih mjesta, volumena pojedinačnog lončića 80 ml i jednostavnim sjetvenim kontejnerima od stiropora. Za konačno presađivanje presadnica korišteni su lončići promjera 10 cm, volumena 0,4 l.

Sjetva kadifice obavljena je 16. 3. 2009. godine. Primijenjena je sljedeća tehnika sjetve:

a. Sjetva omaške u jednostavne sjetvene kontejnere od stiropora, po cijeloj površini kontejnera, uz pikiranje nakon 15 dana u ranom stadiju razvoja, s dva prava lista u kontejnere volumena pojedinačnog lončića 80 ml.

b. Sjetva u kontejnere od 54 sjetvenih mjesta (volumen lončića 75 ml) i 8x6 sjetvenih mjesta (volumen lončića 80 ml) s po dvije sjemenke na jedno sjetveno mjesto, uz kasnije prorjeđivanje u stadiju 2 prava lista i ostavljanje jače razvijene biljke.

Nicanje je započelo 4 dana nakon sjetve, dok je prvo tretiranje presadnica Bio-algeenom S-90 obavljeno 28 dana nakon sjetve (zalijevanjem otopinom 0,5 % i folijarno otopinom 0,2 %). Presađivanje presadnica kadifice u lončiće promjera 10 cm, volumena 0,4 l je obavljeno 62 dana nakon sjetve. Četiri dana nakon presađivanja obavljeno je drugo tretiranje Bio-algeenom S-90 po istoj shemi. U ispitivanje je uključeno devet varijanti (tablica 1).

Pokus je postavljen po principu slučajnog rasporeda u tri ponavljanja. Svaka varijanta se sastojala od 3x18 lončića, ukupno 486 lončića za cijeli pokus. Mjerenje i praćenje parametara je obavljeno 35, 60 i 80 dana nakon sjetve. Praćena je visina biljaka, broj listova, broj formiranih pupoljaka te broj otvorenih cvjetova po biljci.

Prikupljeni podaci su analizirani pomoću statističkog software SPSS ver. 17, primjenom ANOVE i Tukey testa za multiple usporedbe na pragu značajnosti $p \leq 0,05$ i dvostrane analize korelacija prema Pearsonu, $p \leq 0,01$.

Tablica 1. Varijante u pokusu

Varijanta	Varijanta	Napomene
80Z-0,5%	Presadnice u lončiću 80 ml+zalijevanje Bio-algeenom S-90 0,5 %	Izravna sjetva kadifice u jedinice od 6 sjetvenih mjesta, volumen lončića 80 ml, bez pikiranja. 62 dana nakon sjetve presađivanje u lončiće 10 cm promjera, volumena 0,4 l 2 x tretmana Bio-algeenom S-90 (28 i 68 dana nakon sjetve)
80P-0,2%	Presadnice u lončiću 80 ml+folijarno Bio-algeenom S-90 0,2 %	
80K	Presadnice u lončiću 80 ml – bez tretiranja, kontrola	
P80-Z-0,5%	Presadnice pikirane u 80 ml lončiće + zalijevanje Bio-algeenom S-90 0,5%	Sjetva omaške u stiroporne kontejnere + pikiranje 14 dana kasnije u kontejnere od 80 ml volumena (jedinice po 6 sjetvenih mjesta). 62 dana nakon sjetve presađivanje u lončiće 10 cm promjera, volumena 0,4 l 2 x tretmana Bio-algeenom S-90 (28 i 68 dana nakon sjetve)
P80-P-0,2%	Presadnice pikirane u 80 ml lončiće + folijarno Bio-algeenom S-90 0,2 %	
P80-K	Presadnice pikirane u 80 ml lončiće–bez tretiranja, kontrola	
75Z-0,5%	Presadnice u lončiću 75 ml+zalijevanje Bio-algeenom S-90 0,5 %	Izravna sjetva u kontejnere od 54 sjetvenih mjesta, volumen lončića 75 ml, bez pikiranja. 62 dana nakon sjetve presađivanje u lončiće 10 cm promjera, volumena 0,4 l. 2 x tretmana Bio-algeenom S-90 (28 i 68 dana nakon sjetve)
75P-0,2%	Presadnice u lončiću 75 ml +folijarno Bio-algeenom S-90 0,2 %	
75K	Presadnice u lončiću 75 ml – bez tretiranja, kontrola	

Izvor: obrada autora

3. REZULTATI I RASPRAVA

Analizom prikupljenih podataka utvrđene su značajne razlike u visini biljaka između inačice kadifice iz izravne sjetve u kontejnere, pojedinačnih lončića volumena 75 i 80 ml, u odnosu na kadificu zasijanu omaške, uz dodatno pikiranje.

Značajne razlike u visini biljaka pri prvom mjerenju, u početnim stadijima razvoja, nisu zabilježene, razlike među njima su došle do izražaja pri drugom i trećem mjerenju (grafikon 1). Pri drugom mjerenju visine biljaka, kadifica zasijana u lončiće volumena 75 ml, neovisno o tretmanu Bio-algeenom S-90, pokazuje značajno intenzivniji porast biljaka u odnosu na ostale varijante. Pri trećem mjerenju (04. 6.2009.), kadifica iz sjetve u kontejnere od 75 ml pojedinačnog lončića je statistički značajno viša u odnosu na kadificu dodatno pikiranu u lončiće 80 ml volumena.

Ovi rezultati su u skladu s istraživanjima (Filaković et al., 2009) provedenim na presadnicama paprike koji ukazuju na kontinuirano povećavanje visine biljke s porastom presadnica paprike, ali povećanje volumena sjetvenog mjesta ne povećava kontinuirano visinu presadnice. Slične rezultate su dobili i drugi (Seletković et al., 2011) ispitujući uzgoj sadnica crnog bora (*Pinus nigra* Arn.), pri čemu je visina sadnica varirala u ovisnosti o volumenu uzgojnog kontejnera i nije kontinuirano pratila povećanje visine biljaka s povećanjem

volumena lončića. Manji volumen lončića podrazumijeva gušći sklop i može izazvati izduživanja presadnica. Smanjivanjem volumena lončića, izravno se smanjuju troškovi po jedinici presadnice. Veći volumen lončića presadnicama pruža više vegetacijskog prostora, rjeđi sklop, više supstrata i veći prostor za razvoj jačeg korijena. To je jedan od razloga što presadnice u manjim lončićima u početnim fazama zaostaju za rastom nadzemnog dijela u korist razvoja jačeg korijena. Korištenjem kontejnera većeg volumena povećava se potrošnja supstrata i cijena proizvodnje.

Grafikon 1. Visina presadnica kadifice

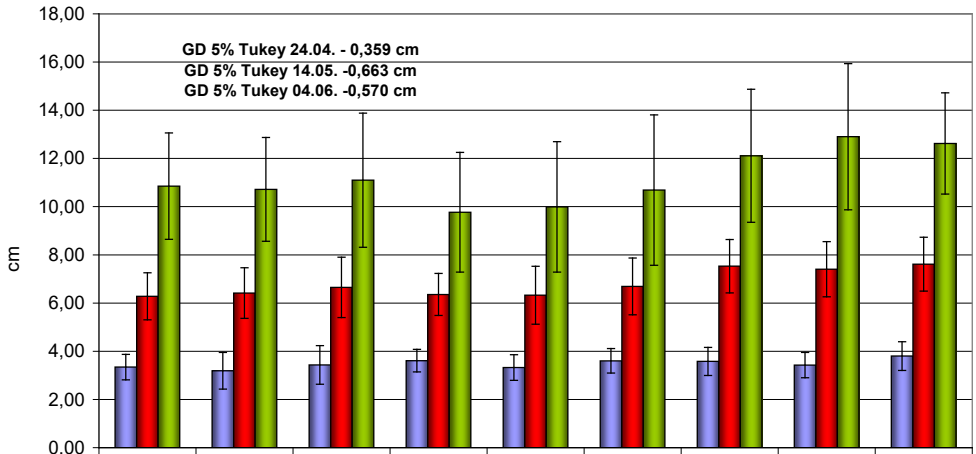

	80Z-0,5%	80P-0,2%	80K	P80-Z-0,5%	P80-P-0,2%	P80-K	75Z-0,5%	75P-0,2%	75K
24.04.	3,34 ab	3,19 a	3,43 ab	3,61 bc	3,33 ab	3,60 bc	3,58 bc	3,43 ab	3,80 c
14.05.	6,28 a	6,41 a	6,65 a	6,36 a	6,33 a	6,69 a	7,53 b	7,41 b	7,61 b
04.06.	10,85 ab	10,72 ab	11,10 abc	9,76 a	9,99 a	10,69 ab	12,11 bcd	12,90 d	12,62 cd

Izvor: obrada autora

Pri prvom prebrojavanju listova po biljci (grafikon 2.) statistički najveći broj je imala kadifica zasijana u kontejnere volumena 75 ml (kontrola, zalijevanje i folijarna primjena), u odnosu na ostale varijante. Pri drugom bonitiranju, broj listova svih ispitivanih varijanti je bio relativno ujednačen i nije pokazivao značajna odstupanja.

Pri trećem bonitiranju, kadifica izravno zasijana u kontejnere volumena pojedinačnog lončića 80 ml formira više listova, razvija se u širinu i dostiže signifikantno veći broj listova u odnosu na sve tri varijante kadifice pikirane u lončiće 80 ml i u odnosu na varijantu izravne sjetve u kontejnere s lončićima 75 ml volumena i tretirane s 0,5 % otopinom Bio-algeena S-90 zalijevanjem (75Z-0,5 %). Rezultati su u suglasnosti s istraživanjima Filakovića i suradnika (2009) na presadnicama paprike, pri čemu se broj listova presadnica kontinuirano povećavao s porastom presadnica. Presadnice zasijane u kontejnere većeg volumena formirale su veći broj listova u odnosu na presadnice u kontejnerima s lončićima manjeg volumena.

Grafikon 2. Broj listova kadifice

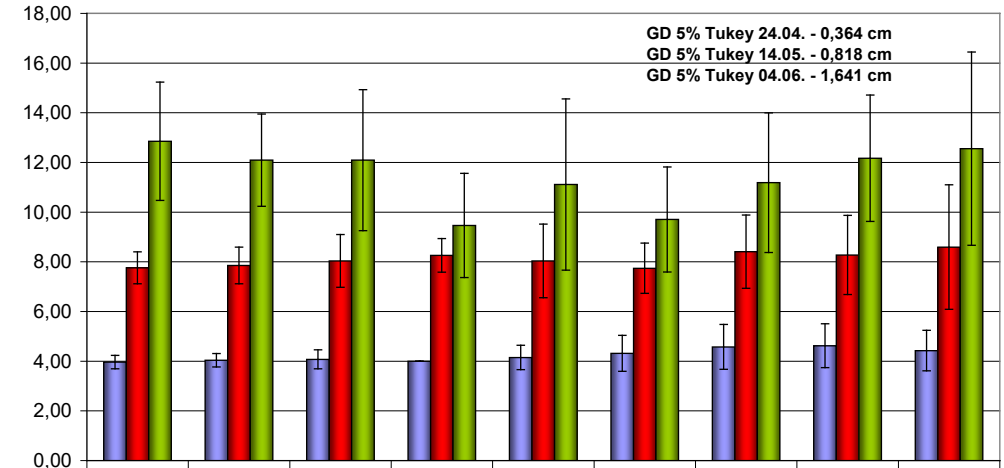

	80Z-0,5%	80P-0,2%	80K	P80-Z-0,5%	P80-P-0,2%	P80-K	75Z-0,5%	75P-0,2%	75K
24.04.	3,96 a	4,04 a	4,07 ab	4,00 a	4,15 ab	4,31 abc	4,57 c	4,62 c	4,43 bc
14.05.	7,76 a	7,85 ab	8,04 ab	8,26 ab	8,04 ab	7,74 a	8,41 ab	8,27 ab	8,59 b
04.06.	12,85 d	12,09 cd	12,09 cd	9,46 a	11,11 bc	9,70 ab	11,19 bc	12,17 cd	12,56 cd

Izvor: obrada autora

Grafikon 3. Broj formiranih cvjetnih pupoljaka i otvorenih cvjetova kadifice po biljci

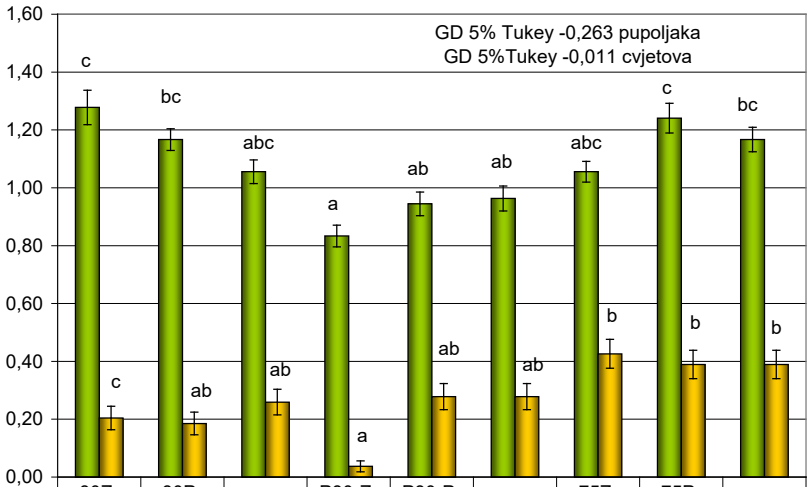

	80Z-0,5%	80P-0,2%	80K	P80-Z-0,5%	P80-P-0,2%	P80-K	75Z-0,5%	75P-0,2%	75K
broj pupoljaka	1,28	1,17	1,06	0,83	0,94	0,96	1,06	1,24	1,17
broj otvorenih cvjetova	0,204	0,185	0,259	0,037	0,278	0,278	0,426	0,389	0,389

Izvor: obrada autora

Najveći broj formiranih pupoljaka je utvrđen u varijanti sjetve kadifice u lončiće 80 ml volumena uz dodatno zalijevanje 0,5 % bioalgeenom, što je potvrdila statistička analiza u usporedbi sa sve tri varijante sjetve kadifice uz dodatnu mjeru pikiranja u lončiće volumena 80 ml bez obzira na način primjene bioalgeena (grafikon 3).

Ako uspoređujemo tri različite varijante sjetve kadifice s identičnim tretmanom Bioalgeena folijarno s 0,2 % (80P-0,2 %, P80-P-0,2 % i 75P-0,2 %), dolazimo do zaključka da upravo pikiranje prouzrokuje kašnjenje u razvoju presadnica, jer je statistički potvrđen najmanji broj pupoljaka upravo u varijanti uzgoja presadnica uz pikiranje (P80-P-0,2 %), a ne, kako je očekivano, u varijanti s manjim volumenom lončića (P75-0,2 %).

Kod broja otvorenih cvjetova (grafikon 3.), statistički najveći broj cvjetova je utvrđen u varijanti sjetve u kontejnere sa 75 ml volumena pojedinačnog lončića i 0,5 % tretmanom bioalgeena zalijevanjem, u usporedbi s ostalim varijantama. Sjetvom u kontejnere s lončićima od 75 ml volumena, kadifica se našla u gušćem sklopu, što je dovelo do intenzivnijeg rasta u visinu i djelomičnog izduživanja biljaka (grafikon 1), kao i tendencijalnog smanjenog rasta u širinu (grafikon 2.). Najmanji broj otvorenih cvjetova je utvrđen u varijanti P80-Z, (pikirane presadnice u lončiće 80 ml i zalijevane s 0,5 % bioalgeenom), u usporedbi s varijantama kadifice izravne sjetve u 80 ml lončiće i zalijevanje s 0,5 % bioalgeenom kao i sve tri varijante kadifice zasijanih u lončiće od 75 ml volumena, s i bez tretiranja bioalgeenom. Presadnice proizvedene sjetvom omaške i pikiranjem u kontejnere 80 ml (P80-P) uz folijarnu primjenu Bio-algeena S-90, zaostajale su u rastu, što se pokazalo i u broju pupoljaka po biljci zbog dodatnog stresa izazvanog pikiranjem biljaka u ranoj juvenilnoj fazi razvoja s jednim ili dva formirana prava lista.

U kumulativnom prikazu broja formiranih pupoljaka i cvjetova kadifice (grafikon 4) prikazan je postotni udio otvorenih cvjetova u ukupnom broju formiranih pupoljaka i cvjetova. Iz grafičkog prikaza 4 vidljivo je kako varijante kadifice u lončićima od 75 ml volumena s jačim porastom u ranijim stadijima imaju veći postotni udio otvorenih cvjetova u ukupnom broju formiranih pupoljaka i cvjetova (28,8 %, 23,9 % i 25,5 %), tj. ranije prelaze u generativnu fazu i time skraćuju ciklus proizvodnje, a sadnice su ranije spremne za prodaju.

Grafikon 4. Kumulativni prikaz formiranih pupoljaka i cvjetova po biljci

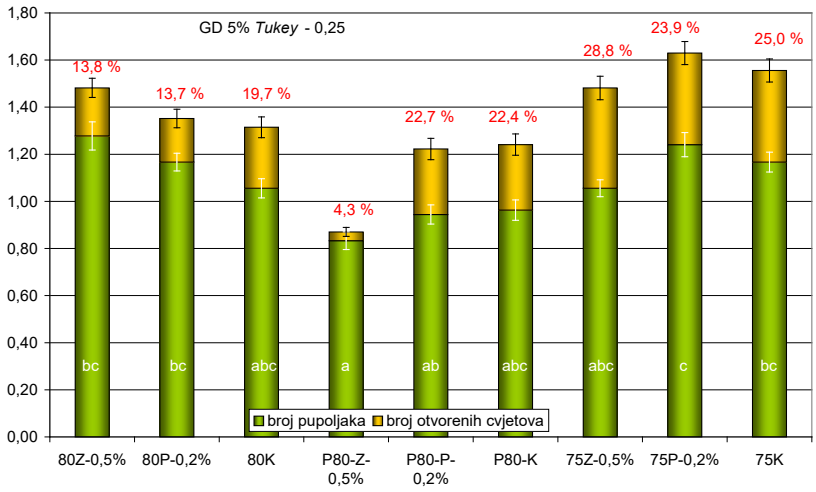

Izvor: obrada autora

Završno, obavljena je analiza korelacija ispitivanih parametara (tablica 2). Analizom podataka potvrđena je statistički pozitivna korelacija između visine biljke i broja formiranih pupoljaka i cvjetova. Kao što je i očekivano, jače razvijene biljke formiraju više cvjetova u odnosu na slabije razvijene biljke.

Tablica 2. Prikaz Pearsonove korelacije ispitivanih parametara

Parametri	Visina biljke u cm	Broj listova	Broj pup. i cvjetova
Visina biljke u cm	-	,061	,451**
Broj listova	,061	-	-,010
Broj pupoljaka i cvjetova	,451**	-,010	-
** Correlation is significant at the 0.01 level (2-tailed), Pearson Correlation, N = 486			

Izvor: obrada autora

Bio-algeen S-90 je sredstvo koje potiče ekspanziju korijena, pojačava tolerantnost prema stresu i jača rezistentnost prema patogenima. U narednim stadijima razvoja bolje razvijeni korijen, pojačana tolerantnost na stres i patogene rezultira povećanjem prinosa i kvalitete (Chojnazka et al., 2012). Efekti primjene Bio-algeena S-90 u proizvodnji sadnica kadifice (zalijevanjem 0,5 % i folijarnom primjenom 0,2 %, dva puta tijekom vegetacije) u usporedbi s kontrolom kod praćenih parametara (grafikoni 1, 2, 3 i 4) statistički nisu potvrđeni. Rezultati ovog istraživanja su u skladu s rezultatima Kažimira (Kažimir et al., 2011) pri uzgoju krastavaca. Tretman Bio-algeenom S-90 je bio obavljen dva puta tijekom vegetacije, prema preporukama proizvođača, što nije utjecalo na povećanje broja, mase, dužine i opsega ploda krastavca u ljetnom periodu uzgoja, u odnosu na druge primijenjene preparate, ali je doprinijelo smanjenom broju ličinki cvjetnog štitastog moljca (*Trialeurodes vaporariorum* Westwood). Utjecaj Bioalgeena na prinos krastavca je bio poboljšan u jesenskom periodu uzgoja.

Rezultati djelovanja Bio-algeena S-90 na kvalitetu presadnica kadifice u ovom pokusu i rezultati istraživanja u uzgoju krastavaca (Kažimir et al., 2011) nisu u skladu s rezultatima istraživanjima primjene Bio-algeena S-90 u uzgoju mrkve (Kwiatkowski et al., 2013), rajčice (Dobromilska, Gubarewitz, 2008), soje (Redžepović et al., 2006). Aplikacija Bio-algeena S-90 u stadiju 6-7 listova kod mrkve je povećalo prinos mrkve, smanjilo ukupnu količinu netržnog korijena, pri tome je smanjilo sadržaj suhe tvari i povećalo sadržaj vitamina C u korijenu mrkve (Kwiatkowski i sur., 2013). Primjenom 0,5 % koncentracije Bio-algeena S-90 na soji dovelo je do povećanja prinosa soje i povećanja sadržaja klorofila a+b u listovima (Redžepović i sur., 2006). U uzgoju rajčice su prinosi značajno povećani u odnosu na kontrolnu varijantu, ako je Bio-algeen S-90 bio primijenjen dva puta tijekom vegetacije. Međutim, primjena Bio-algeena S-90 četiri puta tijekom vegetacije dovela je do smanjenog broja cvjetova i plodova (Dobromilska, Gubarewitz, 2008). Pozitivni utjecaj biostimulatora na sadržaj klorofila, mineralni sadržaj plodova i najveći prinos sitne cherry

rajčice je postignut primjenom Bio-algeena S-90 tri puta tijekom vegetacije u koncentraciji 0,3 % u obliku spreja, folijarnom primjenom (Dobromilska et al., 2008).

U istraživanju folijarne primjene Bio-algeena S-90 u koncentraciji 1 % u uzgoju bosiljka utvrđeno je povećanje visine biljke, broja izbojaka, povećanje prinosa, ali i smanjenje ukupnog sadržaja eteričnog ulja (Kwiatkowski, Juszczak, 2011). U slučaju prave majčine dušice (*Thymus vulgaris* L.) primjena 1 % Bio-algeena S-90 je doprinijela povećanju visine majčine dušice u prosjeku 9 %, broju izbojaka s 20,9 %, što, međutim, nije doprinijelo povećanju prinosa suhe herbe i pritom je dovelo do smanjenja sadržaja timola u odnosu na kontrolnu varijantu (Kwiatkowski, 2011).

Na osnovu analize dobivenih rezultata istraživanja u pokusu s kadificom i rezultata iz literature, moguće je zaključiti kako doza i učestalost primjene Bio-algeena S-90 treba biti izrazito usklađena sa specifičnostima pojedine vrste radi postizanja pozitivnih efekata i najbolje kvalitete proizvoda, što kod velikog broja kultura, pogotovo lončanica, zahtijeva dodatna istraživanja.

4. ZAKLJUČCI

- Tehnologija proizvodnje presadnica izravno utječe na kvalitetu sadnica, veličinu, broj listova, pupoljaka i, konačno, cvjetova, kao i na duljinu proizvodnog ciklusa.
- Najbolji rezultati postignuti su izravnom sjetvom kadifice u kontejnere od 54 pojedinačnih lončića volumena 75 m, uz kasnije presađivanje u lončiće promjera 10 cm, volumena 0,4 l.
- Sjetva kadifice u kontejnere s pojedinačnim sjetvenim mjestima većeg volumena (80 ml) nije doprinijela poboljšanju kvalitete presadnica.
- Sjetva kadifice po cijeloj površini sjetvenog kontejnera uz pikiranje u stadiju 2 prava lista poskupljuje i produžava vrijeme kultivacije sadnica kadifice i predstavlja stres za biljku.
- Primjena Bio-algeena S-90 dva puta u ciklusu proizvodnje presadnica kadifice zalijevanjem otopinom 0,5 % i folijarnom primjenom otopine 0,2 % nije doprinijela značajnom poboljšanju porasta i kvalitete sadnica.
- Potrebna su dodatna ispitivanja učestalosti i doze primjene Bio-algeena S-90 u proizvodnji presadnica i lončanica.

LITERATURA

Dobromilska, R. i Gubarewitz, K. (2008) „Influence of Bio-algeen S-90 on the yield and quality of small-sized tomatos", *Biostimulators in modern agriculture*, Solonaceous crops, Dabrovski, Z.T. (ed), Editorial House Wies Jutra, Limited, Warszawa

Dobromilska, R., Mikiciuk, M., Gubarewitz, K. (2008) „Evaluation of Cherry Tomato Yielding and Fruit Mineral Composition After Using of Bio-algeen S-90" , *Journal of Elementol*, 13 (4), p. 49-499

Chojnazka, K., Saeid, A., Michalac, I. (2012) „The possibilitie of the application of algal biomass in the agriculture", *Chemik*, 66(11), p. 1235-1248

Filković, M. et. al., (2009) „Volumen sjetvenog mjesta kontejnera i starost presadnica paprike i utjecaj na kvalitetu presadnica", U: 44. Hrvatski i 4. međunarodni Simpozij agronoma. Osijek: Sveučilište Josipa Jurja Strossmayera, Poljoprivredni fakultet u Osijeku, str. 434-438

Hasanpouraghdam, M.B., et al., (2011) „Sesquiterpene rich volatile seed oil of *Tagetes patula* L. from Northwest Iran", *Journal of Central European Agriculture*, 12 (2), p. 304-311

Jankowska, B., Poniedzialek, M., Jedrszczyk, E. (2009) „Effect of intercropping cabbage with Franch Marigold (*Tagetes patula* L.) and Pot Marigold (*Calendula officinalis* L.) on the colonization of plants by pest insects", *Folia Horticulturae*, 21 (1), p. 95-103

Kažimir, Z. et al., (2011) „Utjecaj biološke zaštite na prinos krastavaca pri suzbijanju cvjetnog štitastog moljca (*Trialeurodes vaporariorum* Westwood)", *Agronomski glasnik*, 6, str. 305-315

Kwiatkowski, C. (2011) „The Effect of growth stimulators and forecrop on row material quality and yield of garden thyme (*Thymus vulgaris* L.)", *Herba Polonica*, 57(1), p. 5-15

Kwiatkowski, C., Juszczak, J. (2011) „The response of sweet basil (*Ocimum basilicum* L.) to the application of growth stimulators and forecrops", *Acta Agrobotanica*, 64 (2), p. 69-76

Kwiatkowski, C., Kolodziej, B., Wozniak, A. (2013) „Yield and Quality parameters of carrot (*Daucus carota* L.) roots depending on growth stimulators and stubble crops", *Acta Scientiarum Polonorum*, 12 (5), p. 55-68

Rajasekaran, T., Ravishankar, G.A., Obul Redy, B. (2004) „In vitro growth of *Tagetes patula* L. hairy roots, production of thiophenes and its mosquito larvicidal activity", I*ndian Journal of Biotechnology*, 3, p. 92-96

Redžepović, S. et al., (2006) „Effect of inoculation and Growth Regulator on soybean Yield and Photosyntetic Pigment Content", *Agriculturae Conpspectus Scientificus*, 71 (3), p. 75-80

Rondon, M. et al., (2006) „Chemical Compossition and Antibacterial Activity of the Essential Oil of *Tagetes patula* L. (*Asteraceae*) Collected from the Venezuella Andes", *Revista Latinamericana Quimica*, 34 (1-3), p. 32-36

Sacchetti, G. et al., (2001) „Secretory Tissue Ultrastructure in *Tagetes patula* L. (Asteraceae) and Tiophene Localization throught X-Ray Microanaliysis", *Phyton (Horn)*, 41 (I), p. 35-48

Seletković, I. et al., (2011) „Utjecaj različitih tipova kontejnera i doza sporotopivog gnojiva na rast i fiziološke parametre sadnica Crnog bora (*Pinus nigra* Arn.)", *Šumarski list*, Posebni broj, str. 90-102

Sturz, A.V., Kimpinski, J. (2004) „Endoroot bacteria derived from marigolds (Tagetes sp.) can decrease soil population densities of root-lesion nematodes in potato root zone", *Plant and Soil*, 262, p. 241-249

Slavica Dudaš [1]
Irena Šestan [2]

Original scientific paper
UDC 582.998.12:635.03

EFFECT OF SEEDLING GROWING TECHNOLOGY AND BIO-ALGEEN S-90 APPLICATION ON PLANTLETS QUALITY OF FRENCH MARIGOLD (*TAGETES PATULA* L.) 'ORANGE BOY'[3]

ABSTRACT

Marigold 'Orange Boy' seedlings were produced in a cold plastic greenhouse in Humokomprovit H1 media. Three different sowing techniques were implemented: the first two involved direct sowing into containers of 75 and 80 ml volume respectively, while the third technique involved sowing in simple shallow boxes and subsequently transplanting into 80 ml containers 15 days after sowing, when the seedlings reached the stage of two true leaves. Sixty-two days upon sowing all seedlings were transplanted into pots of 10 cm in diameter and 0.4 l in volume. During cultivation, to support the growth, marigold seedlings were treated with Bio-algeen S-90, 28 and 68 days after sowing, and were either watered with 0.5% solution or sprayed with 0.2% solution. Growth and quality parameters such as plant height, leaf number, floral bud and open flower number were investigated, with measurements conducted 35, 60 and 80 days after sowing. Cultivation technique has a significant influence on marigold seedlings quality. Seedlings produced with additional transplantation lagged behind in development, growth, leaf, floral bud and open flower number compared to the variants directly sown in 75 or 80 ml volume containers. The application of Bioalgeen to stimulate seedling growth showed no significant effect, neither on plant height and leaf number, nor on floral bud and open flower number.

Key words: *Growth technology, cold plastic greenhouse, biostimulator, Tagetes patula L., 'Orange Boy'*

[1] PhD, Lecturer, Polytechnic of Rijeka, Department of Agriculture, K. Huguesa 6, Poreč, Croatia. E-mail: slavica.dudas@veleri.hr
[2] Student, Polytechnic of Rijeka, Department of Agriculture, K. Huguesa 6, Poreč, Croatia. E-mail: irensestan@veleri.hr
[3] Received: 13. 2. 2014.; accepted: 5. 5. 2014.

Damir Šekulja [1]
Hermann Pechhacker [2]
Elisabeth Licek [3]

Original scientific paper
UDC 638.153-022.7
638.124.6

DRIFTING BEHAVIOR OF HONEY BEES (*APIS MELLIFERA CARNICA* POLLMAN, 1879) IN THE EPIDEMIOLOGY OF AMERICAN FOULBROOD[4]

ABSTRACT

The drifting of honey bees often occurs in apiaries where numbers of hives are kept close together and it is an important vector in the spreading of honey bee diseases. It occurs in high numbers, frequently and over long distances. Within this work, it was investigated whether drifting might play a role in the epidemiology of American foulbrood. To determine the presence and the number of P. larvae spores in samples of honey, pollen and honey sacs, three different methods were used: modified Ritter-Kiefer (1993) method, Columbia blood agar test (Plagemann, 1985) and catalase tests (Haynes, 1972). Although the level of drifting within the colonies with clinical symptoms of AFB was slightly higher than the one within the colonies without clinical symptoms, AFB infection did not significantly influence the drifting frequency. Even when drifting was compared between two groups of young bees at the age of orientation flights, AFB infection did not significantly influence the level of drifting. However, as the level of P. larvae spores detected both in the pollen and honey stored in the hives, as well as in the pollen found on the legs of the bees from infected colonies, was significantly higher compared with the one in colonies with no clinical symptoms of AFB, it can be concluded that drifting plays a role in the spreading of AFB, especially during the orientation flights of young bees.

Key words: *drifting, American foulbrood, epidemiology*

1. INTRODUCTION

Honey bee colonies affected by American foulbrood (AFB), a disease caused by the spore forming bacterium *Paenibacillus larvae* (Genersch et al., 2006, former *Bacillus larvae* (White, 1906)), normally die, if not treated, and therefore the disease can cause significant losses for beekeepers (Hansen,1984a).

As it is highly contagious, it can easily spread from the infected colony to other colonies of the same or even neighboring apiaries.

[1] PhD, College Professor, Polytechnic of Rijeka, Trpimirova 2, Rijeka, Croatia. E-mail: damir.sekulja@veleri.hr
[2] PhD, Dr., Austrian Carnica Association, Kleine Seeaustrasse 10, 3293 Lunz am See, Austria. E-mail: hc.pechhacker@aca.at
[3] PhD, Dr., profesor, Veterinärmedizinische Universität Wien, Veterinärmedizinische Universität Wien, Klinik für Bienen,Geflügel, Ziervögel, Reptilien und Fische, Veterinärplatz 1, 1210 Wien, Austria. E-mail: elisabeth.licek@vu-wien.ac.at
[4] Received: 16. 2. 2014.; accepted: 5. 5. 2014.

In this study, the epidemiology of AFB is investigated from the aspect of the drifting behavior of honey bees. Drifting is defined as the movement of bees between colonies (Butler, 1939), when honey bees leave one colony and join another.

It can result in increased disease spread, and though the effects of drifting are known (Frasnaye, 1963; Free, 1958 a; b; c; Garifullina, 1960;1962;1963;1965; Jay,1965; 1966 a; b;1968;1969 a; b; c;1971; Lindström, 2006), beekeepers often do not take any steps to prevent it (Matheson, 1991).

Bees entering another hive after drifting are accepted without antagonism, regardless of their age. The greatest amount of drifting occurs when large numbers of bees are flying and the least during the spring build-up and at the end of the main flow (Poltev, 1968; Hooper, 2008). It occurs regardless of the position of the hive or location of the apiary (Sulimanović, 1985).

Heavy drifting could reduce colony populations and may also lead to robbing between colonies and, in extreme cases, to the destruction of weaker colonies (Frasnaye, 1963). It is one of the ways that bee diseases are spread over considerable distances, from hive to hive, or even from apiary to apiary.

The purpose of this work was to find out whether the AFB could be spread by drifting, and whether bees from the infected colonies drift more than those from the healthy ones. The aim was also to see if the drifting of young bees at the age of orientation flights is more intensive than that of adult bees.

It was also investigated whether the drifting bees have *P. larvae* spores in their honey sacs and in pollen on their legs, and the result was compared with the level of infection of the honey and pollen in their hives.

2. MATERIALS AND METHODS

All experiments concerning the spreading of AFB between the colonies were done in isolated areas with no risk of spreading the disease to neighboring apiaries. The material contaminated with *P. larvae* spores was obtained from heavily infected colonies. The methods used for determining the level of drifting between the group of colonies with and the one without clinical symptoms of AFB were modified according to methods described by Šekulja (1989,1991), and according to the previous experience of Pechhacker (1993). To determine the drifting behavior between the colonies with and without symptoms of AFB, ten colonies placed in LR hives (with approximately equal number of bees) were split into two groups. Five of those colonies were heavily infected with AFB, while the other five colonies had no clinical symptoms of the disease. The samples of the bees from each group were differently marked, to allow distinguishing the bees from different groups.

Experiments were organized in the spring, when the activity of the bees was high, due to the rich sources of nectar and pollen in the nature. Both groups of colonies were kept untreated and

the examinations were made in the same way and at the same time of the day for both groups of colonies. In this way, the results were comparable.

The drifting was monitored on the adult foraging bees, and on the young bees at the age of the orientation flights.

After the drifting experiments were done, samples of honey and pollen from the combs, and samples of the honey bees were taken from each of the colonies used in the experiments. From each colony three samples of about fifty bees were taken and euthanized in a different way. The first group of sampled bees was euthanized mechanically, the second by hypothermia at minus 18° C, and the third was treated with liquid nitrogen at minus 196° C. It was done in order to find out whether the way of killing the bees had any influence on the vitality of *P. larvae* spores, i.e. on their ability to form characteristic colonies on MYP - agar.

2.1 Layout of honey bee colonies with and without clinical symptoms of AFB

Ten nuclei were formed in LR hives, consisting of only one body. Five of them were formed (with brood combs and bees) from the heavily infected colonies, with clinical symptoms of AFB, while other five were formed from the colonies with no clinical symptoms of the disease. Newly introduced queens for all nuclei were of the same age and from the same strain of *A. mellifera carnica* P. Colonies were moved to the new location and placed in two rows of five hives each, at the same apiary. Before the beginning of the experiments, the colonies were left at the new site for about one week.

2.2 Marking the honey bees

Samples of honey bees were marked by fluorescent tempera colors, which have been proven to be convenient for such experiments (Sulimanović, 1985; Šekulja, 1989; 1991). Colors are quickly placed either on the thorax or on the abdomen of honey bees, which makes them easily distinguishable.

Some bees at the age of orientation flights were marked genetically. The so-called 'Cordovan mutants' - with brown instead of grey hair, were just added to the colonies. A total of 2,750 marked honey bees were used in the experiments.

2.3 Drifting experiments in honey bee colonies with and without clinical symptoms of AFB

In order to see whether there is a difference between the level of drifting in the colonies with and those without clinical symptoms of AFB, two parallel experiments were organized.

In the first one, from each colony (A, B, C, D and E) of the honey bees with signs of AFB, a sample of 200 honey bees was marked on the thorax. Each sample of bees was marked

in different colors, in order to make it possible to follow the drifting among the colonies within the same row.

At the same time, in each of the colonies (a, b, c, d and e), from the group of bees without clinical symptoms of AFB, a sample of 200 honey bees was also marked, but on the abdomen, according to their position in the row, using the same colors as in the first group. In this way, it was not only possible to observe the drifting among the colonies within the same row, but also between the two groups of colonies, i.e. it was possible to see whether the bees from the healthy colonies tend to drift to the ones with the clinical symptoms and vice versa.

For each group of colonies, 6 observations were done, during a period of three days. Colonies were first examined early in the afternoon, and then again in the evening, when most or sometimes all foraging bees were already back.

2.4 Drifting experiments with honey bees during their orientation flights

Drifting experiments with honey bees at the age of orientation flights were organized with the same layout of colonies, but a few days later. As many of the previously marked bees were still alive, it was necessary to mark the young bees in a different way. The most convenient way of marking honey bees is by recessive genus, i.e. by the genetically different color.

A few brood combs from the colonies of the so-called 'Cordovan mutants' were taken from the Institute in Lunz am See, to the Faculty of Veterinary Medicine in Zagreb, and placed in the incubator. A few days later, a considerable number of young honey bees hatched, but only 250 of them had a recessive gene for brown color. Other young bees were marked on the abdomen with a white color as it had not been used in the previous experiments. They had been marked on the abdomen before being placed in the middle hives in each group of colonies. The driftings were observed in all other colonies in both rows.

In the row of the colonies with clinical symptoms of AFB, 500 young bees were marked on the thorax and introduced into the central colony in the row. As soon as the bees had hatched, the new colony accepted them without any problems.

The same thing was simultaneously repeated in the row of the colonies without clinical symptoms of the disease, the only difference being that 250 young bees were 'Cordovan' mutants, and the other half of young bees were marked on the abdomen. In this way, it was again possible not only to observe the drifting among the colonies of the same group, but also between the two rows.

After the young honey bees had been introduced to the colonies, they were left, until they reached the age of the orientation flights (age of 8 to 12 days). It was not until then that the observations started.

Six observations were made during the period of three days (in the middle of May). The weather conditions were favorable and there was enough pollen and nectar in the nature, so no extra feeding was required.

2.5 Determining the presence and quantity of *P. larvae* spores in bee products of the colonies used in the experiments

After the experiments between the honeybee colonies had been performed, samples of the honey and pollen from the combs and living honey bees were collected.

Three samples of honey were taken from each colony, together with a sample of pollen and three samples of honey bees. The samples were separately packed, marked and placed in a refrigerated container until the time of the examinations.

Honey bees were taken both from the entrance of the hive and from the combs. From each colony, 3 samples of foraging bees, and one sample of the bees at the age of orientation flights were isolated. Honey bees were killed in various ways: by liquid nitrogen, mechanically (by squeezing the thorax), and simply by putting them at - 18° C. The last method has proven to be the best one.

The infected material was examined partly at the Tierhygienische Institut in Freiburg, and mainly at the Institut für Bienenkunde in Lunz am See.

Honey sacs of the bees and samples of honey were examined using the Ritter and Kiefer method (1993), while pollen was examined using the Columbia blood agar test (Plagemann, 1985).

3. RESULTS AND DISCUSSION

The level of drifting in colonies without clinical symptoms of AFB (Table 1) was 0.68% on average (in colony a - 0.44%, in colony b - 0.5%, in colony c - 1.63%, in colony d 0.71%, and in colony e - 0.15%), while in colonies with clinical symptoms of AFB (Table 2) it was 0.85% on average (in colony A - 0.25%, in colony B - 0.65%, in colony C - 2.21%, in colony D - 0.94%, and in colony E - 0.21%). Drifting between the two groups of colonies was not observed.

The results represent the average of 6 observations during 3 days.

Table 1. Drifting of honey bees - colonies without clinical symptoms of AFB

Date	Time	Colony				
		a-green	b-yellow	c-rose	d-orange	e-red
4 May	13:00-15:30	2 yellow	1 rose	3 orange 1 red	2 rose	1 orange
	18:30-20:00	5 yellow	5 rose	9 orange 5 yellow	2 rose	_
5 May	13:00-15:30	4 yellow	2 rose 1 orange	5 orange 4 green 1 red	4 rose 1 red	2 orange
	18:30-20:00	3 yellow	3 rose 1 orange	8 orange 4 green 2 red	5 rose 1 red	2 orange
6 May	13:00-15:30	4 yellow	5 rose 1orange	10 yellow 9 orange	4 rose 3 yellow 2 red	1 orange
	18:30-20:00	3 yellow	3 rose, 2 orange	7 yellow 6 orange 4 red	4 yellow 3 red 3 rose	2 orange
Average number of drifted bees		3,5	4	13	5.67	1.17
Percentage of drifting	From the same group	0.44%	0.50%	1.63%	0.71%	0.15%
	Average	0.68%				
	From the group with clinical symptoms	-	-	-	-	-
	Average	-				

Source: authors

Table 2. Drifting of honey bees - colonies with clinical symptoms of AFB

Date	Time	Colony				
		A-green	B-yellow	C-rose	D-orange	E-red
4 May	13:00-15:30	2 rose 2 yellow	5 rose 1 orange	8 yellow 4 orange 3 red	4 rose 1 yellow 1 red	2 orange
	18:30-20:00	2 yellow	5 rose	12 yellow 8 orange 2 red	4 yellow 3 rose	3 orange
5 May	13:00-15:30	1 yellow	4 rose 1 green	8 yellow 5 orange 2 green	4 rose 2 yellow 2 green	2 orange
	18:30-20:00	2 yellow	5 rose 1 orange	10 yellow 6 orange 2 green	4 rose 3 yellow 2 green	2 orange
6 May	13:00-15:30	2 yellow	4 rose 1 green	12 yellow 7 orange	4 rose 3 yellow 1 green	1 orange
	18:30-20:00	1 yellow	3 rose, 1 green	9 yellow 6 orange 2 green	5 rose 1 red 1 yellow	_
Number of drifted bees		2	5.17	17.67	7.5	1.67
Percentage of drifting	From the same group	0.25%	0.65%	2.21%	0.94%	0.21%
	Average	0.85%				
	From the group without clinical symptoms	-	-	-	-	-
	Average	-				

Source: authors

Drifting during orientation flights in colonies without clinical symptoms of AFB was 0.71% on average (Table 3). As all marked young bees were placed in colony c, drifting was registered in 4 neighboring colonies (in colony a - 0.33%, in colony b - 1.46%, in colony d - 0.77%, and in colony e - 0.29%).

Table 3. Drifting of honey bees during orientation flights - colonies without clinical symptoms of AFB

Date	Time	Colony				
		a	b	c	d	e
14 May	10:00-12:00	1 mutant 1 white abdomen	6 mutants 2 white abd.	–	4 mutants 1 white abd.	–
	18:00-20:00	1 mutant 2 white abd.	5 mutants 3 white abd.	–	4 mutants	1 white abd.
15 May	10:00-12:00	1 mutant 1 white abd.	7 mutants 2 white abd.	–	3 mutants 2 white abd.	1 white abd.
	18:00-20:00	1 mutant	8 mutants 3 white abd.	–	4 mutants 1 white abd.	1mutant 1 white abd.
16 May	10:00-12:00	3 mutants 2 white abd.	12 mutants 5 white abd.	–	7 mutants 2 white abd.	3 mutants 1 white abd.
	18:00-20:00	1 mutant 2 white abd.	10 mutants 7 white abd.	–	6 mutants 3 white abd.	2 mutants 4 white abd.
Average number of drifted bees		2.67	11.67	-	6.17	2.33
Percentage of drifting	From the same group	0.33%	1.46%	-	0.77%	0.29%
	Average	0.71%				
	From the group with clinical symptoms	-	-	-	-	-
	Average	-				

Source: authors

Drifting during orientation flights in colonies with clinical symptoms of AFB was 1.52% on average (Table 4). Again, as all marked young bees were placed in colony C, drifting was registered in 4 neighboring colonies (in colony A - 0.46%, in colony B - 3.77%, in colony D - 1.38%, and in colony E - 0.48%).

Drifting between the two groups of colonies was registered only in colony B - 0.13%, and in colony C - 0.04%, 0.03% on average (drifting from colonies with clinical symptoms to other group was not observed).

The results represent the average of 6 observations during 3 days.

Table 4. Drifting of honey bees during orientation flights - colonies with clinical symptoms of AFB

Date	Time	Colony				
		A	B	C	D	E
14 May	10:00-12:00	6 white thorax	35 white th. 2 white abd. 1 mutant	_	7 white th.	4 white th.
	18:00-20:00	3 white th.	37 white th. 2 white abd. 1 mutant	_	6 white th.	2 white th.
15 May	10:00-12:00	2 white th.	32 white th.	_	8 white th.	3 white th.
	18:00-20:00	2 white th.	28 white th.	_	5 white th.	1 white th.
16 May	10:00-12:00	4 white th.	25 white th.	1 white abd.	18 white th.	7 white th.
	18:00-20:00	5 white th.	24 white th.	1 white abd.	22 white th.	6 white th.
Average number of drifted bees		3.67	31.17	-	11	3,83
Percentage of drifting	From the same group	0.46%	3.77%	-	1.38%	0.48%
	Average	1,52				
	From the group with clinical symptoms	0.00%	0.13%	0.04%	0.00%	0.00%
	Average	0.03%				

Source: authors

Concentration of *P. larvae* spores in samples of honey, pollen and honey bees from the colonies used in drifting experiments was examined according to the modified (Šekulja,1996) method described by Ritter and Kiefer (1993), according to which each grown *P. larvae* colony represents 119 +/- 15 spores (Table 5).

Table 5. Concentration of *P. larvae* spores in the samples of honey from the combs and from the honey sacs from the colonies used in drifting experiments

Colony Honey from the combs 1st experiment		Concentration of P. larvae colonies		
		Honey (or nectar) from the honey sacs		
		2nd experiment	Orientation flights (2nd experiment)	
Without clinical symptoms of AFB	A	18.75	11.20	--
	B	22.60	15.24	--
	C	22.80	14.18	23.85
	D	23.66	17.32	--
	E	27.00	15.02	--
	Average	22.96	14.59	23.85
With clinical symptoms of AFB	A	75.00	29.43	--
	B	53.14	45.86	--
	C	65.55	31.12	64.60
	D	76.13	33.85	--
	E	101.77	36.93	
	Average	74.32	35.44	64.60

Source: authors

From the honey of the colonies with clinical symptoms, 74.32 colonies had grown on the MYP agar, from the honey sacs of the mechanically killed bees, 34.82 *P. larvae* colonies and from the honey sacs of the bees killed by deep freezing at minus 18° C, 36.06 colonies. From the honey sacs of the bees at the age of orientation flights (killed by deep freezing at minus 18° C), 64.60 *P. larvae* colonies had grown on the MYP agar.

Pollen from the legs of the honey bees and from the combs has also proved to be positive. Columbia blood agar (Plagemann, 1985) and catalase tests (Haynes, 1972) were positive in all cases, except for samples treated by liquid nitrogen (Table 6).

Table 6. Concentration of *P. larvae* spores detected in the samples of combs (pollen/honey), and honey sacs from the colonies used in drifting experiments with different methods

Colony	Samples		Concentration of P. larvae spores		
		Method			
		Modified Hansen/ Ritter	Columbia – Blut – Schrägagar	Catalase test	
	Honey from the combs		22.96	+	+
Without clinical symptoms of AFB	Honey from the honey sacs	Mechanically killed bees	14.49	+	+
		Bees killed at - 18°C	14.69	+	+
		Bees killed by liquid nitrogen	negative	negative	negative
	Pollen from the combs		n/a	+	+
	Pollen from the bee legs		n/a	+	+
	Honey sacs (orientation flights)		23.85	+	+
With clinical symptoms of AFB	Honey from the combs		74.32	+	+
	Honey from the honey sacs	Mechanically killed bees	34.82	+	+
		Bees killed at - 18°C	36.06	+	+
		Bees killed by liquid nitrogen	negative	negative	negative
	Pollen from the combs		n/a	+	+
	Pollen from the bee legs		n/a	+	+
	Honey sacs (orientation flights)		64.6	+	+

Source: authors

P. larvae infection could be spread from one bee hive to another, or from one apiary to another by beekeepers (during manipulation with hives or frames), by various bee parasites (*V. destructor* or other mites) or by occasional visitors to the hives (wasps or other insects). However, it is mainly spread by the bees themselves. Honey bees can get in touch with *P. larvae* spores in the nature visiting the same places as the bees from the infected colonies (water, same sources of pollen and nectar, etc.). During periods of the year when there is not enough food in the nature, honey bees usually engage in robbing behavior, which is one of the most important ways of spreading the disease between colonies.

Another behavior pattern of honey bees which could significantly contribute to the spreading of *P. larvae* infection between colonies is drifting behavior. The drifting of honey bees is known

to be an important way of spreading many bee diseases. It occurs when honey bees leave one colony and join another.

Bees entering another hive after drifting are accepted without antagonism whatever their age. Although the greatest amount of drifting occurs when a large number of bees are flying (Poltev,1968), it is present always, regardless of the position of the hive or location of apiary (Cook, 1962; Free, Spencer-Booth, 1961; Jay, 1980; Jay, Dixon, 1988; Jay, Harris, 1979; Jay, Warr, 1984 ; Nekrasov, 1949; Sulimanović, 1985). All three members of the bee colony drift (Currie, Jay, 1988; 1989; 1991; Goetze, 1954, Hüttinger, Pechhacker 1988; Levenets, 1951; Šekulja, 1991), but under practical conditions of beekeeping, only the drifting of worker bees is significant (Withrell, 1965).

Drifting could also lead to robbing between colonies and, in extreme cases, to the destruction of the weaker colonies (Frasnaye, 1963).

Drifting behavior should be distinguished from robbing. Drifting occurs by mistake, and as the bees are convinced that they are entering their own hive, they are accepted by the host colony and many of them remain in it forever.

Robbing behavior occurs when bees enter a foreign hive in order to rob it. They usually kill the bees of the host colony and take the food to their own hive.

When honey bees drift into a foreign hive, they may have *P. larvae* spores on their bodies, in the pollen on their legs or in their honey sacs. They usually have no direct contact with the brood, but through social contact in the colony, *P. larvae* spores could find their way and infect the unsealed brood.

During the experimental part of this work, drifting occurred in both groups of colonies used in the experiments. The level of drifting within the colonies without clinical symptoms of AFB was lower than that within the colonies with clinical symptoms of AFB. However, the obtained difference was not considerable.

The obtained difference was slightly higher when the level of drifting was compared between two groups of young bees at the age of orientation flights. The results have also shown that the drifting of young bees was more intensive than the drifting of adult bees.

P. larvae spores were found both in honey sacs and in pollen on the legs of honey bees used in the experiments. The pollen taken from the combs was also positive. Although spores were detected in the honey sacs of both groups of colonies, a much lower concentration of *P. larvae* spores was detected among the bees from the colonies without clinical symptoms of AFB. In the honey from the combs a considerably higher concentration of *P. larvae* spores was detected in the honey from the colonies with clinical symptoms of AFB.

Liquid nitrogen probably kills all *P. larvae* spores given the fact that not a single sample treated by liquid nitrogen was positive.

It has also been observed that there was a significant difference between the concentration of *P. larvae* spores in the honey from the combs and the one in the honey sacs of the adult bees from the same hives, but at the age of orientation flights, the difference was not significant any more.

4. CONCLUSION

Based on various data about the level of drifting of worker bees, it could be concluded that high proportions of worker bees drift, drift frequently and drift over long distances.

It could not be concluded from the obtained results that the level of AFB infection has a significant influence on the drifting behavior of honey bees. Even in this case of young bees during their orientation flights, it could hardly be concluded that the level of infection has significantly influenced the level of drifting.

However, as the concentration of *P. larvae* spores found in pollen on the legs of infected honey bees, as well as in honey and pollen taken from the combs from the infected colonies, was significantly higher compared with the one in colonies with no clinical symptoms of the disease, it could be concluded that the drifting behavior of honey bees is one of the ways of spreading of *P. larvae* infection.

REFERENCES

Butler, C.G. (1939) "The drifting of drones." *Bee Wld*. 20, p. 140-142.

Cook, V.A. (1962) "Drifting of bees: effects of hives placed in circle." *NZ J. Agricult. Res. 105*, p.407-411.

Currie, R.W., Jay, S.C. (1988) "The influence of a colony's queen state, time of year, and drifting behavior on the acceptance and longevity of adult drone honey bees (*Apis mellifera* L.)." *J. Apic. Res. 27*, p. 219-226.

Currie, R.W., Jay, S.C. (1989) "Sun position and colony's queen state as possible factors influencing the orientation and drift of drone honeybees (*Apis mellifera* L.)." *J. Apic. Res. 28*, p.142-149.

Currie, R.W., Jay, S.C. (1991) "Drifting behavior of drone honey bees *(Apis mellifera* L.) in commercial apiaries." *J. Apic. Res. 30*, p. 61-68.

Frasnaye, J. (1963) "Les erreurs d'orientation des abeilles (dérive) dans le rucher moderne". *Abeille 6*, p. 185-200.

Free, J.B. (1958a) "The drifting of honey bees." *J. Agricult. Sci.* 51, p. 294-306.

Free, J.B. (1958b) "The ability of worker honey bees (*Apis mellifera*) to learn a change in the location of their hives." *Anim. Behav.* 6, p. 219-223.

Free, J.B. (1958c) "The behavior of honey bees when their hive is moved to a new site." *Bee Wld.* 39, p. 109-115.

Free, J.B., Spencer - Booth, Y. (1961)" Further experiments on the drifting of honey bees." *J.Agricult. Sci* 54, p.153-158.

Garifullina, A. Kh. (1960) "Drifting of bees in large apiaries in the swarming season.# In: *'Report of the Scientific conference of higher educational institutions in honour of the 40th anniversary of the Tatar* A.S.S.R., *Kazan*, p. 219-220.

Garifullina, A. Kh. (1962) "Drifting of honey bees at different seasons of the year." *Vop. Ekol.* 7, p. 37-38.

Garifullina, A. Kh. (1963) "Drifting of bees during cleansing flights." *Sb. Trud. Vopros. Zool. Kazan. gos. pedagog. Inst.*, p. 302-310.

Garifullina, A. Kh. (1965) "Forced migration of honey bees [from one colony to another] by moving their hive." *Sb. Trud. Vopros. Zool. Kazansk. gos. pedagog. Inst.*, p. 68-74

Goetze, G. (1954) "Wie stark verfliegen sich die Drohnen an einem grösseren Bienenstand?" *Bienenztg. 68*, p. 223-225.

Hansen, H. (1984a) "Methods for determining the presence of foulbrood *Bacillus larvae* in honey", *Danish J. Plant Soil Sci.*, 88, 325-328.

Haynes, W. C. (1972) "The catalase test, an aid in the identification of *Bacillus larvae*." *Am. Bee J. 112*, p. 130-131.

Hüttinger, E., Pechhacker, H. (1988) „Der Verflug von Arbeitsbienen und Drohnen." *Bienenwelt 30*, 173-178.

Hooper, T. (2008) Guide to bees and honey. Northern Bee Books. London.

Jay, S.C. (1965) "Drifting of honey bees in commercial apiaries. I. Effect of various environmental factors." *J. Apic. Res. 4*, p. 167-175.

Jay, S.C. (1966a) "Drifting of honey bees in commercial apiaries. II. Effect of various factors when hives are arranged in rows." J. *Apic. Res. 5*, p. 103-112.

Jay, S.C. (1966b) "Drifting of honey bees in commercial apiaries. III.Effect of apiary layout." *J. Apic. Res.* 5, p. 137 - 148.

Jay, S.C. (1968) "Drifting of honey bees in commercial apiaries. IV. Further studies of the effect of apiary layout." *J. Apic. Res. 7*, p. 37-44.

Jay, S.C. (1969a) "Drifting of honey bees in commercial apiaries. V. Effect of drifting on honey production." *J. Apic. Res. 8*, p. 13-17.

Jay, S.C. (1969b) "Studies on hiving package bees. I. Effects of various factors on loss and drifting of bees." *J. Apic. Res. 8*, p. 83-89.

Jay, S.C. (1969c) "Studies on hiving package bees. II. Effects of environmental factors on loss and drifting of bees." *J. Apic. Res. 8*, p. 91-97.

Jay, S.C. (1971) "Sun position as a possible factor in the disorientation of honey bees (Apis mellifera) (Hymenoptera - Apidae)" *Can. Entomol. 103*, p. 1111-1114.

Jay, S.C. (1980) "Studies on hiving package bees. IV. Effects on loss and drifting of bees of the method of hiving, time of day, apiary layout, and the presence or absence of brood." *J. Apic. Res. 19*, p. 242-247.

Jay, S.C., Dixon, D. (1988) "Drifting behavior and honey production of honey bee colonies maintained on pallets." *J. Apic. Res. 27*, p. 213-218.

Jay, S.C., Harris, L. (1979)" Loss and drifting of honey bees from hives moved outside after indoor wintering. I. Effect of various environmental factors." *J. Apic. Res. 18*, p. 52-56.

Jay, S.C., Warr, D. (1984) "Sun position as a possible factor in the disorientation of honey bees in the southern hemisphere." *J. Apic. Res. 23*, p. 143-147.

Levenets, I.P. (1951) "The drifting of drones." *Pcelovodstvo 1*, p. 25-30.

Lindström, A. (2006) *Distribution and transmission of American foulbrood in honey bees*. Doktorska disertacija. Agronomski fakultet Uppsala.

Matheson, A. (1991) "*Drifting behavior in honey bees.* " IBRA bibliography No 38, London.

Nekrasov, V.U. (1949) "The drifting of bees." *Pcelovodstvo 3*, 177 - 184.

Pechhacker, H. (1993) Personal communication (practical experience in epidemiology of AFB). Lunz am See.

Plagemann, O. (1985) "Eine einfache Kulturmethode zur bakteriologischen Identifizierung von Bacillus larvae mit Columbia-Blut-Schrägagar". *Berl. Münch. Tierärztl. Wochr*, 98, p. 61-62.

Poltev, V.I. (1968) "Robbing and drifting of honey bees." *Pčelovodstvo 7*, p. 42.

Ritter, W., Kiefer, B. (1993) "Eine Methode zum Nachweis von *Bacillus larvae* in Honig proben." *Tierärztl. Umschau 48*, p. 806-811.

Sulimanović, Đ. (1985) *Varooza*. Pčelarski Savez Hrvatske. Zagreb.

Šekulja, D. (1989) *Zalijetanje trutova u stacionarnim uvjetima pčelarenja LR-nastavljačama*. Diplomski rad. Veterinarski fakultet Zagreb.

Šekulja, D. (1991) *Zalijetanje pčela pri pčelarenju košnicama nastavljačama*. Magistarski rad. Veterinarski fakultet Zagreb.

Šekulja, D. (1996) *New aspects in Epidemiology of Bacillus larvae infection by Apis mellifera carnica Pollman*. Doktorska disertacija. Veterinarski fakultet Beč.

Withrell, P.C. (1965) "Drifting of drones." *Am. bee J. 105*, p. 175.

Damir Šekulja [1]
Hermann Pechhacker [2]
Elisabeth Licek [3]

Izvorni znanstveni rad
UDK 638.153-022.7
638.124.6

ZALIJETANJE PČELA (*APIS MELLIFERA CARNICA* POLLMAN, 1879) U EPIDEMIOLOGIJI AMERIČKE GNJILOĆE PČELINJEG LEGLA[4]

SAŽETAK

Zalijetanje pčela predstavlja važan put u prijenosu pčelinjih bolesti i često se događa na pčelinjacima, gdje je veći broj košnica na okupu. Zahvaća velik broj pčela, javlja se učestalo i na većim udaljenostima. U ovom je radu istraženo može li zalijetanje imati ulogu i u epidemiologiji američke gnjiloće pčelinjeg legla. Za utvrđivanje prisutnosti i broja P. larvae *spora u uzorcima meda, peluda i u mednim mjehurima, korištene su tri različite metode: modificirana Ritter-Kiefer metoda (1993), Columbia krvni agar test (Plagemann,1985) i katalaza test (Haynes,1972).*

Iako je razina zalijetanja unutar pčelinjih zajednica s kliničkim znacima američke gnjiloće bila neznatno viša od one unutar zajednica bez kliničkih simptoma, zaraženost američkom gnjilećom nije značajno utjecala na učestalost zalijetanja. Čak i kada se zalijetanje usporedilo između dviju grupa mladih pčela u dobi orijentacijskih letova, zaraženost američkom gnjilećom nije značajno utjecala na razinu zalijetanja. No kako je razina spora P. larvae *utvrđena u peludu i medu iz košnica, kao i na peludu nađenom na nogama mladih pčela iz zaraženih pčelinjih zajednica bila značajno veća u usporedbi s onom u zajednicama bez kliničkih znakova američke gnjiloće, može se zaključiti da zalijetanje pčela ima ulogu u širenju američke gnjiloće, naročito u vrijeme orijentacijskih letova mladih pčela.*

Ključne riječi: *zalijetanje, američka gnjiloća, epidemiologija*

[1] Dr. sc., profesor v. š., Veleučilište u Rijeci, Trpimirova 2, Rijeka, Hrvatska. *E-mail:* damir.sekulja@veleri.hr
[2] Dr. sc., Austrian Carnica Association, Kleine Seeaustrasse 10, 3293 Lunz am See, Austria. *E-mail:* hc.pechhacker@aca.at
[3] Dr. sc., profesor, Veterinärmedizinische Universität Wien, Veterinärmedizinische Universität Wien, Klinik für Bienen,Geflügel, Ziervögel, Reptilien und Fische, Veterinärplatz 1, 1210 Wien, Austria. *E-mail:* elisabeth.licek@vu-wien.ac.at
[4] Datum primitka rada: 16. 2. 2014.; datum prihvaćanja rada: 5. 5. 2014.

Upućujemo autore da pažljivo pročitaju upute koje slijede i pridržavaju ih se

UPUTE AUTORIMA

Zbornik Veleučilišta u Rijeci je recenzirani zbornik otvoren za suradnju znanstvenicima i stručnjacima iz područja prirodnih, biotehničkih, tehničkih i društvenih znanosti. U Zborniku se objavljuju radovi koji su po svom sadržaju važni za znanstvenu i stručnu javnost iz onih područja znanosti u okviru kojih Veleučilište u Rijeci obavlja djelatnost obrazovanja te istraživanja i razvoja.

Tekstovi se objavljuju na hrvatskom ili engleskom jeziku.

Politika uređivanja

Uredništvo zaprima prijave radova s proširenim sažetkom (na priloženom obrascu; 250 - 500 riječi, pisano u 3. licu). Zaprimljene prijave upućuju se u postupak prosudbe (*assessment process*) članovima Uredništva (prema području rada), ali i ekspertima koji nisu dio Uredništva, u slučaju specifičnog sadržaja. Uredništvo pregledava dostavljene rukopise, te donosi odluke za daljnji postupak i to:

a) koji će rukopisi, u slučaju potrebe, biti vraćeni autoru sa sugestijama, preporukama i primjedbama radi poboljšanja, prije svega, metodološke prezentacije građe istraživanja;

b) koji će rukopisi biti upućeni u postupak recenziranja (*reviewing process*);

c) koji će rukopisi biti odbijeni, budući:

- da tema ne zadovoljava zahtijevanu znanstvenu/stručnu razinu;
- da je autor članak sa sličnom temom već objavio;
- da tema ne ispunjava kriterije zbornika, osobito ako je sadržaj izvan koncepcije orijentacije zbornika te ne ispunjava metodološke standarde kojih se zbornik mora pridržavati.

Ako članak nije prihvaćen, Uredništvo autoru šalje obavijest, ali rukopis se ne vraća. Ako je autor usvojio primjedbe i sugestije iz postupka prosudbe i poboljšao tekst prema zahtjevu navedenog postupka, rukopis se šalje u postupak recenziranja. Autor dostavlja rukopis uz ispunjeni obrazac s potpisanom *Izjavom o autorskim pravima*. Svojim potpisom autor potvrđuje izvornost svoga članka i svoje autorstvo. Da bi se izbjeglo autorovo odustajanje od objave članka u tijeku recenzentskog postupka, autor se obvezuje svojim potpisom u *Izjavi o autorskim pravima* na prihvaćanje recenzentskog postupka. Nakon toga slijedi odluka o odbijanju ili prihvaćanju članka.

Prikazi knjiga, doktorskih disertacija, međunarodnih konferencija i drugih znanstvenih skupova ne podliježu recenziji. Uredništvo odabire i uređuje prikaze koji su relevantni za objavljivanje u

zborniku sukladno koncepciji uređivačke politike. Prikazi knjiga i ostalih publikacija trebaju biti napisani kao kritičke recenzije, a opseg prikaza ne bi trebao prelaziti osam kartica.

Prijevodi značajnih radova, odnosno onih koji po svom sadržaju mogu pobuditi interes znanstvene i stručne javnosti, također se objavljuju u zborniku, a njihov opseg ne bi trebao biti veći od 20 kartica.

Postupak recenziranja

Svi članci obvezno se recenziraju. Za svaki članak predviđena su dva recenzenta i to anonimna i nezavisna. Imena autora također su za recenzente anonimna. Recenzenti pišu recenziju prema dobivenim uputama i na propisanom obrascu. Ako članak, prema stajalištu recenzenta, ne udovoljava međunarodnim standardima i kriterijima zbornika, Uredništvo članak ne prihvaća. Ako recenzent članak pozitivno ocijeni, može ga kategorizirati u jednu od kategorija vrsnoće:

- *Izvorni znanstveni članak (Original scientific paper) -* originalno znanstveno djelo u kojem su izneseni novi rezultati fundamentalnih ili primijenjenih istraživanja. Članak sastavljen tako da se može na temelju datih informacija:
    - reproducirati metodološki i računski postupak i dobiti rezultate s jednakom točnošću ili unutar granice stupnja slobode, kako to navodi autor; ili
    - ponoviti autorova opažanja i prosuditi njegove analize; ili
    - provjeriti točnost analiza i dedukcija na kojima se temelje autorovi nalazi.
- *Prethodno priopćenje (Preliminary communication) -* znanstveni članak koji obavezno sadrži jednu ili više znanstvenih informacija, ali bez dovoljno pojedinosti koje bi omogućile čitatelju provjeru iznesenih znanstvenih spoznaja.
- *Izlaganje sa znanstvenog skupa (Conference paper) -* može biti objavljeno samo kao cjelovit članak koji je prethodno referiran na znanstvenom skupu, a u obliku cjelovitog članka nije objavljen u zborniku skupa.
- *Pregledni rad (Review article) -* rad koji sadrži temeljit i obuhvatan kritički pregled određene problematike, no bez značajnije izvornosti rezultata; sadrži posebni problem o kojem je već publiciran znanstveni rad, ali mu se pristupa na nov način.
- *Stručni članak (Professional paper) -* sadrži korisne priloge iz struke i za struku.

Nakon što budu napisane, Uredništvo analizira recenzije. Ako je to potrebno, rad vraća autoru koji je dužan rad prilagoditi zahtjevima recenzenta. Rad se dostavlja autoru nakon primitka obje recenzije. U slučajevima gdje se ne dovodi u pitanje kvaliteta i autoriziranost teksta, Uredništvo također može intervenirati.

Nakon što autor ponovno dostavi rad, Uredništvo utvrđuje usklađenost članka s primjedbama recenzenata.

Objavljuju se samo kategorizirani radovi koji imaju dvije pozitivne recenzije. Glavni i odgovorni urednik, nakon završetka postupka recenziranja te izmjena i dopuna tekstova koje su unijeli autor i Uredništvo, predlaže redoslijed prihvaćenih članaka u sadržaju.

Kriteriji redoslijeda jesu:

(1) kategorizacija sukladno stupnju znanstvene vrsnoće;

(2) ako su recenzenti različito kategorizirali članak, glavni i odgovorni urednik predlaže odluku Uredništvu, u pravilu, u prilog autora, tj. višu kategoriju;

(3) uvažavanje aktualnosti teme, autora i interesa zbornika u slučaju konkurentnosti iste razine znanstvene vrsnoće (kategorije).

Sadržaj članka

Rad treba biti relevantan za međunarodnu znanstvenu i stručnu javnost s jasno naznačenim ciljevima i rezultatima istraživanja, zaključkom, referencama u tekstu i bibliografskim jedinicama na kraju rada. Ideje u radu moraju biti originalne i trebaju značajno pridonositi razvoju predmeta istraživanja, a metodologija mora biti jasno opisana.

Autori u članku moraju posebnu pozornost obratiti odgovarajućem strukturiranju teksta i njegovoj odgovarajućoj dužini sukladno s priznatim standardima znanstvene metodologije.

Rad se dostavlja s posebnom stranicom (priložen obrazac) u okviru koje se potpisuje i *Izjava o autorskim pravima* te suglasnost za upućivanje rada u postupak recenzije.

Posebna stranica sadrži: naslov članka, ime i prezime autora ili, ako je više koautora, za svakog ponaosob znanstveno zvanje, stručnu spremu, znanstveni interes, odnosno područje kojim se autor bavi, naziv i adresu institucije u kojoj je autor zaposlen, broj telefona, broj faksa i adresu e-pošte. Svi navedeni podaci moraju biti napisani:

- na hrvatskom jeziku
- na engleskom jeziku, ako izvorni jezik članka nije engleski.

Prva stranica članka treba sadržavati: naslov članka, sažetak i ključne riječi na jeziku članka (na prvoj stranici članka koji se dostavlja ne navode se autori!). Na kraju članka isti podaci daju se na:

- hrvatskom jeziku (ako je tekst članka na engleskom jeziku), te
- na engleskom jeziku, ako izvorni jezik članka nije engleski.

Tekst članka mora početi uvodom, a sadrži još glavna poglavlja, fusnote, tablice, grafikone, sheme, reference u tekstu, zaključak i popis korištene literature.

Tehničko uređivanje članka

Tekstovi se pišu u *Microsoft Word Windows* programu (95 i viši). Opseg rada ne smije prelaziti jedan autorski arak (16 kartica, oko 28 800 znakova) A4 formata, a tekst je pisan u fontu Arial, veličine 11, s jednostrukim proredom (*single*), poravnan s obje strane, pisan od početka reda (bez uvlačenja prvog retka ulomka), s marginama od 2,5. Opseg rada može biti veći samo ako je to dogovoreno s glavnim i odgovornim urednikom. Ako je u tekstu potrebno posebno označiti neku riječ ili rečenicu, koriste se pisana kosa slova (*italic*), nikako ne podebljana (*bold*). Za odvajanje odlomaka koristi se dvostruki razmak.

Fusnote se rabe samo za dodatna pojašnjenja osnovnoga teksta. One se ne koriste kao poziv na Literaturu. Označavaju se na dnu stranice, u kontinuitetu, kroz cijeli članak, arapskim brojevima počevši od 1.

Naslovi poglavlja (od Uvoda do Zaključka) moraju biti kratki i jasni, te redom numerirani arapskim jednoznamenkastim brojevima. Poglavlja mogu imati i potpoglavlja koja se obavezno numeriraju s dvoznamenkastim, odnosno najviše troznamenkastim brojevima (primjer: 1; 1.1.; 2. ; 2.1.; 2.1.1. itd.), ne više od toga.

Tablice, grafikoni i sheme moraju imati broj i naziv (piše se iznad tablice, grafikona, sheme) te izvor podataka (navodi se u podnožju u skraćenom obliku; ako je preuzeto iz određenog izvora – Prezime autora (godina); npr. Izvor: Driankov et al. (1996)). Numeriraju se u kontinuitetu arapskim brojevima (posebno grafikoni, posebno sheme).

Važna napomena: Ako tablica, grafikon ili slika sadržavaju posebne znakove te su rađeni u posebnom programu, dostavljaju se u posebnoj datoteci s točno navedenim i označenim položajem na kojem dolaze u tekstu.

Članak mora zadovoljavati sve tehničke propozicije navedene u ovim uputama.

Stil i organizacija teksta

Autori se obvezno moraju pridržavati znanstvene metodologije prezentacije građe u pisanju tekstova koja je uobičajena u znanstvenim publikacijama (*Harvard style*).

To zahtijeva sljedeći pristup:

(1) Naslov i organizacija prezentacije građe:

Naslov je najvažniji sažetak rada koji mora odražavati sadržaj i svrhu rada. Mora biti jasan, koncizan i informativan (veličina fonta 14).

Građu se raspoređuje u dijelove kao što su:

- Sažetak (*Abstract*) – ispod naslova
- Ključne riječi
- Uvod

- Metodologija/metoda/model/koncepcija analize – u drugom poglavlju
- Empirijski podaci (dokumentacijska podloga) i analiza **–** slijede u trećem

poglavlju.

- Rezultate i diskusiju – prezentira se u četvrtom poglavlju
- Zaključci – (naravno) slijede na kraju.

(2) Sadržaj pojedinih dijelova prezentirane građe:

a. *Sažetak* – na skraćeni način opisuje sadržaj članka, sadrži opći prikaz teme i ispisuje se u 150 - 250 riječi *single*, veličina fonta 10, *italic*, obvezno treba sadržavati:

- utvrđeni cilj istraživanja
- metodu/model/koncepciju analize
- glavni rezultat istraživanja (analize)
- temeljni zaključak istraživanja

Sažetak se ne smije pisati u odlomcima.

b. *Ključne riječi* – moraju odražavati suštinu sadržaja rada, a navodi se tri do pet takvih riječi (veličina fonta 10, *italic*).

c. *Uvod* – sadrži definiranje problema i predmeta istraživanja s pozivom na recentnu literaturu, odnosno rezultate istraživanja (taj se dio može istaknuti i u posebnom, tj. 2. poglavlju kao *Literature review*); pri kraju uvodnog dijela utvrditi radnu/e pretpostavku/e (hipotezu/e) istraživanja – o kojoj/kojima se treba očitovati (kasnije) na početku zaključaka; taj dio završiti s naznakom organizacije teksta.

d. *Metodologija/Metoda/Model/Koncepcija* – obično se prezentira u drugom poglavlju; metoda/model/koncepcija analize mora biti transparentno istaknuta radi eventualnog (ponavljanja) testiranja rezultata od zainteresiranih istraživača (to je jedno od temeljnih pravila znanstvene metodologije).

e. *Empirijski podaci i analiza* **–** sadržavaju dokumentacijsku podlogu i rezultate analize.

f. *Rezultati i rasprava* **–** objasniti rezultate, osobito njihovo ekonomsko značenje i poruke.

g. *Zaključak* **–** treba imati u vidu da taj dio teksta nije i ne smije biti rezime! Zaključci su autorovo originalno mišljenje (ocjena) o dobivenim rezultatima te sadrže očitovanje o polaznoj hipotezi (je li ili nije dokazana), glavne rezultate istraživanja/analize, osvrt na ograničenja i probleme u istraživanju te smjernice za buduća istraživanja.

(3) *Literatura* – navesti samo one naslove (izvore) koji su korišteni u tekstu! Koristi se veličina fonta 9; viseći prvi redak.

Iza teksta članka na hrvatskom jeziku i popisa literature treba priložiti sažetak članka na engleskom jeziku (do 250 riječi). Uz sažetak na engleskom jeziku navodi se i naslov članka te ključne riječi (u konačnom prihvaćenom radu za objavu navode se i podaci o autorima na engleskom jeziku).

TABLICE dolaze unutar teksta. Svi podaci u tablici stavljaju se u redove i stupce odvojene jednostrukim tankim linijama. Svaki stupac sadrži naziv i uključuje numeričku jedinicu koja se odnosi na cijeli stupac. Tako se za višeznamenkaste brojeve rabe jedan ili dva broja, a u nazivu za određeni stupac označuju se numeričke jedinice u tisućama, milijunima i sl. Tablice se numeriraju u kontinuitetu arapskim brojevima (tablica 1, tablica 2 itd.), a pored broja i naziva, moraju imati i izvor podataka.

GRAFIKONI I SHEME dolaze unutar samog teksta. Moraju imati broj, naziv i izvor podataka. Numerira ih se u kontinuitetu arapskim brojevima (posebno grafikoni, posebno slike). Izvori podataka, navode se ispod grafikona, odnosno slika.

Napomena. U tekstu se ne prepričavaju i ne ponavljaju rezultati koji su navedeni u tablicama i grafikonima, već se rabe referentne oznake koje upućuju na podatke u tablicama ili grafikonima.

REFERENCE U TEKSTU. Citirane dijelove teksta navodi se u tekstu, a ne u bilješkama. Stavlja ih se u zagrade, uz prezime autora i godinu izdanja npr. (Horvat, 2003), a u slučaju citata navodi se još i stranica (Horvat, 2003:150). Ne koristi se *ibid.* i sl. Svaka bilješka navodi se kao i prvi put. Ako se radi o dvojici autora: (Horvat, Courty, 2004). Ako je više autora navesti prvog i pisati et al. (Horvat et al., 2003). Ako se radi o izvoru s interneta, u referenci u tekstu navodi se samo osnovna domena (http://www.veleri.hr). Svaka referenca mora se navesti u popisu literature.

LITERATURA obuhvaća sve korištene izvore i potpune podatke o djelima koja se obvezno spominju u referencama. Popis literature piše se bez broja poglavlja i dolazi na kraju rada (poslije Zaključka). Literaturu se ne numerira. Uređuje se abecednim redom prema prezimenu autora te kronološki za radove istog autora.

Literaturu se citira prema primjerima za knjige, časopise i ostale izvore:

- *Knjige:* prezime, inicijali (godina) *Naslov,* mjesto izdavanja: ime izdavača

Mohr, L. B. (1996) *Impact analysis for program evaluation*, 2nd. ed. London: Sage

Ako su dva ili tri autora, redom navesti njihova prezimena i inicijale (godinu) *Naslov,* mjesto izdavanja: ime izdavača

Riddersträle, J., Nordström, K. (2004) *Karaoke Capitalism Management for Mankind,* Harlow: Pearson Education Ltd.

Perišin, I., Šokman. A., Lovrinović, I. (2001) *Monetarna politika,* Pula: Sveučilište u Rijeci, Fakultet ekonomije i turizma "Dr. Mijo Mirković"

Ako je više autora (četiri ili više), navodi se prezime prvog autora nakon čega slijedi et al.

Norton, M. B. et al. (1981) *A People and a Nation – A History of the United States,* Boston: Houghton Mifflin Company.

- *Časopisi:* prezime, inicijali (godina) "Naslov članka", *naziv časopisa u kojem je objavljen,* volumen(broj), stranice

Fox, S. (1994) "Empowerment as a Catalyst for Change: An Example from the Food Industry", *Supply Chain Management*, 2(3), p. 29-33

Ako je više autora (četiri ili više), navodi se prezime prvog autora nakon čega slijedi et al.

Di Noia, C. et al. (1999) "Should Banking Supervision and Monetary Policy Tasks be Given to Different Agencies?", *International Finance,* 2(3), p. 361-378

Ako je više radova istog autora objavljenih iste godine, uz godinu se rabe oznake "a, b, c":

Quah, Danny Tyson. (1993 a) "Empirical Cross-section Dynamics in Economic Growth", *European Economic Review*, 37(2-3), p. 426-434

(1993 b) "Galton's Fallacy and Tests of the Convergence Hypothesis", *Scandinavian Journal of Economics*, 95(4), p. 427-443

(1994) "Exsploiting cross Section Variation for Unit Root Inference in Dynamic Data", *Economics Letters*, 44(1-2) p. 9-19

(1996 a) "Empirics for Economic Growth and Convergence" *European Economic Review*, 40(6), p. 951-958

(1996 b) "Regional Convergence Clusters across Europe", *European Economic Review*, 40(3-5), p. 951-958

- *Izvori preuzeti s interneta:* prezime autora/urednika, inicijali imena, (godina), "Naslov članka", *Naslov časopisa,* datum publikacije, godište, broj, stranice, adresa na internetu (datum pregleda adrese na internetu)

Ako kod izvora preuzetih s interneta nema autora: adresa na internetu (datum pregleda adrese na internetu).

Martin, C. L. (1998) "Relationship Marketing: a High-Involvement Product Attribute Approach, *Journal of Product and* Brand *management,* 7(1), p. 6-26 //http:www.apmforum.com/emerald/marketing-research-asia.htm (3. 10. 2002.)

- *Knjige sabranih djela:* autor poglavlja/odjeljka (godina) "Naslov poglavlja/odjeljka". U: ime izdavača ili autora sabranih djela, *Naslov sabranih djela,* mjesto izdavanja: izdavač.

Silobrčić, V. (2000) "Znanstvena proizvodnost i kriteriji vrednovanja znanstvenika u Hrvatskoj". U: Sunko, U. D. (ur.) *Znanost u Hrvatskoj na pragu trećeg tisućljeća,* Zagreb: HAZU.

- *Radovi u Zborniku skupa:* autor (godina izdanja) "Naslov članka". U: Naslov zbornika. Mjesto izdanja: izdavač, stranice

Fedchak, E., Duvall, L. (1996) "An engineering approach to electronic publishing" In: *Proceedings of the* I*nternational* W*orkshop on Multimedia Software Development,* 25-26 March. Berlin, Los Alimos, Ca: IEEE Comput. Soc. Press, p. 80-88.

- *Teze i disertacije*: navodi se ime autora (godina) *naslov*, te institucija gdje su teze obranjene

Whitehead, S. M. (1996) *Public and private men: masculinities at work in education management,* doktorska disertacija, Leeds Metropolitain University

- *Službene publikacije:* naziv publikacije/organizacije/ustanove, (godina) *Naslov,* mjesto izdavanja: izdavač

Department of the Environment (1986) *Landfilling wastes.* London: HMSO (*Waste management paper, 26)*

Ostali prilozi u Zborniku

Ostali prilozi dostavljaju se na isti način kao i članci. Ne recenziraju se, a Uredrički odbor ih ocjenjuje i razvrstava u sljedeće vrste priloga:

Prikazi knjiga. Kritička recenzija pisana jasnim i konciznim stilom u kojoj se procjenjuje struktura, stil i znanstvena dostignuća knjige. U naslovu Prikaza navodi se autor knjige. Ispod toga osnovni podaci o autoru knjige (titula, ustanova u kojoj je autor zaposlen), naslov i podnaslov rada, ako postoji, godina

izdanja, izdavač, broj stranica, vrsta izdanja, jezik, ISBN i adresu e-pošte za dopisivanje. Autor prikaza potpisuje se na kraju. Uz ime autora navodi se i ustanova u kojoj je autor zaposlen i prilaže se kopija naslovne stranice.

Prikazi doktorskih disertacija. U naslovu Prikaza navodi se autor disertacije. Ispod toga osnovni podaci o autoru (titula, ustanova u kojoj je autor zaposlen), naslov i, ako postoji, podnaslov rada te članovi komisije za obranu. Dalje se navodi datum, godina te ustanova i mjesto obrane. U kritičkom prikazu opisuje se struktura, stil i vrednuju metodologija i rezultati istraživanja. Analiziraju se teoretski i praktični doprinosi u određenom znanstvenom području. Autor prikaza potpisuje se na kraju. Uz ime autora navodi se i ustanova u kojoj je autor zaposlen.

Prikazi konferencije ili drugih skupova. Pišu se kao kritičke recenzije. U naslovu prikaza navodi se: Naziv konferencije, organizator, datum održavanja, mjesto održavanja, jezik konferencije, osoba za kontakt, e-pošta, *web*-stranica, podatak o materijalu s konferencije. Prikaz daje jasan i koncizan pregled glavnih ciljeva konferencije, imena ključnih izlagača te diskusije sudionika o znanstvenim dostignućima, rezultatima istraživanja i prijedlozima za daljnja istraživanja o ključnim pitanjima. Autor prikaza potpisuje se na kraju. Uz ime autora navodi se i ustanova u kojoj je autor zaposlen.

Ostale važne napomene Uredništva

Uredništvo pridržava pravo da tekstove koji ne odgovaraju kriterijima uputa vrati autoru, odnosno da radove u potpunosti prilagodi propozicijama Zbornika i standardima hrvatskog književnog jezika, odnosno stranog jezika. Autori su dužni pridržavati se tehničkih i ostalih uputa koje propisuje Uredništvo.

Jedan autor u jednom Zborniku može objaviti najviše dva rada.

Konačnu odluku o objavljivanju članaka kao i redoslijed članaka, određuje Uredništvo Zbornika.

Autor dobiva jedan primjerak Zbornika u kojemu je njegov rad objavljen (jedan primjerak po objavljenom članku).

Rad autora mora biti pisan standardnim jezikom i bez pravopisnih i gramatičkih pogrešaka.

Autorska prava

Kada je jednom prihvaćen, članak obvezuje autora, stoga ga ne smije objaviti drugdje bez dozvole Uredništva Zbornika koje je članak prihvatilo, a i tada isključivo uz podatak o tome gdje je članak objavljen prvi put.

Autori jamče da je njihov rad izvorni doprinos i da objavljivanje njihovog članka ne predstavlja kršenje autorskih prava. Prihvaćanjem radova za objavljivanje, izdavač postaje nositelj autorskih prava, ako u sporazumu nije navedeno drukčije.

Dostavljanje radova

Prošireni sažeci na propisanom obrascu dostavljaju se elektroničkom poštom. Nakon prihvaćene teme, radovi se dostavljaju u papirnatom obliku u tri primjerka te u elektroničkom obliku (na CD-u ili elektroničkom poštom) uz popunjeni popratni obrazac (posebnu stranicu) koji sadrži sljedeće podatke: naslov članka, ime i prezime autora i koautora te za svakoga ponaosob znanstveno zvanje, stručnu spremu, znanstveni interes, odnosno područje kojim se autor bavi, naziv i adresu institucije u kojoj je autor zaposlen, broj telefona, broj faksa, adresu e-pošte, te potpisanu *Izjavu o autorskim pravima*. Svi navedeni podaci moraju biti napisani na jeziku članka, na hrvatskom jeziku i na engleskom jeziku (ako izvorni jezik članka nije engleski).

Adresa za dostavu radova:

e-pošta: zbornik@veleri.hr

VELEUČILIŠTE U RIJECI,

Zbornik Veleučilišta u Rijeci,

Vukovarska 58, 51 000 Rijeka

Informacije o Zborniku Veleučilišta u Rijeci nalaze se na *web*-stranicama Veleučilišta u Rijeci: *http://www.veleri.hr*

UREDNIŠTVO

GUIDELINES FOR AUTHORS

The Journal of the Polytechnic of Rijeka is a peer reviewed journal open for collaboration to scientists and experts in the field of natural, biotechnical, technical and social sciences.

Texts will be published in Croatian or in English.

Editing Policy

The Editorial Board accepts applications with extended abstracts (on the enclosed submission form; 250-500 words, written in the third person). All applications go through the assessment process carried out by the members of the Editorial Board (according to the subject area addressed), as well as by other experts who are not members of the Editorial Board in the case of a specific content. The Editorial Board reviews the submitted manuscripts and decides on further procedure as follows:

a) which manuscripts, in case it is necessary, will be returned to the author with suggestions, recommendations and comments with the scope of improving primarily methodological presentation of research materials;

b) which manuscripts will go through review process;

c) which manuscripts will be rejected since:

- the subject matter does not meet the required scientific or professional level;
- the author has already published an article with a similar topic;
- the subject matter does not meet the Journal criteria, particularly if the content is beyond the concept orientation of the Journal and does not meet the methodological standards that the Journal must comply with.

If an article is not accepted, the Editorial Board notifies the author without returning the manuscript. If the author has accepted comments and suggestions given in the assessment process and has improved the text according to the requests made, the manuscript is then sent to review process. The author submits the manuscript together with the completed form and a signed Copyright Statement. With his signature the author confirms his authorship as well as the originality of the article. In order to avoid withdrawing the paper during the review process, by signing the Copyright Statement the author asserts compliance with the review process. The decison on the rejection or acceptance of the article follows.

Reviews of books, doctoral dissertations, international conferences and other scientific meetings/ gatherings do not go through the the review process. The Editorial Board chooses and edits reviews they consider relevant for publication in the Journal and in line with the editing policy concept. Reviews of books and other contributions should be written as a critical review and their length should not exceed 8 typed double-spaced pages.

Translations of important papers, i.e. the content of which can arouse interest of scientific and professional public will also be published in the Journal and their lengths should not exceed 20 typed double-spaced pages.

Review Process

All articles submitted for publication are reviewed by two anonymous and independent reviewers. The names of the authors will also be unknown to the reviewers. Reviewers evaluate the article following some already given criteria by filling in a reviewer evaluation form. If the reviewers find that the article does not meet international standards and the Journal criteria, the Editorial Board does not accept the article. If the reviewer gives a positive review the article can be categorized into one of the following categories:

- *Original scientific paper* – an original scientific work which presents new results of some fundamental or applied research. The article is written in a way that using the information given the following can be done:
  - reproduce methodological procedures and mathematical calculations obtaining equally accurate results or within the permitted deviation as indicated by the author himself; or
  - repeat the author's observations and judge his analyses; or
  - check the accuracy of the analyses' results and deductions on which the author bases his findings.
- *Preliminary communication* – a scientific article which has to contain one or more pieces of scientific information, but without sufficient details which would enable readers to check the presented scientific findings.
- *Conference paper* – can be published only as a full text previously presented at a scientific conference, but not published as a complete article in conference proceedings.

• *Review article* – an article which contains thorough and complete critical review of a specific problem, but without any significant original results; deals with a specific problem already discussed in a previously published work but adopting new approach.

• *Professional paper* – contains some useful contributions in the field of profession

and for the profession in question.

After the reviews have been completed the Editorial Board analyzes them. If it is necesary the paper is returned to the author who has to introduce the changes required by the reviewers. The paper is returned to the author only after both reviews have been received by the Editorial Board. In cases where the quality and originality of the text in not in question the Editorial Board is empowered to intervene.

After the author resubmits the paper, the Editorial Board verifies whether the article has been revised following the reviewers' comments and suggestions.

Only categorized papers given two positive reviews are published. After the review process has been completed and the articles changed and revised by the authors and the Editorial Board, the Editor-in-Chief proposes the sequence of the accepted articles in the table of contents.

The criteria for the order in which the articles will appear in the Journal are:

(1) Categorization according to level of scientific excellence;

(2) If the reviewers have categorized the article in different categories, the Editor-in-Chief proposes to the Editorial Board the categorization in favour of the author, i.e. to a higher category;

(3) The topicality of the theme, author and the Journal's field of interest in the case when articles have been assigned the same level of scientific excellence (category).

Content of the Article

The paper must be relevant for international scientific and professional public with clearly defined objectives and results of the research, conclusion, references in the text and bibliography at the end of the paper. The ideas presented in the paper must be original, considerably contributing to the development of the topic researched with clearly described methodology.

When writing articles authors must pay special attention to the appropriate structuring of the text and its length which should be in line with the accepted standards of scientific methodology.

The paper is submitted together with a separate page (enclosed form) which comprises a signed Copyright Statement and a consent for the review process of the article in question.

A separate page should contain: the title of the article, name and surname of the author or, if there are more co-authors academic affiliation (title, the field of scientific interest i.e. the field that the author has special interest in, the name and address of the institution, phone number, fax number and email address for each author. All the above mentioned information must be written:

- in Croatian
- in English.

The first page of the article should contain: the title of the article, abstract and key words in the language of the article (on the first page of the article submitted the authors are not mentioned). At the end of the article the same information is given:

- in Croatian (if the article is in English) and
- in English, if the original language of the article is other than English.

The main body of the text should begin with an introduction and contain sections, footnotes, tables, graphs, diagrams, references in the text, conclusion and bibliography.

Text Editing

The text of the article should be written in *Microsoft Word Windows* program (95 or later versions). The length of the paper should not exceed 16 A4 format pages (about 28 800 characters with spaces), and the font used should be Arial, font size 11 single-spaced, justified, written from the begining to the end of the line (without indenting the first line of a paragraph), all margins at 2.5 cm. The length of the paper can exceed the above mentioned limit only if the Editor-in-Chief consents. If it is necessary to highlight a specific word or a sentence italics should be used, never bold. Paragraphs should be double-spaced.

Footnotes should be used only for additional explanations of the text. They are not used to refer to literature used. They are put at the bottom of the page and numbered consecutively in Arabic numerals starting with number 1.

Section headings (from Introduction to Conclusion) should be short and clear and numbered using single Arabic numerals. Section headings can have subsection headings which must be marked with double or maximum triple-digit numbers (e.g. 1; 1.1.; 2.; 2.1.; 2.1.1. etc.), but not more than that.

Tables, graphs and diagrams should have a number and a caption (written above the table, graph or diagram) as well as the source of information (written in short form at the bottom; if it has been taken from another source – surname of the author (year); e.g. Source: Driankov et al. (1996)). They should be numbered consecutively in Arabic numerals (graphs should be numbered separately from diagrams).

Important note: If a table, graph or diagram contains some specific signs and is written in a special program, it should be submitted as a separate file with precise indications and marked insertion point in the text.

The article should comply with all the editing requirements listed in these guidelines.

Text Organization and Style

Authors should apply scientific methodology in presenting the contents of their papers complying with the standards of scientific publications ("Harvard Style")

This implies the following:

(1) *Title and organization of the content of the paper*:

The title is the most important abstract of the work which must contain the content and the objective of the paper. It should be clear, concise and informative (font size 14).

The content is divided into sections as follows:

- Abstract – below the title
- Key words
- Introduction
- Methodology /method / model / conception of the analysis – in the second section
- Empirical data (documented background) and analysis – in the third section
- Results and discussion – are presented in the fourth section
- Conclusion – at the end

(2) *The content of particular sections of the material presented*:

a. *Abstract* – it describes in short the content of the article, it contains a general overview of the topic in 150-250 words single spaced, font size 10, italic, and should include:

- Established objective of the research
- Method / model / conception of the analysis
- Main results of the research (or the analysis)
- Basic conclusion of the research

The abstract should not be written in paragraphs.

b. *Key words* – should reflect the essence of the article's content, usually there are three to five words (font size 10, italic).

c. *Introduction* – is focused on defining the problem and subject matter of the research with reference to the latest literature, i.e. research results (this part can also be indicated in a separate section i.e. in the second section as *Literature review*; towards the end of introduction working hypotheses should be formulated which will be discussed later on at the beginning of the conclusion; this part should end indicating the organization of the text.

d. *Methodology /method / model / conception* - is usually presented in the second section; the method /model / *conception* of the analysis should clearly be stated because of possible re-testing of the research results by interested researchers (this is one of the fundamental principles of scientific methodology).

e. *Empirical data and analysis* – contain documentation background and the results of the analysis.

f. *Results and discussion* – explain results, particularly their economic significance and

messages.

g. *Conclusion* – it should be kept in mind that this part does not represent a summary! Conclusions are the author's original opinion on or evaluation of results obtained and they contain information on the starting hypothesis (which can be contradicted or confirmed), main results of the research/analysis, referring to limitations and problems of the research as well as guidelines for future research.

(4) *References* – list only titles (sources) referred to in the text! Font size 9 is to be used, first line hanging.

After the text of the article written in Croatian and bibliography, abstract in English should follow (up to 250 words). Together with the abstract in English, the title and key words of the article should also be included (in the final version of the article accepted for publication basic information on the authors in English is also included).

TABLES should be included in the text. All the information given in tables are put in rows and columns separated by single thin lines. Each column heading for numerical data should include the unit of measurement applied to all data under the heading. Large numbers can be expressed in smaller units with appropriate column headings (in thousands, millions, etc.). Tables are numbered consecutively in Arabic numerals (e.g. Table 1, Table 2, etc.), and next to the number the source of data should also be stated.

GRAPHS AND DIAGRAMS should be included in the text. They need to have a number, the title and the source of information. They should be numbered in sequence with Arabic numerals (graphs separately from pictures). The sources of information are stated below the graphs i.e. pictures.

Note: The results indicated in tables and graphs are not described and repeated in the text, but should be related in the text by means of reference marks.

REFERENCES IN THE TEXT. Cited parts of the text are included in the text of the article, not in the footnotes. They are put in brackets with the name of the author and the year of publication e.g. (Horvat, 2003), and in the case of a citation, the page is also indicated (Horvat, 2003:150). *Ibid*. and similar words should not be used. Each note is indicated in the same way it has been indicated the first time. If there are two authors e.g.: (Horvat, Courty, 2004). If there are more than two authors, the first one should be indicated followed by "et al", e.g. (Horvat et al., 2003). For Internet sources

in the references included in the text only the basic domain is indicated *(http://www.veleri.hr)*. Each refernece should be listed in bibliography.

Bibliography comprises all sources used as well as complete information on works mentioned in references. Bibliography does not include the number of headings and is put at the end of the paper (after Conclusion). Bibliography is not numbered and it is listed in alphabetical order by first author's last name and in chronological order when there are more works by the same author.

References for books, journals and other sources are cited according to the following examples:

- *Books:* surname, initials (year) *Title,* place of publication: name of the publisher

Mohr, L. B. (1996) *Impact analysis for program evaluation*, 2nd. ed. London: Sage

If there are two or three authors, their surnames and initials (year) are put in order as they appear in the book *Title,* place of publication: name of the publisher

Riddersträle, J., Nordström, K. (2004) *Karaoke Capitalism Management for Mankind,* Harlow: Pearson Education Ltd.

Perišin, I., Šokman. A., Lovrinović, I. (2001) *Monetarna politika,* Pula: Sveučilište u Rijeci, Fakultet ekonomije i turizma "Dr. Mijo Mirković"

If there are more authors (four or more), the surname of the first author is put followed by et al.

Norton, M. B. et al. (1981) *A People and a Nation – A History of the United States,* Boston: Houghton Mifflin Company.

- *Journals:* surname, initials (year) "Title of the article", *title of the journal in which it was published,* volume (number), pages

Fox, S. (1994) "Empowerment as a Catalyst for Change: An Example from the Food Industry", *Supply Chain Management*, 2(3), p. 29-33

If there are more authors (four or more), the surname of the first author is put followed by et al.

Di Noia, C. et al. (1999) "Should Banking Supervision and Monetary Policy Tasks be Given to Different Agencies?", *International Finance,* 2(3), p. 361-378

Multiple works by the same author published in the same year, besides the year the "a, b, c" letters are used after the year:

Quah, Danny Tyson. (1993 a) "Empirical Cross-section Dynamics in Economic Growth", *European Economic Review*, 37(2-3), p. 426-434

(1993 b) "Galton's Fallacy and Tests of the Convergence Hypothesis", *Scandinavian Journal of Economics*, 95(4), p. 427-443

(1994) "Exsploiting cross Section Variation for Unit Root Inference in Dynamic Data", *Economics Letters*, 44(1-2) p. 9-19

(1996 a) "Empirics for Economic Growth and Convergence" *European Economic Review*, 40(6), p. 951-958

(1996 b) "Regional Convergence Clusters across Europe", *European Economic Review*, 40(3-5), p. 951-958

- *Sources from the Internet:* surname of the author/editor, name initials, (year), "Title of the article", *Title of the journal,* date of publication, year, volume, number, pages or online equivalent, Internet address (date of accession)

If Internet sources do not give the name of the author: Internet address (date of accession).

Martin, C. L. (1998) "Relationship Marketing: a High-Involvement Product Attribute Approach, *Journal of Product and* B*rand management,* 7(1), p. 6-26 //http:www.apmforum.com/emerald/marketing-research-asia.htm (3. 10. 2002.)

- *Books of collected writings:* author of the chapter (year of publication) "Title of the chapter". In: name of the publisher or author of collected writings, *Title of collected writings,* place of publication: publisher.

Silobrčić, V. (2000) "Znanstvena proizvodnost i kriteriji vrednovanja znanstvenika u Hrvatskoj". U: Sunko, U. D. (ur.) *Znanost u Hrvatskoj na pragu trećeg tisućljeća,* Zagreb: HAZU.

- *Papers in Conference Proceedings:* author (year of publication) "Title of the article". In: Title of the Conference Proceedings. Place of publication: publisher, pages of the section referred to:

Fedchak, E., Duvall, L. (1996) "An engineering approach to electronic publishing" In: *Proceedings of the* I*nternational* W*orkshop on Multimedia Software Development,* 25-26 March. Berlin, Los Alimos, Ca: IEEE Comput. Soc. Press, p. 80-88.

- *Theses and dissertations*: name of the author is stated (year) *title*, and the name of the awarding institution

Whitehead, S. M. (1996) *Public and private men: masculinities at work in education management,* doctoral dissertation, Leeds Metropolitain University

- *Official publications:* title of the publication/organization/institution, (year) *Title,* place of publication: publisher

Department of the Environment (1986) *Landfilling wastes.* London: HMSO (*Waste management paper, 26)*

Other Journal Contributions

Other contributions are submitted in the same way as articles. They are not reviewed, but are evaluated and grouped by the Editorial Board in the following types of contributions:

Books reviews. Critical reviews are written in clear and concise manner evaluating the structure, style and scientific achievements of a particular book. It starts with the name of the author (of the book in question), followed by his academic title, institution affiliation, the title and subtitle (if there is one) of the work, year of publication, publisher, number of pages, type of edition, language, ISBN and email address for contact. The author of the review signs the text at the end. Together with the name of the reviewer, the institution affilitaion is given and a copy of the cover page is enclosed.

Doctoral Dissertations Reviews. In the title of the review, the author of the dissertation is stated, followed by some basic information on the author (academic title, institution affiliation), title and subtitle (if there is one) of the dissertation, as well as the names of the members of the Ph.D.

committee. Further on date, year, institution and place of the dissertation defence is indicated. The critical review describes the structure, style, evaluating methodology and research results. Theoretical and practical contributions to a particular scientific field are analysed. The author of the review signs the text at the end. Together with the name of the reviewer, the institution affilitaion is given.

Reviews on conferences and other scientific gatherings. They are written as critical reviews. In the title of the review the following is included: title of the conference, organizers, date and venue of the conference/meeting, official language of the conference, the name of the person for contact, followed by email, webpage and information on conference materials. The review provides a clear and concise survey of the main objectives of the conference, names of keynote speakers and discussions of the participants on scientific achievements, research results and suggestions for further researches on key issues. The author of the review signs the text at the end. Together with the name of the reviewer, the institution affilitaion is given.

Other Important Information

The Editing Board reserves the right to return texts to authors which do not meet the guidelines criteria, or to fully adapt contributions to comply with the Journal editing rules and the standard Croatian language, i.e. the language of the article. Authors have to comply with all the editing and other guidelines provided by the Editorial Board.

In one issue of the Journal one author can publish not more than two articles.

Final decision on publication of an article, as well as the order of articles in the Jouranl is made by the Editorial Board.

The author receives a copy of the Journal where his contribution is published (one copy per contribution).

Contributions should be written in standard language free of spelling and grammar mistakes.

Copyright

Once the article has been accepted for publication, the author cannot publish it somewhere else without the permission of the Journal's Editorial Board, and even then the author will have to state where the article was published for the first time.

Authors guarantee that their paper represents an original contribution and that its publication will not infringe any existing copyright. By accepting contributions for publication, the publisher becomes the copyright holder, unless otherwise is stipulated by the agreement.

Manuscript Submission

After the topic has been accepted, papers are submitted in the paper form in three copies as well as in the electronic form (on a CD or via electronic mail) together with a completed form (a separate page) which contains the following information: title of the article, name and surname

of the author and co-author, and academic title, qualification, field of interest, i.e. field that the author deals with, name and address of the institution affiliation, telephone number, fax number, email address, and a signed Copyright Statement. All the information given should be written in the language of the article, in Croatian and in English (if the original language of the article is other than English)

Address for manuscript submission:

e-mail: zbornik@veleri.hr

VELEUČILIŠTE U RIJECI,

Zbornik Veleučilišta u Rijeci,

Vukovarska 58, 51 000 Rijeka

Information on the Journal of the Polytechnic of Rijeka (Zbornik Veleučilišta u Rijeci) can be obtained on the website of the Poytechnic of Rijeka: *http://www.veleri.hr*

EDITORIAL BOARD

RECENZENTI - REVIEWERS

Prof. dr. sc. Helena Blažić

Prof. dr. sc. Dragan Bubalo

Prof. dr. sc. Čedomir Dundović

Prof. dr. sc. Božidar Kliček

Prof. dr. sc. Dean Kružić

Prof. dr. sc. Sandra Lovrenčić

Prof. dr. sc. Sanda Martinčić-Ipšić

Prof. dr. sc. Klaudio Pap

Prof. dr. sc. Patrizia Poščić

Prof. dr. sc. Zlatko Puškadija

Prof. dr. sc. Slavomir Stankov

Prof. dr. sc. Ratko Zelenika

Izr. prof. dr. Žiga Čepar (Slovenija)

Izr. prof. dr. Maja Meško (Slovenija)

Doc. dr. sc. Željko Boneta

Doc. dr. sc. Bosiljka Britvić Vetma

Doc. dr. sc. Saša Drezgić

Doc. dr. sc. Ivana Đurđević

Doc. dr. sc. Ani Grubišić

Doc. dr. sc. Marina Ivašić-Kos

Doc. dr. sc. Jelena Jardas

Doc. dr. sc. Dionis Jurić

Doc. dr. sc. Marinela Krstinić Nižić

Doc. dr. sc. Božidar Kovačić

Doc. dr. sc. Zoran Levnajić (Slovenija)

Doc. dr. sc. Dina Lončarić

Doc. dr. sc. Marko Perić

Doc. dr. sc. Nataša Rupčić

Doc. dr. sc. Tomislav Senčić

Doc. dr. sc. Ana Štambuk

Doc. dr. sc. Ana-Marija Vrtodušić Hrgović

Dr. sc. Jasmina Dlačić

Dr. sc. Renata Erhatić

Dr. sc. Vladimir Glažar

Dr. sc. Goran Gregov

Dr. sc. Dario Iljkic

Dr. sc. Jonatan Lerga

Dr. sc. Sven Maričić

Dr. sc. Dijana Oreški

Dr. sc. Igor Pešić

Dr. sc. Dijana Plantak Vukovac

Dr. sc. Ines Pohajda