

# Predviđanje europskih i nacionalnih pokazatelja u gospodarenju biorazgradivim komunalnim otpadom korištenjem umjetnih neuronskih mreža

---

**Puntarić, Eda**

**Doctoral thesis / Disertacija**

**2022**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zagreb, Faculty of Agriculture / Sveučilište u Zagrebu, Agronomski fakultet**

*Permanent link / Trajna poveznica:* <https://um.nsk.hr/um:nbn:hr:204:662813>

*Rights / Prava:* [In copyright](#)/[Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja:* **2024-07-23**



*Repository / Repozitorij:*

[Repository Faculty of Agriculture University of Zagreb](#)





Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Eda Puntarić

**PREDVIĐANJE EUROPSKIH I  
NACIONALNIH POKAZATELJA U  
GOSPODARENJU BIORAZGRADIVIM  
KOMUNALNIM OTPADOM  
KORIŠTENJEM UMJETNIH  
NEURONSKIH MREŽA**

DOKTORSKI RAD

Zagreb, 2022.



University of Zagreb

FACULTY OF AGRICULTURE

Eda Puntarić

**PREDICTION OF EUROPEAN AND  
NATIONAL INDICATORS IN  
BIODEGRADABLE MUNICIPAL WASTE  
MANAGEMENT USING ARTIFICIAL  
NEURAL NETWORKS**

DOCTORAL DISSERTATION

Zagreb, 2022



Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Eda Puntarić

**PREDVIĐANJE EUROPSKIH I  
NACIONALNIH POKAZATELJA U  
GOSPODARENJU BIORAZGRADIVIM  
KOMUNALNIM OTPADOM  
KORIŠTENJEM UMJETNIH  
NEURONSKIH MREŽA**

DOKTORSKI RAD

Mentori:  
prof. dr. sc. Neven Voća  
dr. sc. Lato Pezo

Zagreb, 2022.



University of Zagreb

FACULTY OF AGRICULTURE

Eda Puntarić

**PREDICTION OF EUROPEAN AND  
NATIONAL INDICATORS IN  
BIODEGRADABLE MUNICIPAL WASTE  
MANAGEMENT USING ARTIFICIAL  
NEURAL NETWORKS**

DOCTORAL DISSERTATION

Supervisors:  
prof. dr. sc. Neven Voća  
dr. sc. Lato Pezo

Zagreb, 2022.

## **Bibliografski podaci:**

Znanstveno područje:	Biotehničke znanosti
Znanstveno polje:	Poljoprivreda (agronomija)
Znanstvena grana:	Ekologija i zaštita okoliša
Institucija:	Sveučilište u Zagrebu Agronomski fakultet
Voditelj doktorskog rada:	prof. dr. sc. Neven Voća dr. sc. Lato Pezo
Broj stranica:	204
Broj slika:	53
Broj tablica:	112
Broj priloga:	6
Broj literaturnih referenci:	177
Datum obrane doktorskog rada:	10. lipanj 2022.
Sastav povjerenstva za obranu doktorskog rada:	izv. prof. Željka Zgorelec prof. dr. sc. Jerko Gunjača doc. dr. sc. Dajana Kučić Grgić

Rad je pohranjen u:

Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, Ulica Hrvatske bratske zajednice 4 p.p. 550, 10 000 Zagreb,

Knjižnici Sveučilišta u Zagrebu Agronomskog Fakulteta, Svetošimunska cesta 25, 10 000 Zagreb.

Tema rada prihvaćena je na sjednici Fakultetskog vijeća Agronomskog Fakulteta Sveučilišta u Zagrebu, održanoj dana 13. travnja 2021. godine, te odobrena na 11. redovitoj sjednici Senata Sveučilišta u Zagrebu, održanoj dana 8. lipnja 2021. godine.

SVEUČILIŠTE U ZAGREBU  
AGRONOMSKI FAKULTET

**IZJAVA O IZVORNOSTI**

Ja, **Eda Puntarić**, izjavljujem da sam samostalno izradila doktorski rad pod naslovom:

**PREDVIĐANJE EUROPSKIH I NACIONALNIH POKAZATELJA U GOSPODARENJU  
BIORAZGRADIVIM KOMUNALNIM OTPADOM KORIŠTENJEM UMJETNIH  
NEURONSKIH MREŽA**

Svojim potpisom jamčim:

- da sam jedina autorica ovog doktorskog rada;
- da je doktorski rad izvorni rezultat mojeg rada te da se u izradi istog nisam koristila drugim izvorima osim onih koji su u njemu navedeni;
- da sam upoznata s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (čl. 19).

Zagreb, 10.06.2022. godine

---

*Potpis doktorandice*

## Ocjena doktorskog rada:

Povjerenstvo za ocjenu doktorske disertacije:

1. Prof. dr. sc. Željka Zgorelec, izvanredna profesorica Agronomskog fakulteta Sveučilišta u Zagrebu;
2. Prof. dr. sc. Jerko Gunjača, redoviti profesor u trajnom zvanju Agronomskog fakulteta Sveučilišta u Zagrebu;
3. Doc. dr. sc. Dajana Kučić Grgić, docentica na Fakultetu kemijskog inženjstva i tehnologije Sveučilišta u Zagrebu.

Disertacija je obranjena na Agronomskom fakultetu Sveučilišta u Zagrebu, 10. lipnja 2022. godine pred Povjerenstvom za obranu doktorskog rada u sastavu:

1. Prof. dr. sc. Željka Zgorelec, izvanredna profesorica Agronomskog fakulteta Sveučilišta u Zagrebu;

---

2. Prof. dr. sc. Jerko Gunjača, redoviti profesor u trajnom zvanju Agronomskog fakulteta Sveučilišta u Zagrebu;

---

3. Doc. dr. sc. Dajana Kučić Grgić, docentica na Fakultetu kemijskog inženjstva i tehnologije Sveučilišta u Zagrebu.

---



## Informacije o mentorima:

### Mentor: Prof.dr.sc. Neven Voća

Neven Voća rođen je 10. travnja 1973. u Zagrebu, gdje je završio osnovnu i srednju školu. Agronomski fakultet Sveučilišta u Zagrebu, smjer mehanizacija poljoprivrede, upisao je 1992. godine, a diplomirao je 1997. godine. Zapošljava se 1999. godine na Agronomskom fakultetu u Zagrebu na Zavodu za poljoprivrednu tehnologiju, skladištenje i transport, kao mlađi asistent. Iste godine upisuje poslijediplomski studij, na smjeru Mehanizacija poljoprivrede, a magistarski rad naslova "*Agrarni modeli proizvodnje biodizelskoga goriva*" obranio je 17.01.2003. Doktorsku disertaciju pod naslovom: "*Utjecaj uparavanja na fizikalno-kemijska svojstva zrna kukuruza u procesu proizvodnje etanola*", obranio je 2. ožujka 2007. godine na istom fakultetu.

U znanstveno zvanje znanstveni suradnik izabran je 26. ožujka 2008., viši znanstveni suradnik 13. srpnja 2010., i znanstveni savjetnik 13. srpnja 2012. godine. U znanstveno-nastavno zvanje docenta izabran je 21. svibnja 2008., izvanrednog profesora 21. ožujka 2012., a redovitog profesora 19. rujna 2017. godine.

Kao autor i koautor objavio je 154 znanstvena i stručna rada od kojih su 48 u a1 bazi podataka, 46 u a2 bazi i 60 radova na međunarodnim znanstvenim skupovima. Kao koautor je napisao poglavlje "Tehnologije vaganja" u knjizi "Priručnik o proizvodnji i upotrebi stočne hrane-krme" te je koautor sveučilišnog priručnika "Pojmovnik bioplina", "Uzgoj i korištenje Miskantusa" i "Tehnologija uzgoja, dorade i skladištenja energetske kulture Sida hermaphrodita (L.) Rusby". Bio je voditelj 58 diplomskih ili završnih radova, voditelj jednog magistarskog i tri doktorska rada. Vodio je tri međunarodna projekta i to bilateralni znanstveni projekt između Hrvatske i Srbije "Mogućnosti proizvodnje peleta za energiju iz vinske komine i komine masline" (2011-2012), Eureka znanstveni projekt "UMEG – Utilization of marc for energy generation" (2006-2010) i projekt Erasmus+ "Zero food waste education of "Z" generation of European citizens" (2021-2024). Vodio je domaći VIP projekt Ministarstva poljoprivrede, ribarstva i ruralnog razvoja RH "Korištenje vinske komine u svrhu proizvodnje toplinske energije" (2008-2010) i znanstveni projekt Hrvatske zaklade za znanost "Zbrinjavanje mulja kroz proizvodnju energetskih kultura" (2018-2022).

Znanstveno se usavršavao na Scoula di Management Gorizia u Italiji (1999) te na Kansas State University u SAD-u (2003). Bio je vanjski član Odbora za zaštitu okoliša Hrvatskog sabora (2008-2011), znanstveni tajnik Znanstvenog vijeća za zaštitu prirode HAZU (2011-2015), ravnatelj Agencije za zaštitu okoliša (2012-2015) te član Upravnog vijeća Europske agencije za okoliš (2012-2015).

## **Mentor: dr.sc. Lato Pezo**

Lato Pezo rođen je 3. kolovoza 1971. godine u Novom Sadu, Srbija. Strojarski fakultet Sveučilišta u Beogradu (Mašinski fakultet Univerziteta u Beogradu) upisao je 1989. godine. Diplomirao je 1994. godine na katedri za Automatsko upravljanje.

U Institutu za opštu i fizičku hemiju u Beogradu, zaposlio se 1994. godine te je postavljen na mjesto istraživača pripravnika gdje je radio na razvijanju tehnologija i implementaciji postrojenja u području prehrambene tehnologije, procesne tehnike, silikatne kemije i ekologije sa posebnim naglaskom na izradi matematičkih modela ovih postrojenja.

Iste godine upisuje poslijediplomski studij na strojarskom fakultetu u Beogradu (Mašinski fakultet Univerziteta u Beogradu), a 1997. godine brani magisterski rad naslova "*Procesi sušenja i dinamička analiza diskontinualne vakuumske sušare*". Iste godine stječe zvanje Istraživač suradnik na strojarskom fakultetu u Beogradu (Mašinski fakultet Univerziteta u Beogradu). Doktorsku disertaciju pod naslovom: "*Matematičko modeliranje, simulacija i identifikacija diskontinualne atmosferske sušare*" odbranio je 1999. godine na istom fakultetu nakon čega je u znanstveno zvanje znanstveni suradnik izabran 06. lipnja 2001. godine, dok je 29. travnja 2015. godine izabran u znanstveno zvanje viši znanstveni suradnik na istom fakultetu.

Glavno područje interesa može se sažeti u područje matematičkog modeliranja, numeričke simulacije i optimizacije parametara u okviru prehrambene tehnologije, procesne tehnike, novih materijala i zaštite okoliša.

Kao autor i koautor objavio je nekoliko znanstvenih publikacija, kao i nekoliko tehničkih rješenja. Rezultati dosadašnjih istraživanja objavljeni su u preko 300 znanstvenih radova, sažetaka i tehničkih rješenja, od čega više od 250 u znanstvenim časopisima međunarodnog značaja.

Uz navedeno, vodio je projekt Ministarstva prosvete, nauke i tehnološkog razvoja (u periodu od 2005-2007 godine), dodatno je sudjelovao kao voditelj projektnog zadatka na dva projekta. Sudjelovao je u radu više komisija za odbranu doktorata (15 doktorata) kao i u pripremi doktorskih teza mladih doktoranata i pisanju znanstvenih radova. Također je sudjelovao u komisijama za izbor u zvanje „istraživač suradnik“ (2 komisije) i u zvanje „znanstveni suradnik“ (5 komisija). Uz navedeno uradio je preko 200 recenzija za visokokotirane znanstvene časopise.

## Zahvala

*“Nitko od nas nije stigao tamo gdje smo sami. Bez obzira je li pomoć koju smo dobili bila očita ili suptilna, priznavanje nečije pomoći velik je dio razumijevanja važnosti zahvaljivanja.”*

*(Harvey Mackay)*

*Prvenstveno se zahvaljujem prof.dr.sc. Nevenu Voći i dr.sc. Lati Pezi na mentorstvu i stručnom vodstvu tijekom studija te nesebičnoj pomoći tijekom izrade doktorske disertacije. Hvala na neizmjernom strpljenju, prenošenju znanja, iskustava i ideja bez kojih ovaj doktorski rad ne bi bio to što je sada. Hvala što ste ovaj veliki korak u mom životu svojim savjetima učinili jednostavnijim.*

*Zahvalu upućujem i članovima povjerenstva za ocjenu doktorskoj rada na svim konstruktivnim kritikama i savjetima, dobronamjernoj pomoći i ljudskosti te ugodnoj suradnji.*

*Posebna zahvala mojim najbližim, mami, tati, sestrama Ildi i Adi te mom Hrvoju, što su sa mnom proživljavali sve obaveze i uspjehe tokom studija te me pratili na putu prema stjecanju zvanja doktora znanosti. Hvala na strpljenju i razumijevanju zbog mojih čestih odsutnosti duhom i tijelom za vrijeme istraživačkog rada i pisanja doktorske disertacije. Hvala na stalnom iskazivanju interesa oko doktorata. Hvala na trudu oko čitanja rada te savjetima. Hvala na moralnoj potpori i savjetima oko prezentacije. Hvala i za svim buketama tokom studija i drugim znakovima pažnje koji su me poticali da ne odustajem do zadanog cilja. Važno je imati maleni krug velikih ljudi...*

## SAŽETAK

Kontinuiranim povećanjem broja stanovnika dolazi i do povećanja proizvodnje otpada. Isto tako, uz gospodarski rast i, povezano s time, poboljšavanja životnog standarda, također, dolazi do povećanja proizvodnje otpada. Stoga, ne čudi da sve veće količine otpada koje svake godine nastaju uzrokuju opravdanu zabrinutost zbog ekonomske održivosti i ekološke prihvatljivosti trenutnog načina gospodarenja otpadom. Glavni problem s kojim se suočava stručna i znanstvena javnost je kako predvidjeti količinu otpada koja će nastati u bliskoj budućnosti. Planiranje optimalne regionalne ili nacionalne strategije gospodarenja otpadom usko je povezano s količinom otpada koja će nastati. Za rješavanje navedenih problema pokazuje se potreba za kreiranjem pouzdanog modela za predviđanje količine nastalog otpada. Na temelju dosadašnjih istraživanja, umjetne neuronske mreže pokazuju bolje rezultate kod predviđanja nastanka otpada u usporedbi s drugim matematičkim modelima, stoga u ovom istraživanju koristit će se upravo umjetne neuronske mreže kao alat za razvoj matematičkog modela za predviđanje količina nastalog biorazgradivoga komunalnog otpada na europskoj i nacionalnoj razini. U ovom istraživanju poseban naglasak stavljen je na razvoj modela za predviđanje nastanka biorazgradivoga komunalnog otpada. Proučavanje biorazgradivoga komunalnog otpada od posebnog je interesa jer se upravo kod ove vrste otpada vidi veliki potencijal za njegovo relativno jednostavno i jeftino iskorištavanje, i to u vidu sirovine za dobivanje komposta pogodnog za daljnje korištenje u poljoprivredi ili u vidu ulazne sirovine u bioplinskim postrojenjima.

Za kreiranje umjetne neuronske mreže u ovom doktorskom radu ulazne podatke činio je set sociodemografskih, ekonomskih i industrijskih podataka 17 država članica Europske unije za razdoblje od 25 godina. Kreiranim modelom u ovom doktorskom radu željele su se predvidjeti količine promatranih vrsta otpada koje će nastati na području 17 država Europske unije u razdoblju od 2020. do 2025. godine. Uz samo kreiranje mreže za predviđanje količina komponenti biorazgradivog otpada, cilj je istražiti i utjecaj sociodemografskih i ekonomskih pokazatelja na količine biorazgradivoga komunalnog otpada. Prema razvijenom modelu od 2020. do 2025. godine očekuje se da će u 17 država Europske unije nastati 411.351.769 tona miješanoga komunalnog otpada (u sklopu kojeg će nastati i 81.776.732 tona biootpada), 90.280.031 tona papira i kartona, 35.926.182 tona otpadnog drva i 3.511.589 tona tekstilnog otpada. Rezultati ovog istraživanja pokazuju kako na sve četiri promatrane vrste komunalnog otpada pozitivno utječu parametri kao što su broj stanovnika, bruto domaći proizvod po tržišnim cijenama, srednji ekvivalent neto prihoda, turizam, izvoz nafte i naftnih derivata i neto vanjski dug. S druge strane, životni vijek, realni BDP po stanovniku, ukupne obveze financijskog sektora i uvoz roba i usluga negativno utječu na sve četiri vrste otpada. Zaključno se može reći da iako je Europska unija heterogena zajednica i bez obzira na poteškoće u pronalasku što ažurnijih podataka o otpadu, kreiran model pokazao je zadovoljavajuća svojstva i mogućnosti u predviđanju količina miješanoga komunalnog otpada, otpadnog papira, drva i tekstila. Rezultati istraživanja mogu poslužiti kao pomoć pri uspostavi ekonomičnijeg i ekološki prihvatljivijeg načina gospodarenja biorazgradivim otpadom.

**Ključne riječi:** umjetna inteligencija, procjenjivanje količina, nastanak otpada, gospodarenje otpadom, utjecaj na okoliš, Europa

## EXTENDED ABSTRACT

### Prediction of European and national indicators in biodegradable municipal waste management using artificial neural networks

The increasing amounts of waste generated each year raise legitimate concerns about the economic viability and environmental sustainability of the current way of waste management. The main problem facing professionals and academics is predicting the amounts of waste that will be generated in the near future. Planning an optimal regional or national waste management strategy is closely linked to the amount of waste that will be generated. To solve these problems, a reliable model for predicting the amount of waste needs to be developed. Such a tool should make it possible to select the most appropriate waste management technique. Based on previous research, artificial neural networks show better results in predicting waste generation compared to other mathematical models. Therefore, in this research, artificial neural networks are used as a tool to develop models for predicting the amount of biodegradable municipal waste at European and national level.

This doctoral thesis is divided into 5 basic thematic units. It begins with an introduction in which the reader is briefly introduced to the main topics such as waste and artificial neural networks. It also defines the research area and the main objectives and hypotheses. For example, the introduction clearly explains that there are two main objectives of the research. The first objective is to develop a mathematical model for predicting the amounts quantities of components of biodegradable waste using artificial neural networks with the aim of applying it at European and national level. The second objective is to predict the impact of socio-demographic, economic and industrial indicators on the amount of biodegradable waste using artificial neural networks.

The introduction is followed by a review of previous literature. In this chapter, the concepts of municipal waste, biodegradable waste and artificial neural networks are explained in more detail. Research conducted by other authors to date is also presented and explained in detail. They refer to the parameters that influence waste generation, as well as research that has dealt with the creation of mathematical models and their success in predicting waste generation. An additional significance of this research lies in the scale of the research. To date, artificial neural networks have been used to make predictions on a smaller local or regional scale. This usually covers the area of a particular city, state or group of closely related states. The aim of this research is to investigate the accuracy of a model with large-scale data (17 countries of the European Union).

In the Materials and Methods chapter, the methodological approach and the way of creating a mathematical model are explained. To develop the model, demographic data (population, life expectancy, educational attainment), economic progress data (gross domestic product at market prices, gross domestic product per capita, total financial sector liabilities, net external debt, nominal effective exchange rate, direct investment in the reporting economy, house price index, data on the number of (non-)employed persons (total number of employed persons, unemployment rate, youth unemployment rate), tourism data (arrivals in tourist accommodation facilities, number of nights spent in tourist accommodation facilities), trade data (imports of goods and services, exports of goods and services, exports of oil and petroleum products) and waste data (annual municipal waste generation in thousands of tonnes, municipal waste generation per capita, municipal waste recycling rate, waste disposal) were collected. All data were collected for a period of 25 years for 17 countries of the European Union: Belgium, the Czech Republic, Denmark, Estonia, France, Croatia, Ireland, Italy, Latvia, Lithuania, Luxembourg, Hungary, Malta, the Netherlands, Slovenia, Spain and Sweden.

In this research, the Multi-Layer Perceptron (MLP) model was used, which consists of a total of three layers: input, hidden layer and output. Before starting to compute the model, the database

of collected data was divided into data for learning (60% of the data), for verification (20%) and for testing the neural network (20 %). Numerical verification of the obtained artificial neural network model was tested using the coefficient of determination ( $r^2$ ), reduced chi-squared ( $\chi^2$ ), mean bias error (MBE), root mean square error (RMSE), mean percentage error (MPE), sum of squares error (SSE) and average absolute relative deviation (AARD). The constructed neural network model showed promising generalisation properties for the collected database and could be used to accurately predict waste generation: 20 networks, the maximum values of  $r^2$  (during the training cycle,  $r^2$  for the output variables (mixed municipal waste, municipal waste paper and cardboard, wood and textiles) were: 0.999, 0.998, 0.997 and 0.998).

The results obtained show that artificial neural networks are indeed a reliable tool to create a mathematical model to predict the amount of biodegradable municipal waste at European and national level. The actual accuracy of the results of this research in terms of waste generation in the 17 countries observed will be verified when the data on waste generation for the year 2020 becomes available.

In addition to creating a network to predict the quantities of biodegradable waste components, the influence of socio-demographic, economic and industrial indicators on the quantities of municipal biodegradable waste generated was also observed. Of the 28 input data, 10 input factors have a positive influence on all 4 observed waste types, while 4 input factors have a negative influence on all 4 observed waste types. Other observed factors (such as foreign direct investment, annual unemployment rate data, exports of goods and services and education) did not yield results from which a single conclusion could be drawn. From the above, it is clear that the accuracy of predicting the amount of biodegradable waste using artificial neural networks really depends on the choice of socio-demographic, economic and industrial indicators.

For further studies to be carried out, it is proposed to use parameters such as population, gross domestic product at market prices, mean net income equivalent, tourism, exports of oil and petroleum products and net foreign debt, as these parameters positively influence all four types of municipal waste observed. On the other hand, life expectancy, real GDP per capita, total financial sector liabilities and imports of goods and services have a negative impact on all four types of waste. The results of this study are in line with the studies conducted so far, according to which the generation of municipal waste is mainly influenced by GDP, tourism, population and wages. Depending on changes in these factors, the amount of waste generated also changes. The model created can help the waste management system behave like a "living organism". In this flexible way, the waste management system could change in parallel with social and economic changes. This would make municipal waste management more efficient and economical, with less impact on the environment.

**Keywords: artificial intelligence, estimating quantities, waste generation, waste management, environmental impact, Europe**

## SADRŽAJ:

1. UVOD .....	1
1.1. Ciljevi i hipoteze istraživanja .....	3
2. PREGLED DOSADAŠNJE LITERATURE.....	4
2.1. Otpad.....	4
2.1.1. Kategorizacija otpada .....	7
2.1.2. Biorazgradivi komunalni otpad .....	11
2.1.3. Biootpad .....	15
2.1.4. Količine komunalnog otpada u Europskoj uniji .....	17
2.1.5. Količine komunalnog otpada u Hrvatskoj .....	19
2.1.6. Parametri koji utječu na količine nastaloga komunalnog otpada.....	21
2.1.7. Predviđanje nastanka komunalnog otpada .....	24
2.2. Umjetne neuronske mreže .....	29
2.2.1. Razvoj i primjena umjetnih neuronskih mreža .....	29
2.2.2. Arhitektura umjetnih neuronskih mreža .....	31
2.2.3. Glavna obilježja umjetnih neuronskih mreža .....	32
2.2.4. Vrste umjetnih neuronskih mreža i pravila učenja .....	33
2.2.5. Kreiranje umjetne neuronske mreže .....	35
3. MATERIJALI I METODE .....	37
3.1. Metodološki pristup.....	37
3.2. Osnovni koraci pri kreiranju matematičkog modela korištenjem umjetnih neuronskih mreža specifičnih za ovo istraživanje.....	41
3.3. Matematički model za predviđanje ulaznih podataka za razdoblje od 2020. do 2025. godine (ANN2).....	45
3.4. Točnost matematičkog modela .....	46
3.5. Ograničenja prikupljenih podataka .....	47
4. REZULTATI .....	49
4.1. Matematički model za predviđanje četiriju frakcija biorazgradivoga komunalnog otpada od 2020. do 2025. godine .....	49
4.2. Matematički model za predviđanje ulaznih podataka za razdoblje od 2020. do 2025. godine (ANN2).....	52
4.3. Rezultati predviđanja socioekonomskih pokazatelja za razdoblje od 2020. do 2025. godine .....	54
4.3.1. Broj stanovnika .....	54
4.3.2. Životni vijek.....	58
4.3.3. BDP po tržišnim cijenama .....	59

4.3.4.	BDP po stanovniku .....	61
4.3.5.	Ukupne obveze financijskog sektora .....	62
4.3.6.	Neto vanjski dug .....	64
4.3.7.	Nominalni efektivni tečaj .....	65
4.3.8.	Inozemna izravna ulaganja .....	66
4.3.9.	Harmonizirani indeks cijene stambenih objekata.....	67
4.3.10.	Ukupno zaposleni .....	68
4.3.11.	Godišnji podaci o stopi nezaposlenosti .....	70
4.3.12.	Stopa nezaposlenosti mladih .....	71
4.3.13.	Srednji ekvivalent neto prihoda .....	72
4.3.14.	Uvoz roba i usluga .....	73
4.3.15.	Izvoz roba i usluga.....	74
4.3.16.	Izvoz nafte i naftnih derivata .....	75
4.3.17.	Obrazovanje .....	77
4.3.18.	Dolasci u turističke smještajne objekte.....	82
4.3.19.	Noćenja u turističkim smještajnim objektima .....	84
4.3.20.	Nastali komunalni otpad.....	85
4.3.21.	Količina nastalog otpada po stanovniku .....	87
4.3.22.	Stopa recikliranja komunalnog otpada .....	88
4.3.23.	Odlaganje komunalnog otpada .....	89
4.3.24.	Miješani komunalni otpad i biootpad kao dio miješanoga komunalnog otpada .	90
4.3.25.	Papir i karton.....	94
4.3.26.	Drvo.....	98
4.3.27.	Tekstil .....	102
4.4.	Analiza glavnih komponenti (engl. <i>Principal Component Analysis</i> – PCA) .....	104
4.4.1.	PCA – grupa ekonomskih pokazatelja .....	104
4.4.2.	PCA – grupa pokazatelja zaposlenosti i zarade.....	105
4.4.3.	PCA – grupa pokazatelja obrazovanja.....	106
4.4.4.	PCA – grupa pokazatelja o otpadu .....	108
4.4.5.	PCA – grupa pokazatelja biorazgradivoga komunalnog otpada .....	109
5.	RASPRAVA .....	110
5.1.	Utjecaj ulaznih varijabli na stvaranje otpada.....	110
1.	Broj stanovnika .....	110
2.	Životni vijek.....	110
3.	Ekonomski pokazatelji .....	111



4.	Zaposlenost i zarada.....	115
5.	Vanjska trgovina .....	117
6.	Obrazovanje .....	119
7.	Turizam.....	120
8.	Podaci o otpadu.....	121
5.2.	Potvrđivanje postavljenih ciljeva i hipoteza .....	124
5.3.	Ograničenja provedenog istraživanja i prijedlozi za buduća istraživanja.....	125
6.	ZAKLJUČAK .....	127
7.	POPIS LITERATURE:.....	129
8.	ŽIVOTOPIS.....	144
9.	PRILOZI.....	146
	Prilog 1: Popis ključnih brojeva koji spadaju u komunalni otpad .....	146
	Prilog 2: Podaci korišteni za razvoj mreže .....	148
	Prilog 3: Elementi matrice $W_1$ i vektora $B_1$ i matrice $W_2$ i vektora $B_2$ za kreiranje matematičkog modela ANN1 .....	180
	Prilog 4: Elementi matrice $W_1$ i vektora $B_1$ i matrice $W_2$ i vektora $B_2$ za kreiranje matematičkog modela ANN2 .....	183
	Prilog 5: Statistički pokazatelji za model ANN2.....	200
	Prilog 6: Utjecaj ulaznih varijabli na izlazne vrijednosti .....	201

## POPIS KRATICA:

BDP – bruto domaći proizvod

BFGS algoritam – Broyden-Fletcher-Goldfarb-Shanno algoritam

EE otpad – električni i elektronički otpad

EU – Europska unija

ISCED – Međunarodna standardna klasifikacija obrazovanja (engl. *International Standard Classification of Education*)

LoW – engl. *List of Waste*

MLR – višestruka linearna regresija (engl. *multi-layer perceptron*)

PCA – analiza glavnih komponenti (engl. *principal component analysis*)

SS – suma kvadrata (engl. *Sum of squares*)

## POPIS TABLICA:

Tablica 1. Popis grupa otpada.....	8
Tablica 2. Popis svojstva otpada koja ga čine opasnim.....	9
Tablica 3. Prosječan sastav komunalnog otpada u EU-u .....	12
Tablica 4. Procijenjeni sastav miješanoga komunalnog otpada u RH.....	12
Tablica 5. Nastali i odloženi biorazgradivi komunalni otpad u RH, 1997. – 2019 .....	14
Tablica 6. Popis korištenih kratica i pripadajuća objašnjenja .....	39
Tablica 7. Sažetak matematičkog modela umjetne neuronske mreže (performanse i pogreške) za faze učenja, testiranja i provjere valjanosti .....	49
Tablica 8. Testovi „dobrog uklapanja“ za kreirani matematički model.....	50
Tablica 9. Testovi „dobrog uklapanja“ za razvijeni matematički model .....	51
Tablica 10. Pregled rezultata rada višeslojne neuronske mreže (performanse i greške) za cikluse učenja (treninga), testiranja i validacije mreže.....	53
Tablica 11. Broj stanovnika i količine nastalog miješanoga komunalnog otpada, papira i kartona, otpada od drva i tekstilnog otpada u 2018. godini .....	57
Tablica 12. Prikaz predviđenog neto vanjskog duga u 17 država EU-a od 2020. do 2025. godine .....	64
Tablica 13. Prikaz predviđenog nominalnog efektivnog tečaja u 17 država EU-a od 2020. do 2025. godine.....	65
Tablica 14. Prikaz predviđenih vrijednosti za inozemna izravna ulaganja 17 država EU-a od 2020. do 2025. godine .....	66
Tablica 15. Prikaz predviđenih iznosa harmoniziranog indeksa cijene stambenih objekata u 17 država EU-a od 2020. do 2025. godine.....	67
Tablica 16. Prikaz predviđenih godišnjih podataka o stopi nezaposlenosti u 17 država EU-a od 2020. do 2025. godine. ....	70
Tablica 17. Prikaz predviđenih stopa nezaposlenih mladih u 17 država EU-a od 2020. do 2025. godine.....	71

Tablica 18. Prikaz predviđenih količina izvoza nafte i naftnih derivata u 17 država EU-a od 2020. do 2025. godine .....	75
Tablica 19. Prikaz predviđenih količina nastaloga komunalnog otpada po stanovniku (kg/stanovnik) u 17 država EU-a od 2020. do 2025. godine. ....	87
Tablica 20. Prikaz predviđenih količina odloženoga komunalnog otpada (u tisućama tona) u 17 promatranih država EU-a od 2020. do 2025. godine .....	89
Tablica 21. Predviđena količina miješanoga komunalnog otpada koja će nastati od 2020. do 2025. godine prikazana u tisućama tona.....	92
Tablica 22. Količine papira i kartona, kuhinjskog otpada i vrtnog (zelenog) otpada koje nisu odvojeno sakupljene, već čine dio miješanoga komunalnog otpada.....	94
Tablica 23. Predviđena količina papira i kartona koja će nastati od 2020. do 2025. godine prikazana u tisućama tona .....	95
Tablica 24. Predviđena količina otpadnog drva koja će nastati od 2020. do 2025. godine prikazana u tisućama tona.....	99
Tablica 25. Prikaz predviđenih količina tekstilnog otpada koje će nastati u 17 država EU-a od 2020. do 2025. godine, prikazano u tisućama tona .....	102
Tablica 26. Popis ključnih brojeva koji spadaju u komunalni otpad.....	146
Tablica 27. Podaci o broju stanovnika korišteni za razvoj umjetne neuronske mreže .....	148
Tablica 28. Podaci o životnom vijeku (god.) korišteni za razvoj umjetne neuronske mreže .	149
Tablica 29. Podaci o BDP-u po tržišnim cijenama (milijun eura) korišteni za razvoj umjetne neuronske mreže .....	150
Tablica 30. Podaci o BDP-u po stanovniku (euro po stanovniku) korišteni za razvoj umjetne neuronske mreže .....	151
Tablica 31. Podaci o ukupim obvezama financijskog sektora (kao postotak BDP-a) korišteni za razvoj umjetne neuronske mreže .....	152
Tablica 32. Podaci o neto vanjskom dugu (kao postotak BDP-a) korišteni za razvoj umjetne neuronske mreže .....	153
Tablica 33. Podaci o nominalnom efektivnom tečaju (kao postotna promjena) korišteni za razvoj umjetne neuronske mreže.....	154
Tablica 34. Podaci o inozemnim izravnim ulaganjima (kao postotak BDP-a) korišteni za razvoj umjetne neuronske mreže.....	155
Tablica 35. Podaci o harmoniziranim indeksima cijene stambenih objekata (kao prosječna godišnja stopa promjene) korišteni za razvoj umjetne neuronske mreže .....	156
Tablica 36. Podaci o ukupnom broju zaposlenih ljudi u dobi od 15 do 64 godine (broj zaposlenih u tisućama) korišteni za razvoj umjetne neuronske mreže .....	157
Tablica 37. Podaci o stopi nezaposlenosti (%) korišteni za razvoj umjetne neuronske mreže	158
Tablica 38. Podaci o stopi nezaposlenosti mladih (%) korišteni za razvoj umjetne neuronske mreže.....	159
Tablica 39. Podaci o srednjem ekvivalentu neto prihoda (euro) korišteni za razvoj umjetne neuronske mreže .....	160
Tablica 40. Podaci o uvozu roba i usluga (u milijunima eura) u 17 država EU-a od 1995. do 2019. korišteni za razvoj umjetne neuronske mreže .....	161
Tablica 41. Podaci o izvozu roba i usluga (u milijunima eura) u 17 država EU-a od 1995. do 2019. korišteni za razvoj umjetne neuronske mreže .....	162
Tablica 42. Podaci o izvozu nafte i naftnih derivata (u milijunima tona) u 17 država EU-a od 1995. do 2019. korišteni za razvoj umjetne neuronske mreže.....	163

Tablica 43. Postotak stanovništva sa završenim osnovnoškolskim i nižim srednjoškolskim obrazovanjem u 17 država EU-a od 1995. do 2019. ....	164
Tablica 44. Postotak stanovništva sa završenim srednjoškolskim ili višim obrazovanjem u 17 država EU-a od 1995. do 2019. ....	165
Tablica 45. Postotak stanovništva koji imaju završeno srednjoškolsko obrazovanje ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje u 17 država EU-a od 1995. do 2019. ....	166
Tablica 46. Postotak stanovništva koji ima visoko obrazovanje u 17 država EU-a od 1995. do 2019. ....	167
Tablica 47. Dolasci u turističke smještajne objekte u Belgiji, Hrvatskoj, Češkoj, Danskoj, Estoniji, Francuskoj, Mađarskoj, Irskoj, Italiji i Latviji od 1995. do 2019. godine .....	168
Tablica 48. Dolasci u turističke smještajne objekte u Litvi, Luksemburgu, Malti, Nizozemskoj, Sloveniji, Španjolskoj i Švedskoj od 1995. do 2019. ....	169
Tablica 49. Noćenja u turističkim smještajnim objektima u Belgiji, Hrvatskoj, Češkoj, Danskoj, Estoniji, Francuskoj, Mađarskoj, Irskoj, Italiji i Latviji od 1995. do 2019. godine .....	170
Tablica 50. Noćenja u turističkim smještajnim objektima u Litvi, Luksemburgu, Malti, Nizozemskoj, Sloveniji, Španjolskoj i Švedskoj od 1995. do 2019. ....	171
Tablica 51. Godišnje količine nastaloga komunalnog otpada (prikaz u tisućama tona) u 17 promatranih država EU-a od 1995. do 2019. ....	172
Tablica 52. Količina komunalnog otpada (kg) po stanovniku u 17 država EU-a od 1995. do 2019. godine .....	173
Tablica 53. Stopa recikliranja komunalnog otpada u 17 promatranih država EU-a od 1995. do 2019. godine .....	174
Tablica 54. Ukupna količina odloženoga komunalnog otpada (u tisućama tona) u 17 država EU-a od 1995. do 2019. godine .....	175
Tablica 55. Količine nastalog miješanoga komunalnog otpada (u tisućama tona) u 17 država EU-a od 1995. do 2019. godine .....	176
Tablica 56. Količine nastalog papira i kartona (prikaz u tisućama tona) u 17 država EU-a ..	177
Tablica 57. Količine nastalog otpadnog drva (prikaz u tisućama tona) u 17 država EU-a ....	178
Tablica 58. Količine nastalog otpadnog tekstila (prikaz u tisućama tona) u 17 država EU-a	179
Tablica 59. Elementi matrice $W_1$ i vektora $B_1$ (prikazani u retku pristranosti) za matematički model ANN1 .....	180
Tablica 60. Elementi matrice $W_2$ i vektora $B_2$ (prikazani u stupcu pristranosti) za matematički model ANN1 .....	182
Tablica 61. Elementi matrice $W_1$ i vektora $B_1$ za varijablu $c$ .....	183
Tablica 62. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Broj stanovnika“ .....	183
Tablica 63. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Očekivani životni vijek“ .....	183
Tablica 64. Elementi matrice $W_2$ i vektora $B_2$ varijablu „Očekivani životni vijek“ .....	184
Tablica 65. Elementi matrice $W_1$ i vektora $B_1$ za varijablu koja označava osnovnoškolsko i niže srednjoškolsko obrazovanje .....	184
Tablica 66. Elementi matrice $W_2$ i vektora $B_2$ za varijablu koja označava osnovnoškolsko i niže srednjoškolsko obrazovanje .....	184
Tablica 67. Elementi matrice $W_1$ i vektora $B_1$ za varijablu koja označava srednjoškolsko ili više obrazovanje .....	184
Tablica 68. Elementi matrice $W_2$ i vektora $B_2$ za varijablu koja označava srednjoškolsko ili više obrazovanje .....	185

Tablica 69. Elementi matrice $W_1$ i vektora $B_1$ za varijablu koja obuhvaća sve stanovnike koji imaju završeno srednjoškolsko obrazovanje ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje .....	185
Tablica 70. Elementi matrice $W_2$ i vektora $B_2$ za EL3.....	186
Tablica 71. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Visoko obrazovanje“ .....	186
Tablica 72. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Visoko obrazovanje“ .....	186
Tablica 73. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „BDP po tržišnim cijenama“ .....	186
Tablica 74. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „BDP po tržišnim cijenama“ .....	187
Tablica 75. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „BDP po stanovniku“ .....	187
Tablica 76. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „BDP po stanovniku“ .....	188
Tablica 77. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Ukupne obveze financijskog sektora“ .....	188
Tablica 78. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Ukupne obveze financijskog sektora“ .....	188
Tablica 79. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Neto vanjski (inozemni) dug“ .....	188
Tablica 80. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Neto vanjski (inozemni) dug“ .....	189
Tablica 81. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Nominalni efektivni tečaj“ .....	189
Tablica 82. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Nominalni efektivni tečaj“ .....	189
Tablica 83. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Inozemna izravna ulaganja“ .....	190
Tablica 84. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Inozemna izravna ulaganja“ .....	190
Tablica 85. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Ukupno zaposleni“ .....	190
Tablica 86. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Ukupno zaposleni“ .....	191
Tablica 87. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Godišnji podaci o stopi nezaposlenosti“ .....	191
Tablica 88. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Godišnji podaci o stopi nezaposlenosti“ .....	191
Tablica 89. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Stopa nezaposlenosti mladih“ ...	191
Tablica 90. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Stopa nezaposlenosti mladih“ ...	192
Tablica 91. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Srednji ekvivalent neto prihoda“	192
Tablica 92. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Srednji ekvivalent neto prihoda“	193
Tablica 93. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Dolasci u turističke smještajne objekte“ .....	193
Tablica 94. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Dolasci u turističke smještajne objekte“ .....	193
Tablica 95. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Noćenja u turističkim smještajnim objektima“ .....	193
Tablica 96. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Noćenja u turističkim smještajnim objektima“ .....	194
Tablica 97. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Uvoz roba i usluga“ .....	194
Tablica 98. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Uvoz roba i usluga“ .....	194
Tablica 99. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Izvoz roba i usluga“ .....	195
Tablica 100. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Izvoz roba i usluga“ .....	195
Tablica 101. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Izvoz nafte i naftnih derivata po zemljama partnerima“ .....	195
Tablica 102. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Izvoz nafte i naftnih derivata po zemljama partnerima“ .....	196
Tablica 103. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Deflacionirane cijene nekretnina“	196

Tablica 104. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Deflacionirane cijene nekretnina“	196
Tablica 105. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Stopa recikliranja komunalnog otpada“	196
Tablica 106. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Stopa recikliranja komunalnog otpada“	197
Tablica 107. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Odlaganje komunalnog otpada“	197
Tablica 108. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Odlaganje komunalnog otpada“	198
Tablica 109. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Nastali komunalni otpad - kilogram po stanovniku“	198
Tablica 110. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Nastali komunalni otpad - kilogram po stanovniku“	198
Tablica 111. Elementi matrice $W_1$ i vektora $B_1$ za varijablu „Nastali komunalni otpad – prikaz u tisućama tona“	198
Tablica 112. Elementi matrice $W_2$ i vektora $B_2$ za varijablu „Nastali komunalni otpad – prikaz u tisućama tona“	199

## POPIS SLIKA:

Slika 1. Hijerarhija gospodarenja otpadom.....	5
Slika 2. Nastali i odloženi biorazgradivi komunalni otpad u Republici Hrvatskoj u razdoblju od 1997. do 2020.....	13
Slika 3. Količina komunalnog otpada u 2019. godini u državama članicama EU-a.....	18
Slika 4. Količine ukupno nastaloga komunalnog otpada u RH od 1995. do 2020. godine.....	20
Slika 5. Godišnje količine nastaloga komunalnog otpada po stanovniku u Republici Hrvatskoj i EU-u, od 1995. do 2019. godine.....	20
Slika 6. Vremenski razvoj umjetnih neuronskih mreža.....	30
Slika 7. Arhitektura umjetnog neurona.....	31
Slika 8. Arhitektura višeslojne umjetne neuronske mreže.....	32
Slika 9. Grafički prikaz parametara korištenih pri kreiranju matematičkog modela u ovom istraživanju.....	43
Slika 10. Povezanost matematičkih modela korištenih u ovom istraživanju.....	44
Slika 11. Prikupljeni podaci i očekivane vrijednosti dobivene matematičkim modelom.....	50
Slika 12. Prikaz broja stanovnika u Francuskoj, Italiji i Belgiji od 1995. do 2025.....	55
Slika 13. Prikaz broja stanovnika u preostalim 14 država EU-a od 1995. do 2025.....	55
Slika 14. Prikaz očekivanog životnog vijeka stanovnika 17 država EU-a od 1995. do 2025. godine.....	58
Slika 15. Prikaz BDP-a po tržišnim cijenama u Belgiji, Francuskoj, Italiji, Nizozemskoj i Španjolskoj od 1995. do 2025. godine.....	59
Slika 16. Prikaz BDP-a po tržišnim cijenama u preostalim 12 promatranim država EU-a od 1995. do 2025. godine.....	60
Slika 17. Prikaz BDP-a po stanovniku u Luksemburgu od 1995. do 2025. godine.....	61
Slika 18. Prikaz BDP-a po stanovniku u preostalim 16 država EU-a od 1995. do 2025. godine.....	61
Slika 19. Prikaz ukupnih obveza financijskog sektora kao % BDP-a u Irskoj, Luksemburgu, Malti i Nizozemskoj od 1995. do 2025. godine.....	63
Slika 20. Prikaz ukupnih obveza financijskog sektora kao % BDP-a u preostalim 14 promatranim država EU-a od 1995. do 2025. godine.....	63
Slika 21. Prikaz ukupno zaposlenih od 15. do 64. godine u 17 država EU-a od 1995. do 2025. godine.....	69
Slika 22. Prikaz ukupno zaposlenih od 15. do 64. godine u 17 država EU-a od 1995. do 2025. godine.....	69
Slika 23. Srednji ekvivalent neto prihoda u 17 država EU-a od 1995. do 2025. godine.....	72
Slika 24. Uvoz roba i usluga u 17 država EU-a od 1995. do 2025. godine.....	73
Slika 25. Izvoz roba i usluga iz 17 država EU-a od 1995. do 2025. godine.....	74
Slika 26. Predškolsko obrazovanje, primarno obrazovanje i niže sekundarno obrazovanje u 17 država EU-a od 1995. do 2025. godine.....	78
Slika 27. Više sekundarno obrazovanje, post-sekundarno netercijarno obrazovanje u 17 država EU-a od 1995. do 2025. godine.....	79
Slika 28. Više srednje obrazovanje i post-sekundarno, netercijarno obrazovanje u 17 država EU-a od 1995. do 2025. godine.....	80
Slika 29. Broj visoko obrazovanih u 17 država EU-a od 1995. do 2025. godine.....	81
Slika 30. Prikaz dolazaka u turističke smještajne objekte u Francuskoj, Italiji i Španjolskoj od 1995. do 2025. godine.....	82

Slika 31. Prikaz dolazaka u turističke smještajne objekte u preostalih 14 država EU-a od 1995. do 2025. godine. ....	83
Slika 32. Prikaz broja noćenja u turističkim smještajnim objektima u Francuskoj, Italiji i Španjolskoj od 1995. do 2025. godine. ....	84
Slika 33. Prikaz broja noćenja u turističkim smještajnim objektima u preostalih 14 promatranih država EU-a od 1995. do 2025. godine. ....	85
Slika 34. Količine nastaloga komunalnog otpada, prikaz u tisućama tona, za Francusku, Italiju, Nizozemsku i Španjolsku od 1995. do 2025. godine. ....	86
Slika 35. Količine nastaloga komunalnog otpada, prikaz u tisućama tona, za preostalih 13 promatranih država EU-a od 1995. do 2025. godine. ....	86
Slika 36. Stopa recikliranja komunalnog otpada u 17 država EU-a od 1995. do 2025. godine. ....	88
Slika 37. Količine nastalog miješanoga komunalnog otpada u Francuskoj, Italiji i Španjolskoj od 1995. do 2025. godine. ....	91
Slika 38. Količine nastalog miješanoga komunalnog otpada u preostalih 14 država EU-a od 1995. do 2025. godine. ....	91
Slika 39. Količina miješanoga komunalnog otpada koja će u ispitivanim državama nastati od 2020. do 2025. godine. ....	93
Slika 40. Količine nastalog papira i kartona u 17 država EU-a od 1995. do 2025. godine. ....	96
Slika 41. Količina otpadnog papira i kartona koja će nastati u 17 promatranih država EU-a od 2020. do 2025. godine. ....	97
Slika 42. Količine nastalog otpadnog drva u 17 država EU-a od 1995. do 2025. godine. ....	100
Slika 43. Količina otpadnog drva koja će nastati u razdoblju od 2020. do 2025. godine po državama. ....	101
Slika 44. Količina otpadnog tekstila koja će nastati u promatranim državama EU-a od 2020. do 2025. godine. ....	103
Slika 45. PCA analiza za grupu ekonomskih pokazatelja. ....	105
Slika 46. PCA analiza za grupu pokazatelja zaposlenosti i zarade. ....	106
Slika 47. PCA analiza za grupu pokazatelja obrazovanja. ....	107
Slika 48. PCA analiza za podatke o otpadu. ....	108
Slika 49. PCA analiza za grupu podataka koja predstavlja vrste biorazgradivoga komunalnog otpada. ....	109
Slika 50. Utjecaj ulaznih varijabli na količine miješanoga komunalnog otpada za matematički model ANN1. ....	201
Slika 51. Utjecaj ulaznih varijabli na količine otpada od papira i kartona za matematički model ANN1. ....	202
Slika 52. Utjecaj ulaznih varijabli na količine otpada od drva za matematički model ANN1. ....	203
Slika 53. Utjecaj ulaznih varijabli na količine tekstilnog otpada za matematički model ANN1204. ....	



# 1. UVOD

Zakon o gospodarenju otpadom definira otpad kao „svaku tvar ili predmet koju posjednik odbacuje, namjerava ili mora odbaciti“ (NN 84/21). Otpad i njegova proizvodnja neizbježni su rezultati ljudskog postojanja. U današnje vrijeme svjedočimo kontinuiranom porastu svjetske populacije, a uz porast broja stanovnika i stalni gospodarski napredak, dolazi i do povećanja proizvodnje otpada. Dodatni veliki problem je prekomjerna urbanizacija i rast stanovništva na relativno malom području što otežava prikupljanje, skladištenje i obradu otpada. Zbog navedenog otpad postaje prijetnja za javno zdravlje i okoliš, a opasnost od lošeg upravljanja otpadom ozbiljan je globalni problem (Tun i sur., 2018; Castillo-Giménez i sur., 2019; Dev Sharma i Jain, 2020).

Informacije o količini (i vrsti) otpada koja će nastati mogu pojednostaviti procjenu ukupnog ulaganja za odgovarajuću organizaciju ljudi, opreme, spremnika i vremena potrebnog za odgovarajući način gospodarenja otpadom (Ghazi Zade i Noori, 2008). Brojna dosadašnja istraživanja bavila su se razvijanjem različitih matematičkih modela koji pomažu u planiranju i pronalasku najboljeg načina gospodarenja otpadom te u predviđanju količina nastanka otpada. Tako su primjerice Beigl i sur. (2004) razvili matematički model za identificiranje parametara za procjenu proizvodnje otpada u različitim europskim gradovima. Razvijen matematički model imao je srednju apsolutnu postotnu pogrešku od 8 % čime je potvrđena pretpostavka da razvijen matematički model može biti koristan alat za podršku donosiocima odluka u smislu učinkovitoga gospodarenja otpadom u različitim europskim gradovima. Također, zaključili su da kvaliteta ulaznih podataka uvelike utječe na razinu točnosti te da je potrebna buduća nadogradnja matematičkih modela kako bi model za predviđanje količina otpada bio što kvalitetniji.

U posljednje vrijeme sve se veća pažnja posvećuje istraživanju umjetnih neuronskih mreža kao alatu za predviđanje nastanka otpada. Umjetne neuronske mreže su matematički modeli obrade informacija koji funkcioniraju na sličan način kao i ljudski mozak, a služe za rješavanje problema na području umjetne inteligencije. Umjetne neuronske mreže su nelinearni alat u kojem se koristi niz ulaznih parametara iz kojih se izračunavaju elementi koji su međusobno povezani, dok je krajnji rezultat jedan ili više izlaznih parametara (Ghazi Zade i Noori, 2008; Abdoli i sur., 2011; Ribić i sur., 2019). Umjetne neuronske mreže u mogućnosti su riješiti jednostavne računalne operacije poput zbrajanja, množenja, ali sposobne su obraditi i velike količine podataka. Međutim, jedno od najkorisnijih i najznačajnijih obilježja umjetnih neuronskih mreža je predviđanje podataka zbog sposobnosti učenja neuronske mreže (Agatonovic-Kustrin

i Beresford, 2000; Bunsan i sur., 2013). Posljednjih godina neuronske mreže privukle su veliko zanimanje i postaju sve popularniji alat za određivanje ulazno-izlaznih odnosa nelinearnih sustava. Između ostalog, neuronske mreže pokazale su se i kao korisno sredstvo za modeliranje različitih ekoloških sustava, a neuronske mreže imale su i široku primjenu i na drugim složenim sustavima (Ghazi Zade i Noori, 2008; Noori i sur., 2009; Antanasijević i sur., 2013). Primjer složenog sustava gdje se mogu primijeniti umjetne neuronske mreže je i sustav gospodarenja otpadom. Tako su primjerice autori Kulisz i Kujawska (2020) proveli istraživanje za predviđanje stvaranja komunalnog otpada u Poljskoj pomoću modeliranja neuronskim mrežama. Rezultati istraživanja pokazuju kako matematički modeli koji koriste neuronske mreže za određivanje trendova proizvodnje otpada pokazuju dobre rezultate predviđanja, kako u lokalnom kontekstu poljskih gradova, tako i na nacionalnom nivou. Na temelju razvijenog modela predviđa se da će se buduće stvaranje otpada do 2024. godine u Poljskoj povećati za 2 %. Nadalje, tako osmišljeni matematički model koji se temelji na umjetnim neuronskim mrežama moguće je koristiti za daljnja istraživanja primjene održivih rješenja u gospodarenju komunalnim otpadom i odgovarajućih tehnologija njihovoga gospodarenja (Kulisz i Kujawska, 2020). Ovim doktorskim radom želi se proširiti lokalne i regionalne granice korištenja neuronskih mreža te kreirati model za predviđanje nastanka otpada na razini Europske unije (EU) i na nacionalnoj razini pojedinih država članica. Upravo je predviđanje europskih i nacionalnih pokazatelja u gospodarenju biorazgradivim komunalnim otpadom korištenjem umjetnih neuronskih mreža glavno područje istraživanja ovog dokorskog rada. Osnovni cilj je razvoj matematičkog modela i istraživanje primjene umjetnih neuronskih mreža za predviđanja količina različitih frakcija biorazgradivog otpada na europskoj i nacionalnoj razini i to za 17 država članica EU-a. Kreiranim modelom želi se predvidjeti količine četiriju frakcija biorazgradivoga komunalnog otpada koje će nastati na području 17 promatranih država EU-a u razdoblju od 2020. do 2025. godine. Razvijeni matematički model omogućit će pronalazak najboljeg načina oporabe, odnosno zbrinjavanja otpada kao temelj održivoga gospodarenja otpadom.

U ovom istraživanju poseban naglasak stavljen je na komunalni biorazgradivi otpad s obzirom na to da biorazgradivi otpad obično čini više od 50 posto komunalnog otpada. Pravilnim odvajanjem biorazgradivog otpada postavili bi se preduvjeti za daljnju obradu ekološki prihvatljivijim metodama, kao što je kompostiranje ili anaerobna digestija. Na taj način ujedno bi se smanjilo oslobađanje stakleničkih plinova do kojeg dolazi uslijed razgradnje organskog materijala na odlagalištima (Wei i sur., 2017), a kompost, kao i digestat, koji nastaju u bioplinskim postrojenjima, mogli bi se koristiti u poljoprivredi kao poboljšivači kvalitete tla.

## **1.1. Ciljevi i hipoteze istraživanja**

U ovom istraživanju postavljene su sljedeće hipoteze:

Hipoteza 1: Umjetne neuronske mreže su pouzdan alat kojim se može kreirati matematički model predviđanja količina biorazgradivoga komunalnog otpada na europskoj i nacionalnoj razini.

Hipoteza 2: Točnost predviđanja količina biorazgradivog otpada korištenjem umjetnih neuronskih mreža ovisi o odabiru ulaznih sociodemografskih, ekonomskih i industrijskih pokazatelja.

Ciljevi postavljeni u ovom doktorskom radu su:

Cilj 1: Izraditi matematički model predviđanja količina komponenti biorazgradivog otpada korištenjem umjetnih neuronskih mreža s ciljem njegove primjene na europskoj i nacionalnoj razini.

Cilj 2: Predvidjeti utjecaj sociodemografskih, ekonomskih i industrijskih pokazatelja na količine proizvedenog biorazgradivog otpada primjenom umjetnih neuronskih mreža.

## 2. PREGLED DOSADAŠNJE LITERATURE

### 2.1.     Otpad

Otpad postoji od samih početaka čovječanstva, a čovjek je ujedno jedina vrsta na svijetu koja stvara otpad. U prošlosti su količine nastalog otpada bile male jer se čovjek zbog svog načina života nije dugo zadržavao na jednom mjestu. Dostupnost resursa također je bila ograničena što je motiviralo ljude da svaki materijal ili predmet maksimalno iskoriste. Materijali koji su se u prošlosti najčešće koristili više puta (preteča današnjeg pojma ponovne uporabe) bili su koža, perje, krzno i općenito tekstil. Zbog takvog načina života, gdje čovjek ne proizvodi velike količine otpada, utjecaj otpada na okoliš bio je zanemariv. Kada bi određene količine otpada i nastale, najčešće bi se radilo o otpadu biljnog porijekla, kostima, drvu, pepelu i slično, a otpad bi se odlagao u tlu. Otpad odložen u tlu služio je kao materijal za poboljšanje kvalitete tla odnosno kao kompost, a sustav kompostiranja bio je poznat u Kini još prije 4000 godina (Barbalace, 2003; Puntarić i sur., 2012; Sofilić, 2015; Jurišić i sur., 2019).

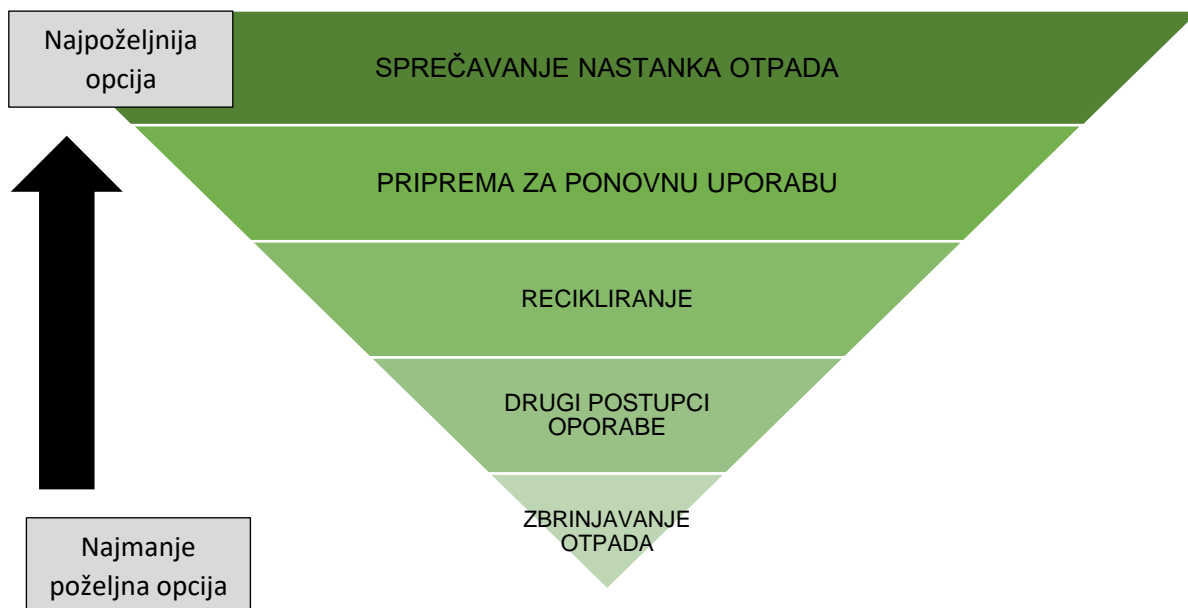
S povećanjem broja stanovništva, povećava se i količina nastalog otpada te istodobno dolazi do veće proizvodnje otpada po jedinici površine, čime se smanjuje udio zemljišta dostupnog za njegovo odlaganje. Kako je gustoća naseljenosti rasla i kako se pritisak na zemljište unutar urbanog područja povećavao, počeli su se razvijati prvi sustavi gospodarenja otpadom. Tako je primjerice u Londonu još 1354. godine izdana naredba da se prljavština (otpad) oduzeta kućama uklanja na tjednoj bazi (Wilson, 1976).

Industrijska revolucija, brzi razvoj ugljena, a kasnije naftna industrija i pojava tehničkih pomagala omogućili su znatno poboljšanje životnog standarda. Proporcionalno s porastom standarda, povećale su se i količine nastalog otpada. Nažalost, poboljšanje životnog standarda nije skladno pratila razina osviještenosti ljudi o štetnom djelovanju otpada što je dovelo do lošega gospodarenja otpadom. S time se nekadašnji način maksimalnog iskorištavanja materijala, stvari i predmeta kao svojevrsna preteča današnjeg recikliranja potpuno izgubio (Barles, 2014; Sofilić, 2015).

U skladu sa spomenutim promjenama kroz povijest, mijenjao se i način gospodarenja otpadom. Prvi oblik gospodarenja otpadom u prošlosti činilo je prikupljanje i odlaganje otpada, dok je današnji sustav gospodarenja otpadom mnogo kompleksniji. U današnjoj terminologiji gospodarenje otpadom sastoji se od sakupljanja, prijevoza, razvrstavanja, uporabe i zbrinjavanja, kao i kontinuiranog nadzora nad lokacijama i radnjama koje se poduzimaju nad otpadom (Kalambura i sur., 2011, 2018/851). Općenito govoreći, gospodarenje otpadom označava bilo koju aktivnost nad otpadom. U današnje vrijeme posebna pozornost usmjerena

je na gospodarenje otpadom, a glavni ciljevi gospodarenja otpadom su zaštita ljudi i okoliša te očuvanje resursa. Pritom je izuzetno važno spriječiti rizik od onečišćenja mora, vode, tla i zraka, pojave buke i neugodnih mirisa, ugrožavanje biljnog i životinjskog svijeta, nastajanje eksplozije i/ili požara i drugo. Spomenuti ciljevi trebali bi se primjenjivati u cijelom svijetu tako da se ne narušava dobrobit budućih generacija (Brunner i Fellner, 2007; NN 84/21). Kako bi se navedeno ostvarilo, današnja politika EU-a odražava prelazak shvaćanja otpada kao problem na razmišljanje i iskorištavanje otpada kao iskoristive sirovine. Navedeno se provodi uzimajući u obzir hijerarhiju otpada. Hijerarhija otpada predstavlja koncept koji izražava principe minimiziranja štete koju uzrokuje gospodarenje otpadom na okoliš. Prednost se daje recikliranju i ponovnoj upotrebi otpada u odnosu na odlaganje otpada. Koncept hijerarhije otpada postoji otprilike četrdeset godina, a započet je u Sjedinjenim Američkim Državama, dok je 2008. godine načelo hijerarhije otpada uključeno u Okvirnu direktivu o otpadu 2008/98/EC te je naknadno prenesena u nacionalno europsko pravo država članica EU-a. Hijerarhija otpada najčešće se objašnjava kao obrnuta piramida raspoređena u pet koraka gdje od najpoželjnijeg prema najmanje poželjnom načinu gospodarenja otpadom čine (Slika 1.):

1. sprečavanje nastanka otpada
2. priprema za ponovnu uporabu
3. recikliranje
4. drugi postupci uporabe, npr. energetska uporaba
5. zbrinjavanje otpada.



Slika 1. Hijerarhija gospodarenja otpadom. Izvor: Bide i sur., 2019

Kao što je prikazano na Slici 1., najmanje poželjna opcija u konceptu hijerarhije otpada je zbrinjavanje otpada, što u pravilu znači odlaganje otpada na odlagalište. Zatim slijede drugi postupci uporabe u obliku termičke obrade materijala u kombinaciji s energetsom uporabom, nakon čega slijedi recikliranje. Recikliranje se odnosi na transformacije rastavljanjem, sortiranjem i cirkulacijom materijalima, kako bi se omogućio njihov ponovni ulazak u industrijske i biološke proizvodne procese. Sljedeći korak u hijerarhiji gospodarenja otpadom je priprema za ponovnu uporabu. Najpoželjnija opcija u hijerarhiji je sprečavanje da određena tvar ili materijal postanu otpad. Time se potiču dizajn, proizvodnja i navike potrošnje koje ne rezultiraju stvaranjem otpada. Na taj način potiče se popravak proizvoda, prenamjena s ciljem produljenja životnog vijeka proizvoda. Jedan od primjera sprečavanja nastanka otpada može biti i (kućno) kompostiranje jer se tim procesom umjesto dobivanja otpada, (bio)otpad koristi kao materijal kojim se povećava kvaliteta tla (Hultman i Corvellec, 2012; Hrvatska agencija za okoliš i prirodu, 2018). Hijerarhija otpada podrazumijeva značajne promjene u sektoru gospodarenja otpadom pri čemu se promiče ekonomski rast kroz razvoj ekoinovacija, kao i druge mjere za smanjenje utjecaja na okoliš (EC 2008/98/EZ; Hultman i Corvellec, 2012; Pires i Martinho, 2019). Kad primjenjuju hijerarhiju otpada, države članice EU-a osiguravaju da razvoj zakonodavstva i politike o otpadu bude potpuno transparentan te da se poštuju postojeći nacionalni propisi o savjetovanju i uključivanju građana te svih dionika. Tako je i Republika Hrvatska, kao najmlađa članica, prije pristupanja kao punopravna članica EU-a trebala uskladiti nacionalno zakonodavstvo s pravnom stečevinom EU-a u svim područjima, uključujući i područje otpada. Stoga, pojam hijerarhije otpada preuzet je i u nacionalno zakonodavstvo Hrvatske kao red prvenstva gospodarenja otpadom (NN 84/21).

U Zakonu o gospodarenju otpadom (NN 84/21), kao krovnom zakonodavnom aktu Republike Hrvatske što se tiče teme otpada, uz red prvenstva gospodarenja otpadom definirana su i načela gospodarenja otpadom. Svrha tih načela je pružanje pravne zaštite kako bi se sustav gospodarenja otpadom organizirao uz što kvalitetnije odluke i kako bi se što uspješnije spriječio nastanak otpada, kako bi se smanjile količine nastalog otpada, kao i štetan utjecaj na okoliš sukladno općem interesu. Načela kojima se to želi postići su:

1. Načelo onečišćivač plaća – pravna ili fizička osoba koja proizvede otpad dužna je podmiriti sve troškove mjera gospodarenja otpadom i mjera za provedbu sanacije štete koju je onečišćivač prouzročio ili mogao prouzročiti.
2. Načelo blizine – propisuje da se otpadom gospodari što je moguće bliže mjestu njegova nastanka. Na taj način smanjuje se negativan utjecaj i opasnosti prilikom transporta i odabira optimalne lokacije za gospodarenje otpadom.

3. Načelo samodostatnosti – propisuje da se bilo koji oblik gospodarenja otpadom treba obavljati na samodostatan način slijedeći pritom propisane nacionalne ciljeve i vodeći računa o zemljopisnim okolnostima ili o drugim potrebama posebnih građevina za posebne kategorije otpada.
4. Načelo sljedivosti – propisuje da tok otpada treba moći slijediti, i to od samog porijekla otpada s obzirom na proizvod, ambalažu i proizvođača tog proizvoda pa sve do posjeda tog otpada kao i daljnje informacije o obradi (Drmić, 2012; NN 84/21).

### **2.1.1. Kategorizacija otpada**

Ako su kategorije otpada, kao i načini na koje se otpad može pravilno koristiti, jasno definirani, tada se vrijedni materijali sadržani u otpadu mogu učinkovitije iskoristiti (Gharfalkar i sur., 2015). Također, kako bi se dobili usporedivi i pouzdani podaci o stvaranju i gospodarenju otpadom, potrebne su jasne definicije i zajedničko razumijevanje kategorizacije otpada. Stoga, s ciljem usporedivosti, ponovljivosti i učinkovitosti na području EU-a osmišljen je popis otpada pod nazivom *European List of Waste (LoW)*. LoW predstavlja popis otpada koji daje zajedničku terminologiju za razvrstavanje otpada u EU-u. Navedeni popis otpada pomaže u razumijevanju, ali i gospodarenju otpadom. U navedenom popisu određen je standardni sustav za klasifikaciju otpada koji svakoj vrsti otpada uz opisni naziv dodjeljuje i „kôd“ koji se koristi prilikom transporta otpada i gospodarenja otpadom (koji se često odnose i na posebne kodove otpada), a dogovoreni „kodovi“ (u RH preneseno kao ključni brojevi) služe i kao osnova za statistiku otpada (Eurostat, 2010).

Zakon o gospodarenju otpadom u Hrvatskoj daje okvirne odredbe oko kategorizacije otpada. Kategorizacija otpada obuhvaća određivanje svojstva, porijekla i mjesta nastanka otpada, dok je posjednik otpada dužan kategorizirati otpad koji ima u posjedu tako da mu odredi porijeklo i mjesto nastanka, grupu, podgrupu i ključni broj sukladno Katalogu otpada (NN 84/21). Detaljnije odredbe o kategorizaciji otpada u Hrvatskoj propisane su Pravilnikom o katalogu otpada (NN 90/15). Sukladno Pravilniku o katalogu otpada (NN 90/15), svakoj vrsti otpada dodijeljen je ključni broj otpada kao jedinstvena oznaka koja se sastoji od šesteroznamenkastoga broja. Prve dvije znamenke određuju pripadnost grupi u koju je svrstana ta vrsta otpada. Druge dvije znamenke ključnog broja označavaju pripadnost podgrupi, a zadnje dvije znamenke ključnog broja određuju vrstu otpada unutar podgrupe. Popis koji sadrži sve vrste otpada naziva se Katalog otpada. Katalog otpada sadrži preko osamsto vrsta otpada sistematizirano poredanih u dvadeset grupa te upute za postupak kategorizacije. Grupa, podgrupa i vrsta otpada određuju se na temelju mjesta nastanka,

odnosno na temelju dostupnih podataka o vrsti industrije ili o vrsti procesa u kojem je otpad nastao (NN 90/2015). Popis grupa otpada nalazi se u nastavku (Tablica 1.).

Tablica 1. Popis grupa otpada (izvor: NN 90/2015)

Broj grupe	Naziv grupe
01	Otpad koji nastaje pri istraživanju, eksploatiranju i fizikalno-kemijskoj obradi mineralnih sirovina
02	Otpad iz poljoprivrede i hortikulture, proizvodnje vodenih kultura, šumarstva, lovstva i ribarstva, pripremanja i prerade hrane
03	Otpad od prerade drveta i proizvodnje drvenih panela i namještaja, celuloze, papira i kartona
04	Otpad iz kožarske, krznarske i tekstilne industrije
05	Otpad od rafiniranja nafte, pročišćavanja prirodnog plina i pirolitičke obrade ugljena
06	Otpad iz anorganskih kemijskih procesa
07	Otpad iz organskih kemijskih procesa
08	Otpad od proizvodnje, formulacije, dobave i uporabe prevlaka (boje, lakovi i staklasti emajli), ljepila, sredstva za brtvljenje i tiskarske tinte
09	Otpad iz fotografske industrije
10	Otpad iz termičkih procesa
11	Otpad od kemijske površinske obrade i prevlačenja metala i drugih materijala; hidrometalurgije obojenih metala
12	Otpad od mehaničkog oblikovanja te fizikalne i mehaničke površinske obrade metala i plastike
13	Otpadna ulja i otpad od tekućih goriva (osim jestivih ulja i ulja iz poglavlja 05, 12 i 19)
14	Otpad od organskih otapala, rashladnih i potisnih tvari (osim 07 i 08)
15	Otpadna ambalaža; apsorbensi, tkanine za brisanje, filtarski materijali i zaštitna odjeća koja nije specificirana na drugi način
16	Otpad koji nije drugdje specificiran u Katalogu
17	Građevinski otpad i otpad od rušenja objekta (uključujući iskopanu zemlju s onečišćenih lokacija)
18	Otpad koji nastaje kod zaštite zdravlja ljudi i životinja i/ili srodnih istraživanja (osim otpada iz kuhinja i restorana koji ne potječe iz neposredne zdravstvene zaštite)
19	Otpad iz građevina za gospodarenje otpadom, uređaja za pročišćavanje otpadnih voda izvan mjesta nastanka i pripremu pitke vode i vode za industrijsku uporabu
20	Komunalni otpad (osim iz kućanstva i slični otpad iz ustanova i trgovinskih i proizvodnih djelatnosti), uključujući odvojeno sakupljene sastojke komunalnog otpada



Legislativa u Republici Hrvatskoj koja određuje i objašnjava način klasifikacije otpada u skladu je s propisanim odredbama Europske komisije i europskom kategorizacijom otpada.

Prema svojstvima, otpad se dijeli na opasni i inertni, dok se prema mjestu nastanka otpad dijeli na proizvodni i komunalni otpad. Prema Zakonu o gospodarenju otpadom, „opasni otpad je otpad koji posjeduje jedno ili više opasnih svojstava“ (NN 84/21). Svojstva otpada koja ga čine opasnim nalaze se u Tablici 2. U opasni otpad ubrajamo, primjerice, stare baterije, ostatke lijekova i sredstava za zaštitu bilja, dezinfekciju, dezinsekciju, deratizaciju, ostatke lužina, kiselina, boja, lakova, otapala, sredstva za skidanje hrđe, boje ili laka, sredstva za zaštitu drva, akumulatore, uljne filtre, termometre sa živom, antifriz, boce pod tlakom, ljepila, fotokemikalije, mineralna ulja i drugo.

Tablica 2. Popis svojstva otpada koja ga čine opasnim (izvor: Uredba komisije 1357/2014)

Oznaka	Naziv
HP 1	Eksplozivno
HP 2	Oksidirajuće
HP 3	Zapaljivo
HP 4	Nadražujuće – kožne iritacije i ozljede oka
HP 5	Specifična toksičnost za ciljni organ / aspiracijska toksičnost
HP 6	Akutna toksičnost
HP 7	Kancerogeno
HP 8	Nagrizajuće
HP 9	Zarazno
HP 10	Toksično za reprodukciju
HP 11	Mutageno
HP 12	Oslobađanje akutno toksičnih plinova
HP 13	Senzibilizirajuće
HP 14	Ekotoksično
HP 15	Otpad koji može imati prethodno navedena opasna svojstva koja izvorni otpad nije izravno pokazivao

Zakon o gospodarenju otpadom inertni otpad definira kao „otpad koji ne podliježe značajnim fizičkim, kemijskim ili biološkim promjenama, nije topiv, nije zapaljiv, na bilo koje druge načine fizikalno ili kemijski ne reagira niti je biorazgradiv. S tvarima s kojima dolazi u dodir ne djeluje tako da bi to utjecalo na zdravlje ljudi, životinjskog i biljnog svijeta ili na povećanje dozvoljenih emisija u okoliš.“ (NN 84/21)

Otpad koji je nastao u gospodarstvu odnosno u industriji, obrtu ili drugim sličnim procesima naziva se proizvodni otpad. Proizvodni otpad razlikuje se po količinama, sastavu i svojstvima od komunalnog otpada (Hrnjak-Murčić, 2016; NN 84/21).

Zakon o gospodarenju otpadom u komunalni otpad uključuje miješani komunalni otpad i odvojeno sakupljeni otpad iz kućanstava te miješani komunalni otpad i odvojeno sakupljeni otpad iz drugih izvora, ako je taj otpad sličan po prirodi i sastavu otpadu iz kućanstva. Komunalni otpad ne uključuje otpad iz proizvodnje, poljoprivrede, šumarstva, ribarstva i akvakulture, septičkih jama i kanalizacije i uređaja za obradu otpadnih voda, uključujući kanalizacijski mulj, otpadna vozila i građevni otpad (NN 84/21). Popis ključnih brojeva koji spadaju u komunalni otpad prikazan je u Prilogu 1., a obuhvaća ključne brojeve iz podgrupe 15 01 (ambalaža, uključujući odvojeno sakupljenu ambalažu iz komunalnog otpada) i grupe 20 (otpad iz kućanstava i slični otpad iz obrta, industrije i ustanova, uključujući odvojeno sakupljene sastojke). Ključni brojevi otpada 20 02 02 (zemlja i kamenje), 20 03 04 (muljevi iz septičkih jama) i 20 03 06 (otpad nastao čišćenjem kanalizacije) ne smatraju se komunalnim otpadom (Ministarstvo gospodarstva i održivog razvoja, 2020).

Komunalni otpad sastoji se od svakodnevnih predmeta koje koristimo i bacamo, poput ambalaže proizvoda, starog namještaja, odjeće, ostataka hrane, novina, aparata, baterija i drugo. Svi navedeni predmeti dolaze iz naših domova, škola, bolnica i poduzeća te kroz razne radnje koje čovjek poduzima. Baš zbog toga što svojim (ne)svjesnim djelovanjem odlučujemo u kojem trenutku će određeni predmet postati otpad, možemo reći da je komunalni otpad blizak čovjeku te izravno utječe na njegovo stvaranje. Upravo zbog toga komunalni otpad odražava kulturu ljudi koji ga proizvode te utječe na zdravlje ljudi i okoliš koji ih okružuje (Vergara i Tchobanoglous, 2012). Teme vezane za komunalni otpad imaju veliku važnost i izazivaju veliku zainteresiranost zbog složenoga karaktera komunalnog otpada, promjenjivog sastava te zbog njegove povezanosti s obrascima potrošnje, ali i zbog njegove povezanosti s čovjekom i lako opipljivih problema koje uzrokuje (Blumenthal, 2011).

Prema definiciji Eurostata, komunalni otpad sastoji se od otpada koji prikupljaju lokalne vlasti i odlaže se putem sustava gospodarenja otpadom (Eurostat, 2013). Iako komunalni otpad u Europskoj uniji čini samo između 7 do 10 % ukupno nastalog otpada, to je jedna od kategorija

otpada kojom se najteže gospodari, a gospodarenje i postupanje često predstavlja više od jedne trećine financijskih napora javnog sektora za smanjenje i kontrolu onečišćenja (EC 2018/851, Eurostat, 2021d).

U hrvatskim propisima gospodarenje komunalnim otpadom smatra se javnom uslugom, a navedena usluga trebala bi građanima pružiti sustav gospodarenja otpadom na ekološki prihvatljiv i ekonomski održiv način. Kod gospodarenja komunalnim otpadom glavni cilj je poticati odvojeno sakupljanje komunalnog otpada kako bi se smanjila količina miješanoga komunalnog otpada koji nastaje (NN 84/21).

### **2.1.2. Biorazgradivi komunalni otpad**

Velik dio komunalnog otpada čini biorazgradivi komunalni otpad. Kada se govori o biorazgradivom otpadu, potrebno je naglasiti razliku između pojmova „biorazgradivi otpad“ i „biootpad“. Biorazgradivi otpad je svaki otpad koji je sposoban za anaerobnu ili aerobnu razgradnju, poput papira i kartona, biootpada, tekstila, drva i dr. (EC 1993/31/EZ; NN 84/21). Biorazgradivi otpad je širi pojam, dok je biootpad vrsta otpada koja spada u biorazgradivi otpad te predstavlja užu pojam koji označava „biološki razgradiv otpad iz vrtova i parkova, hranu i kuhinjski otpad iz kućanstva, restorana, ugostiteljskih i maloprodajnih objekata i slični otpad iz proizvodnje prehrambenih proizvoda“ (NN 84/21). Ovisno o lokalnim uvjetima, klimi, izvoru energije, stupnju industrijalizacije i navikama potrošača u pogledu konzumacije hrane i pića, u pravilu između 60 i 70 % komunalnog otpada sastoji se od biorazgradivoga komunalnog otpada (otpad od hrane, zeleni otpad, otpad od papira i kartona) (García i sur., 2005; Vergara i Tchobanoglous, 2012). Prema procijenjenom sastavu miješanoga komunalnog otpada u Republici Hrvatskoj iz 2015. godine, oko 65 % ukupne količine miješanoga komunalnog otpada čini biorazgradivi otpad (NN 3/17).

Tablica 3. prikazuje prosječni sastav komunalnog otpada u Europskoj uniji, dok Tablica 4. prikazuje procijenjeni sastav miješanoga komunalnog otpada u Republici Hrvatskoj u 2015. godini. Biorazgradive vrste komunalnog otpada su u Tablicama 3. i 4. označene masno otisnutim slovima gdje je vidljivo da u EU-u biorazgradivi otpad čini od 60 do 85 % ukupnih količina komunalnog otpada. Prema procijenjenom sastavu miješanoga komunalnog otpada u Republici Hrvatskoj iz 2015. godine, oko 65 % ukupne količine miješanoga komunalnog otpada čini biorazgradivi otpad (Bidlingmaier i sur., 2004; NN 3/17).

Tablica 3. Prosječan sastav komunalnog otpada u EU-u (izvor: Bidlingmaier i sur., 2004)

Sastavnica	Udio (%)
<b>Papir</b>	<b>25 – 35</b>
<b>Kuhinjski otpad</b>	<b>25 – 35</b>
<b>Vrtni (zeleni) otpad</b>	<b>10 – 15</b>
Plastika	7 – 10
Staklo	5 – 10
Željezni metali	3 – 5
Keramika	1 – 2
Opasni otpad	1 – 2
Neželjezni metali	0,5 – 2


Tablica 4. Procijenjeni sastav miješanoga komunalnog otpada u RH u 2015. godini (izvor: NN 3/17)

Sastavnica	Udio (%)
<b>Kuhinjski otpad</b>	<b>30,9</b>
<b>Papir i karton</b>	<b>23,2</b>
Plastika	22,9
Ostali otpad (zemlja, prašina, pijesak, nedefinirano)	6,3
<b>Vrtni (zeleni) otpad</b>	<b>5,7</b>
<b>Tekstil/odjeća</b>	<b>3,7</b>
Staklo	3,7
Metal	2,1
<b>Drvo</b>	<b>1,0</b>
Koža/kosti	0,5
Guma	0,2
<b>Ukupno:</b>	<b>100</b>

S obzirom na to da se velike količine biorazgradivog otpada i dalje odlažu na odlagalištima te imajući na umu da navedena praksa ima negativan utjecaj na okoliš, neophodno je žurno primijeniti alternativne metode gospodarenja ovom vrstom otpada (García i sur., 2005). S ciljem očuvanja okoliša, Direktivom o odlagalištima otpada 1999/31/EZ utvrđeni su ciljevi kojima bi se što manje biorazgradivog otpada trebalo upućivati na odlaganje. Države članice EU-a izrađuju nacionalnu strategiju za provođenje smanjivanja količine biorazgradivog otpada koji se odlaže na odlagališta. Tako je Republika Hrvatska u svoje zakonodavstvo uvela ograničenja u vezi odlaganja biorazgradivoga komunalnog otpada. Prema Zakonu o gospodarenju otpadom, „najveća dopuštena masa biorazgradivoga komunalnog otpada čije se odlaganje u

kalendarskoj godini može dopustiti svim dozvolama za gospodarenje otpadom u Republici Hrvatskoj je 264.661 tona.“ Navedeni iznos čini 35 % mase biorazgradivoga komunalnog otpada proizvedenog u 1997. godini. Također, na odlagališta otpada do 2035. godine može se odložiti najviše 10 % mase ukupno proizvedenoga komunalnog otpada (NN 84/21). Sa spomenutim mjerama želi se smanjiti količina odloženog biorazgradivoga komunalnog otpada na odlagalištima te indirektno smanjiti proizvodnju metana na odlagalištima koji nastaje uslijed razgradnje organske tvari te općenito smanjiti emisije stakleničkih plinova, smanjiti razinu globalnog zatopljanja i spriječiti potencijalno onečišćenje vode, tla i zraka.

U 2020. godini u Hrvatskoj je količina nastalog biorazgradivoga komunalnog otpada iznosila 1.058.703 t, dok je količina odloženog biorazgradivoga komunalnog otpada za 2020. godinu iznosila 596.013 t (Slika 2.). S navedenim količinama Republika Hrvatska ne dostiže propisan cilj kojim je dozvoljeno odložiti 264.661 tonu biorazgradivoga komunalnog otpada (Ministarstvo gospodarstva i održivog razvoja, 2021).



Slika 2. Nastali i odloženi biorazgradivi komunalni otpad u Republici Hrvatskoj u razdoblju od 1997. do 2020.

Ako se zna da je do 2009. količina nastalog biorazgradivoga komunalnog otpada u Republici Hrvatskoj bila gotova jednaka količini biorazgradivog otpada koja se odlagala na odlagalištima (Tablica 5.), Hrvatska je kao ravnopravna članica EU-a izložena velikim izazovima u pogledu ispunjavanja obveza Europske direktive o odlagalištima otpada.

Tablica 5. Nastali i odloženi biorazgradivi komunalni otpad u RH, 1997. – 2019  
(izvor: Ministarstvo gospodarstva i održivog razvoja, 2020)

Godina	Nastali biorazgradivi komunalni otpad (t)	Odloženi biorazgradivi komunalni otpad (t)
2019.	1.132.614	679.080
2018.	1.109.011	744.506
2017.	1.091.066	801.238
2016.	1.072.439	831.977
2015.	1.070.783	828.564
2014.	1.083.596	819.757
2013.	1.103.593	870.434
2012.	1.078.295	892.049
2011.	1.017.519	937.375
2010.	1.012.651	963.889
2009.	1.104.126	1.068.825
2008.	1.126.899	1.088.196
2007.	1.084.016	1.053.336
2006.	1.048.667	1.024.323
2005.	971.085	952.969
2004.	878.131	863.131
2000.	873.538	863.538
1997.	756.175	756.175

Kada se govori o biorazgradivom otpadu, valja spomenuti i globalno obećanje potpisano u studenom 2021. godine u Glasgowu, kojim se više od sto zemalja svijeta obvezuje da će do 2030. godine smanjiti emisije stakleničkog plina metana za 30 % u odnosu na količinu iz 2020. godine (Le Page, 2021). Navedenu inicijativu pokrenule su Sjedinjene Američke Države i Europska unija. O važnosti ovog sporazuma govori činjenica da Sjedinjene Američke Države godišnje odlože gotovo 300 milijuna tona biorazgradivog otpada. Samo s promjenom načina na koji postupaju s biorazgradivim otpadom, Sjedinjene Američke Države mogle bi biti na dobrom putu da dostignu zadani cilj od 30 % manje emisija metana (Themelis, 2021).

### 2.1.3. Biootpad

Biootpad je vrsta otpada s velikim potencijalom za doprinos kružnom gospodarstvu i mogućnošću nastanka dragocjenog materijala za poboljšanje tla, kao i bioplina koji može poslužiti kao izvor obnovljive energije. S udjelom od 34 %, biootpad je najveća pojedinačna komponenta komunalnog otpada u EU-u, dok je recikliranje biootpada ključno za postizanje cilja EU-a za recikliranje 65 % komunalnog otpada do 2035. godine.

U biootpad su uključena četiri ključna broja:

- 20 01 08 (biorazgradivi otpad iz kuhinja i kantina)
- 20 01 25 (jestiva ulja i masti)
- 20 02 01 (biorazgradivi otpad iz vrtova i parkova)
- 20 03 02 (otpad s tržnica) (Izvješće o komunalnom otpadu za 2019. godinu).

Kako bi se biootpad mogao koristiti kao izvor visokokvalitetnoga gnojiva i poboljšivača tla, potrebno ga je odvojeno prikupiti na izvoru uz održavanje niske razine nečistoća. Kontaminacija plastikom izaziva sve veću zabrinutost i potrebno je spriječiti ulazak plastike u biootpad. Iako je udio komunalnog otpada obrađen postupcima kompostiranja i anaerobne digestije iznosio 17 % u 2018., što je više od 11 % u 2004., visok udio biootpada i dalje završava u miješanom otpadu koji se odlaže ili spaljuje, čak i u mnogim državama s dobro uhodanim odvojenim sustavima odvojenog sakupljanja (European Environment Agency, 2020). O važnosti pravilnoga gospodarenja biootpadom, kao i o drugim sastavnicama biorazgradivog otpada, govori i činjenica da na području Europe nastane oko 60 milijuna tona biootpada koji bi se mogao obraditi postupcima kompostiranja i anaerobne digestije.

Kompostiranje je aerobna biološka razgradnja organske tvari gdje uz pomoć mikroorganizama nastaje stabilan proizvod (kompost) pogodan za aplikaciju u tlo (Haug, 1993; Hrvatska agencija za okoliš i prirodu, 2018). S druge strane, „anaerobna digestija je biokemijski proces u kojem se biorazgradivi organski supstrati razgrađuju mikrobiološkim procesima bez prisutnosti kisika, uz proizvodnju bioplina i digestata“ (Omerdić, 2020). Koji način obrade biootpada je najpogodniji, ovisi o vrsti i obilježjima otpada koji ulazi u proces kompostiranja ili digestije. U bioplinskim postrojenjima nije uputno koristiti materijal koji sadrži lignin (npr. drvo ili slama) jer lignin može značajno otežati proces anaerobne digestije. To znači da u bioplinska postrojenja ne bi trebalo upućivati vrtni (zeleni) otpad jer sadrži dosta drva i drvenastog materijala (Hrvatska agencija za okoliš i prirodu, 2018).

Kada bi se spomenutih 60 milijuna tona biootpada obradilo postupcima kompostiranja i anaerobne digestije, umjesto da se odlaže na odlagališta, procjenjuje se da bi došlo do smanjenja emisije od jednog milijuna tona dušika i dvadeset milijuna tona organskog ugljika

(European Parliament, 2017). Nadalje, kada bi se primijenili navedeni procesi gospodarenja biootpadom, neorgansko gnojivo moglo bi se zamijeniti kompostom do 30 % jer bi se kompost kasnije mogao koristiti u poljoprivredi (European Parliament, 2017). Ako kompost i ne zadovolji obilježja koja dozvoljavaju njegovo korištenje na poljoprivrednim površinama gdje se uzgaja hrana za prehranu ljudi, kompost smanjene kvalitete može se koristiti kao poboljšivač tla prilikom uzgoja kultura za prehranu životinja ili za proizvodnju energije, kao i na gradskim i općinskim javnim površinama i na drugim mjestima gdje se uzgaja ukrasno hortikulturno bilje (Purcell i Magette, 2011). Najbolja metoda kojom bi se mogla kontrolirati kvaliteta komposta je pravilno i rano odvajanje biootpada na izvoru. Uz to, potrebno je razviti standardiziran analitički postupak za ocjenu kvalitete konačnog proizvoda (komposta). To bi omogućilo jednostavno nadgledanje kvalitete komposta i lakšu usporedbu proizvoda među različitim objektima (Hargreaves i sur., 2008).

Kao i kompost, i digestirani ostatak anaerobne digestije može se sigurno upotrebljavati kao gnojivo kod ekološke poljoprivrede (Voća i sur., 2004). Korištenjem digestata kao materijala za poboljšanje kvalitete tla zatvorio bi se cijeli krug kružnoga gospodarstva, iako to nažalost nije uvijek tako. Porazni su podaci koji prikazuju da se 52 % ili 1,3 milijuna tona cjelokupnog digestata anaerobne digestije odlaže na odlagalište (European Parliament, 2017). Uz digestat, kao izlazni proizvod anaerobne digestije nastaje i bioplin. Tu su i izračuni koji govore da se iz svake tone otpada podvrgnutog anaerobnoj biološkoj obradi može dobiti od 100 do 200 m<sup>3</sup> bioplina, a svaka tona biootpada ujedno predstavlja potencijal od 350 do 400 kg komposta (Commission of the European Communities, 2008.).

Prema podacima iz Izvješća o komunalnom otpadu za 2020. godinu, procjenjuje se kako je 326 tisuća tona biootpada odloženo na odlagalištima otpada u Hrvatskoj. To znači da se godišnje u Republici Hrvatskoj na odlagalištima odloži između 115 i 130 tisuća tona potencijalnoga komposta te da se potencijalne sirovine nedovoljno iskorištavaju (Ministarstvo gospodarstva i održivog razvoja, 2021).

Količine odvojeno sakupljenog biootpada ovise o količinama nastaloga komunalnog otpada. U državama članicama EU-a s nižim dohotkom, otpad od hrane čini oko 30 % ukupnog otpada iz kućanstva, dok u državama članicama s višim prosječnim prihodom, otpad od hrane čini samo oko 20 %. Geografska nejednakost prikupljenih količina također je uzrokovana načinom i mogućnostima sakupljanja. Naprimjer, u ruralnim područjima gdje se kućanstvima nudi besplatni odvoz vrtnog otpada od vrata do vrata, vrtni otpad može činiti oko 25 % kućnog otpada, dok na područjima gdje besplatno sakupljanje biootpada nije uspostavljeno, vrtni otpad čini obično manje od 10 % nastaloga komunalnog otpada (Dubois i sur., 2020). Također, od




posebne je važnosti uvesti posebna ograničenja kojima bi se zabranilo odlaganje odvojeno sakupljenog biootpada i drugih sastavnica biorazgradivog otpada (EC 1999/31/EZ, NN 84/21). U ovom doktorskom radu proučavat će se četiri frakcije biorazgradivoga komunalnog otpada. To su papir i karton, drvo, tekstil i miješani komunalni otpad. Biootpad kao zasebna vrsta otpada neće se proučavati u sklopu ovog istraživanja, ali na primjeru miješanoga komunalnog otpada pokušat će se odrediti potencijal koji se gubi bacanjem biootpada neodvojenog u miješani komunalni otpad. Za navedene izračune uzimat će se da je 19,88 % miješanoga komunalnog otpada činio upravo biootpad (European Environment Agency, 2020).

#### **2.1.4. Količine komunalnog otpada u Europskoj uniji**

Prema zadnje raspoloživim podacima, u 2019. godini u Europskoj uniji nastalo je gotovo 225 milijuna tona komunalnog otpada. Podijeljeno po stanovnicima, to odgovara količini od 502 kilograma komunalnog otpada po stanovniku EU-a. Riječ je o malom porastu u usporedbi s 2018. godinom kada je nastalo 220 milijuna tona komunalnog otpada odnosno 495 kilograma po stanovniku (Eurostat, 2021c; Eurostat, 2020a). Iako su količine u 2019. godini bile u blagom porastu u usporedbi s 2018. godinom, nisu nadmašene najveće količine komunalnog otpada od 518 kilograma po osobi zabilježene u 2008. godini na razini EU-a (Eurostat, 2020a).

Na prostoru EU-a količina komunalnog otpada razlikuje se od države do države, krećući se od 280 kilograma po stanovniku u Rumunjskoj do 844 kilograma po stanovniku u Danskoj. Države u kojima je nastalo najviše otpada (više od 600 kilograma komunalnog otpada po stanovniku) bile su Luksemburg (791 kilogram), Malta (694 kilograma), Cipar (642 kilograma) i Njemačka (609 kilograma). Na drugom kraju ljestvice, uz Rumunjsku su još samo tri države članice EU-a koje su stvorile manje od 400 kilograma po osobi. To su Poljska (336 kilograma), Estonija (369 kilograma) i Mađarska (387 kilograma) (Eurostat, 2021c; Eurostat, 2021d) (Slika 3.)



Slika 3. Količina komunalnog otpada u 2019. godini u državama članicama EU-a. Izvor: Eurostat, 2021c


Na godišnjoj razini prate se podaci o količini i načinu gospodarenja komunalnim otpadom na razini EU-a. Prilikom prijave podataka, količina nastalog komunalnog otpada sastoji se od otpada, prikupljenog od strane ili u ime lokalnih vlasti, i zbrinutog kroz sustav gospodarenja otpadom. Količina obrađenoga komunalnog otpada iskazuje se za termičke postupke obrade (s energetsom uporabom ili bez energetske uporabe), recikliranja, kompostiranja i odlaganja. Podaci su dostupni u tisućama tona i kilograma po stanovniku. Otpad iz poljoprivrede i industrije nije uključen. Pokazatelj održivog razvoja komunalnog otpada izražava se u kilogramima po stanovniku.

Između država članica EU-a, ali i drugih zemalja, postoje razlike u načinu prikupljanja podataka i gospodarenja otpadom. U većini država članica EU-a metodologije za izračun nastalog komunalnog otpada dovršene su od 2004. nadalje, pa su i podaci iz 2004. i kasnijih godina precizniji i stabilniji od onih ranijih, između 1995. i 2003. godine. Također, valja spomenuti kako države članice EU-a na temelju Uredbe o statistici otpada (EZ) br. 2150/2002 prijavljuju i podatke o nastanku i obradi otpada. Podaci o nastanku otpada imaju raščlambu po izvorima (devetnaest poslovnih djelatnosti prema NACE klasifikaciji i djelatnosti kućanstva) i po kategorijama otpada (prema Europskoj klasifikaciji otpada za statističke svrhe). Podaci o obradi otpada raščlanjeni su na pet vrsta obrade (recikliranje, spaljivanje s energetsom uporabom, ostalo spaljivanje, zbrinjavanje na zemljištu i obrada zemljišta) i na kategorije otpada (Uredba (EZ) 2150/2002).

Iako je kvaliteta podataka o (komunalnom) otpadu za najbogatije nacije na svijetu prilično dobra, nažalost, ne postoji centralizirani skup podataka za manje razvijene zemlje svijeta (Vergara i Tchobanoglous, 2012).

### **2.1.5. Količine komunalnog otpada u Hrvatskoj**


Prvi podaci o nastalom komunalnom otpadu u Republici Hrvatskoj odnose se na podatke iz 1995. godine, dok je kontinuirano praćenje nastaloga komunalnog otpada započelo od 2004. godine nadalje, iako su se podaci do 2005. godine u najvećoj mjeri temeljili na procjenama. Od 2006. godine količine se počinju određivati na temelju prijavljenih podataka od strane obveznika, a tim se količinama pridodaju i količine za onaj dio stanovništva koji nije obuhvaćen organiziranim sakupljanjem i za one jedinice lokalne samouprave za koje podaci nisu dostavljeni. Podaci o komunalnom otpadu iz uslužnog sektora (npr. otpadni papir i karton iz škola i vrtića, ambalažni otpad iz trgovina, otpadna jestiva ulja iz hotela i bolnica itd.) od 2011. godine također se koriste u izračunu ukupnih količina nastaloga komunalnog otpada, kao i podaci o posebnim kategorijama otpada koji je sakupljen u okviru sustava koji organizira Fond za zaštitu okoliša i energetske učinkovitost. Do novih promjena u izračunu dolazi 2015. godine kad su, sukladno uputi iz Eurostata, iz količina ukupno nastaloga komunalnog otpada isključeni ključni brojevi otpada: 20 02 02 (zemlja i kamenje), 20 03 04 (muljevi iz septičkih jama) i 20 03 06 (otpad nastao čišćenjem kanalizacije) (Ministarstvo gospodarstva i održivog razvoja, 2020). Analizirajući količine nastaloga komunalnog otpada u Hrvatskoj od 1995. godine ( Slika 4.), primjećuje se porast ukupnih količina nastaloga komunalnog otpada do 2008. godine. Od 2008. do 2010. godine dolazi do smanjenja količina nastaloga komunalnog otpada što je povezano s gospodarskom krizom 2008. godine i njezinim posljedicama. Od 2010. do 2019. godine količine nastaloga komunalnog otpada u stalnom su porastu. Nakon dugogodišnjeg porasta u 2020. godini dolazi do pada ukupno nastaloga komunalnog otpada u Republici Hrvatskoj, što je većim dijelom posljedica pandemije uzrokovane koronavirusom (Ministarstvo gospodarstva i održivog razvoja, 2021).



Slika 4. Količine ukupno nastaloga komunalnog otpada u RH od 1995. do 2020. godine.

Izvor: Ministarstvo gospodarstva i održivog razvoja, 2021

Iako je količina komunalnog otpada po stanovniku u Republici Hrvatskoj od 2014. godine u porastu (Slika 5.), u usporedbi s EU-om Hrvatska je u donjem dijelu tablice s 444 kilograma po stanovniku odnosno 1,2 kilograma po stanovniku dnevno (podaci za 2019. godinu) (Ministarstvo gospodarstva i održivog razvoja, 2020).



Slika 5. Godišnje količine nastaloga komunalnog otpada po stanovniku u Republici Hrvatskoj i EU-u, od 1995. do 2019. godine. Izvor: Eurostat, 2021f

### **2.1.6. Parametri koji utječu na količine nastaloga komunalnog otpada**

EU ima 27 država članica, a među članicama postoje velike razlike. Te razlike uključuju ekonomske, demografske, socijalne, gospodarske i druge parametre, a isto tako velika razlika postoji i u količini nastaloga komunalnog otpada. Varijacije u količinama nastaloga komunalnog otpada u državama članicama EU-a odražavaju razlike u obrascima potrošnje i ekonomskom bogatstvu, ali ovisе i o načinu prikupljanja i upravljanja komunalnim otpadom (Namlis i Komilis, 2019; Eurostat, 2021d). Količina otpada koji nastaje u nekoj regiji ili državi izravno je proporcionalna gospodarskom rastu i razini potrošnje. U zemljama s niskim primanjima stanovnici uglavnom troše manje robe i generiraju manje otpada nego što to čine razvijene zemlje (Kumar i sur., 2011). Ako usporedimo samo dvije države EU-a i to državu u kojoj nastaje najmanje komunalnog otpada godišnje (Rumunjska) i državu koja proizvodi najviše komunalnog otpada (Danska), mogu se primijetiti značajne razlike, ali i utvrditi/potvrditi određeni obrasci ponašanja. Danska, u kojoj je u 2019. godini nastalo 844 kilograma komunalnog otpada po stanovniku, ima bruto domaći proizvod (BDP) oko 60.000 američkih dolara po stanovniku godišnje. U isto vrijeme, u Rumunjskoj godišnje nastane 280 kilograma po stanovniku, dok BDP iznosi manje od 9.000 američkih dolara po stanovniku godišnje. Čak i na samo ovim dvama primjerima može se primijetiti povezanost između količine nastaloga komunalnog otpada i BDP-a, odnosno općenito ekonomske razvijenosti i količine nastaloga komunalnog otpada (Kumar i sur., 2011; Namlis i Komilis, 2019). Jedno od prvih istraživanja koja su neizravno pokušala povezati životni standard (u obliku BDP-a) i uvoza materijala u zemlju iznijeli su Brunner i Fellner (2007). Autori su utvrdili da je korelacija značajna na razini od 1 % za normalnu regresiju između BDP-a i izravnog unosa materijala u zemlju. Iako uvezeni materijal nije jednak stvorenom otpadu, navedeno može biti dobar pokazatelj da je stvaranje komunalnog otpada u pozitivnom odnosu s razinom BDP-a.

Osim BDP-a, na količine nastaloga komunalnog otpada uvelike utječe i broj stanovnika i razina urbanizacije. Stalno povećanje stanovništva i velika potrošnja materijala rezultira ubrzanim stvaranjem komunalnog otpada. Tako veći i razvijeniji gradovi imaju tendenciju proizvodnje veće količine otpada po stanovniku u usporedbi s manjim gradovima jer su prihodi i potrošnja po stanovniku u urbanim sredinama veći (Kumar i sur., 2011; Vergara i Tchobanoglous, 2012; Wu i sur., 2020).

Postoji mnogo znanstvenih istraživanja o povezanosti socioekonomskih indeksa s količinom nastalom komunalnim otpadom. Većina studija pokazala je da prihod pozitivno utječe na stvaranje komunalnog otpada (Namlis i Komilis, 2019). Međutim, Medina (1997) je primijetio da odnos između stvaranja komunalnog otpada i prihoda ovisi o stupnju razvoja zemlje. Za

zemlje u razvoju, kako se povećavao prihod, povećavala se i količina nastalog komunalnog otpada. Međutim, kod najbogatijih zemalja stvaranje otpada smanjivalo se s povećanjem prihoda. Za zemlje između nije bilo jasne povezanosti (Medina, 1997).

Rezultati istraživanja Tranga i sur. (2017) doveli su do spoznaje da na stope stvaranja otpada uvelike utječe veličina kućanstva (s razinom značajnosti od 1 %) te se pokazalo da kućanstva s više članova generiraju veću količinu komunalnog otpada dnevno. U istom istraživanju varijabla razine ekološke svijesti u obrnuto proporcionalnom odnosu je s količinom nastalog otpada na razini značajnosti od 1 %, što ukazuje da kućanstva koja više brinu o okolišu stvaraju manje otpada. Također, postoji negativan odnos između visine prihoda i stvaranja otpada iz kućanstva na razini od 1 % značajnog ( $p < 0,01$ ). To znači da ljudi s višim prihodima stvaraju manje otpada od ljudi s nižim primanjima. Ovaj rezultat ne podupire ideju da obitelj koja se sastoji od članova s višim prihodima svaki dan stvara veću količinu krutog otpada iz kućanstva, ali navedeno je razumljivo jer kućanstva s višim primanjima (obitelji većeg ekonomskog statusa) češće večeraju vani i rjeđe kuhaju kod kuće, dok kućanstva s nižim prihodima i nižim ekonomskim statusom uglavnom kuhaju kod kuće. Osim toga, nerijetko u kućanstvima s višim prihodima članovi kućanstva rade u smjenama pa često ručaju i večeraju na radnim mjestima. To objašnjava zašto kućanstva s višim prihodima stvaraju manje otpada u usporedbi s obiteljima s nižim prihodima (Trang i sur., 2017). Isto tako, obitelji s višim prihodima stvaraju manje organskog otpada, a više papira i plastike, vjerojatno ponovno kao rezultat češćeg objedovanja izvan kuće u usporedbi s ljudima s nižim prihodima. Slični obrasci ponašanja vrijede i globalno. Kako ljudi stječu bogatstvo, sastav odbačenih materijala je sve kompleksniji. Iz tih se razloga obilježja i sastav otpada uvelike razlikuju među gradovima/regijama. Općenito govoreći, bogatiji gradovi i bogatije nacije imaju složenije sastave otpada od gradova koji su još u razvoju i koji odbacuju manje, ali imaju više biorazgradivih frakcija u otpadu (Vergara i Tchobanoglous, 2012).

Utvrđeno je i da razina obrazovanja utječe na stvaranje otpada. Tako je istraživanje Sujaudina i sur. (2008) pokazalo da je razina obrazovanja obitelji (prosječan broj godina u školi) u pozitivnoj korelaciji sa stvaranjem komunalnog otpada ( $p < 0,05$ ). Iz navedenog je razvidno kako viši stupanj obrazovanja članova obitelji dovodi do veće dnevne količine otpada koja nastaje u kućanstvima (Sujaudin i sur., 2008). Iako se obično očekuje da obitelj koju čine članovi s visokim obrazovanjem svaki dan stvara manju količinu otpada, edukacija odnosno razina obrazovanja ima pozitivan utjecaj na stvaranje otpada iz kućanstva i u istraživanju Tranga i sur. (2017), ali navedeni učinak nije bio statistički značajan (Trang i sur., 2017). Sasvim suprotne rezultate dobili su Monavari i sur. (2012) koji su utvrdili kako je razina

obrazovanja obitelji u negativnoj korelaciji sa stvaranjem otpada iz kućanstva ( $p < 0,05$ ) (Monavari i sur., 2012).

Turizam također ima znatan utjecaj na stvaranje komunalnog otpada (Kumar i sur., 2011; Mateu-Sbert i sur., 2013; Arbulú i sur., 2015). Turizam je jedna od najbrže rastućih gospodarskih grana u svijetu i jedan od najznačajnijih društveno-ekonomskih fenomena trenutne ere. Sektor turizma poprilično je dobio na važnosti u stvaranju prihoda i u broju radnih mjesta širom svijeta. U 2017. godini samo u EU-u više od 13 milijuna ljudi bilo je zaposleno u gospodarskim djelatnostima povezanim s turizmom. Samo tijekom proljeća (od ožujka do lipnja) 2018. godine stanovnici EU-a ostvarili su gotovo 360 milijuna turističkih putovanja u destinacijama u EU-u, što odgovara 1,5 milijardi noćenja u iznajmljenom ili neiznajmljenom smještaju i 128 milijardi eura potrošenih tijekom tih proljetnih putovanja (Eurostat, 2020d). Iz navedenog je jasno da turizam može održati visoku razinu zaposlenosti i prihoda u gospodarstvu mnogih regija. Međutim, turistički sektor je izvor i negativnih utjecaja na okoliš i izvor potrošnje resursa s posljedicama javnozdravstvenih problema. Jedan od najvažnijih utjecaja turizma je stvaranje komunalnog otpada. Mnoga su istraživanja potvrdila kako se komunalni otpad povećavao kako je rasla sezonska populacija turističkih područja ili regija. Kada se govori o utjecaju turizma na stvaranje otpada, svakako valja naglasiti činjenicu da je u većini europskih destinacija vrhunac turizma ljeti, a važno razdoblje je i proljeće s obzirom na to da je oko 32 % godišnjih noćenja u turističkim smještajnim objektima zabilježeno tijekom četiriju mjeseca, od ožujka do lipnja (podaci iz 2019.). Zbog neravnomjerne raspodjele turista tijekom godine nastaju dodatni problemi u gospodarenju otpadom. Kako sezonski raste broj turista, tako raste i količina nastalog komunalnog otpada. Stoga je na takvim područjima potrebno prilagoditi infrastrukturu velikim fluktuacijama u količinama otpada koje nastaju kako bi se s otpadom postupalo na adekvatan način. Još jedan primjer velike neravnomjerne raspodjele turista i turističkih kapaciteta (zbog kojih može doći do problema u gospodarenju otpadom) je procjena da je u 2016. u EU-28 na raspolaganju bilo više od 608 tisuća turističkih smještajnih objekata kojima se zajedno osigurao gotovo 31 milijun kreveta. Približno jedna trećina svih kreveta u skupini država EU-28 nalazila se u samo dvjema državama članicama EU-a, u Francuskoj (5,1 milijun kreveta) i u Italiji (4,9 milijuna kreveta) (Eurostat, 2020d; Eurostat, 2021g). Stoga, u turističkim područjima posebno je važno sakupljati, transportirati, obrađivati i konačno gospodariti otpadom na ekološki prihvatljiv, siguran i isplativ način jer osim ekoloških i zdravstvenih problema, neprikladno upravljanje otpadom može imati negativne utjecaje na atraktivnost turističkog odredišta. Procjena pokazuje kako u prosjeku porast turista

za 1 % uzrokuje ukupni porast komunalnog otpada od 0,28 % (Mateu-Sbert i sur., 2013; Arbulú i sur., 2015).

Na količine nastaloga komunalnog otpada utječu i drugi parametri, kao što su zemljopisni položaj, područje stanovanja/nastanka otpada (kuća/stan, grad/selo), godišnje doba, učestalost prikupljanja otpada, promjene u broju zaposlenosti/nezaposlenosti, migracije, veličina stambene jedinice, utjecaj recikliranja otpada i mnogi drugi čimbenici (Dyson i Chang, 2005; Bandara i sur., 2007; Sujauddin i sur., 2008; Purcell i Magette, 2009; Kumar i sur., 2011; Kulisz i Kujawska, 2020). Većina do sada spomenutih parametara proporcionalna je s količinom nastaloga komunalnog otpada i funkcionira tako da s povećavanjem određenog parametra ili s povećavanjem njegovog utjecaja raste i količina komunalnog otpada. Navedeni odnos može ići i u obrnutom smjeru. Na taj način gospodarska kriza i pogoršanje životnog standarda također utječu na količine nastaloga komunalnog otpada u vidu smanjenja nastaloga komunalnog otpada (Trang i sur., 2017; Namlis i Komilis, 2019).

Pored svih nabrojanih čimbenika koji utječu na količinu nastalog otpada (rast stanovništva, ekonomski razvoj, veličine kućanstva itd.) koji su više-manje javno poznati i „opipljivi“, postoje i drugi čimbenici koji mogu utjecati na stvaranje otpada, a ne moraju uvijek biti izravno kvantificirani. Ti čimbenici mogu biti državno/regionalno zakonodavstvo, (visok) porez na odlaganje (primjerice, Velika Britanija (Davies i Doble, 2004.)), geografske varijacije unutar iste zemlje poput Italije (Mazzanti i sur., 2012.) i Turske (Keser i sur., 2012.), kulturološke razlike (Keser i sur., 2012.), ponašanje i stavovi pojedinaca (Mazzanti i sur., 2012.) i mnogi drugi. Valja posebno istaknuti kako je sprečavanje nastanka otpada ključna aktivnost koja bi mogla dovesti do razdvajanja gospodarskog rasta od stvaranja otpada.

### **2.1.7. Predviđanje nastanka komunalnog otpada**

Pitanja vezana za otpad danas su od velikog interesa. Stvaranje komunalnog otpada i utjecaj koji stvaranje tog otpada ima na okoliš predstavlja aktualnu temu, kako u krugu znanstvene i stručne zajednice, tako i kod javnosti, zbog čega je povećan pritisak na javne vlasti da razviju političke i druge mehanizme za rješavanje ovog problema. Kako bi se riješilo pitanje otpada, potrebno je pronaći odgovarajući način gospodarenja otpadom. Količina i sastav nastalog otpada čine osnovne informacije potrebne za planiranje, rad i optimizaciju sustava gospodarenja otpadom. Dosadašnja znanstvena istraživanja ukazuju na to da je procjena količine komunalnog otpada koja će nastati vrlo bitna stavka u planiranju gospodarenja komunalnim otpadom. Nažalost, nedostatak globalne baze podataka o količini, proizvodnji i



sastavu otpada otežava rješavanje problema s otpadom (Beigl i sur., 2008; Vergara i Tchobanoglous, 2012; Arbulú i sur., 2015). Kako bi se razriješio nedostatak globalnih baza podataka o otpadu, donositelji odluka neprestano traže inovativna i perspektivna rješenja za rješavanje problema predviđanja količina nastaloga komunalnog otpada. Razvoj pouzdanog matematičkog modela za predviđanje ukupnog utjecaja gospodarskog trenda, promjene stanovništva i drugih parametara koji mogu utjecati na količine nastaloga komunalnog otpada predstavljali bi koristan napredak u planiranju održivog sustava gospodarenja komunalnim otpadom. Kod predviđanja nastanka komunalnog otpada najčešće se koriste demografski i socioekonomski čimbenici (Kumar i sur., 2011; Ribić i sur., 2019; Kulisz i Kujawska, 2020). Kako bi se razvio i primijenio učinkovit sustav upravljanja komunalnim otpadom, interes bi se trebao staviti na kreiranje točnih i pouzdanih metoda predviđanja stvaranja komunalnog otpada. Predviđanje količina komunalnog otpada, osim što pomaže u planiranju održivoga gospodarenja otpadom, može poslužiti i kao pomoć kod razvoja zakonske i druge regulative. U današnje vrijeme mnoge vlasti i općenito donosioci odluka imaju velik problem s odabirom i provođenjem adekvatnog načina gospodarenja otpadom. Primjer jednog od problema je osiguravanje prostora i kapaciteta za odlaganje komunalnog otpada godinama unaprijed što ukazuje na hitnu potrebu za pouzdanim predviđanjem količina komunalnog otpada. Do sada su mnoga istraživanja posvećena proučavanju predviđanja količina komunalnog otpada, uključujući matematičke modele vremenskih serija i regresijskih modela. S obzirom na to da je mehanizam nastanka komunalnog otpada jako složen proces te postoji povezanost između socioekonomskih čimbenika i stvaranja komunalnog otpada, nelinearni regresijski modeli pokazuju bolju točnost od onih linearnih, stoga je u posljednje vrijeme učestalo korištenje neuronskih mreža kod predviđanja nastanka otpada (Wu i sur., 2020).

Jahandideh i sur. (2009) u svom su istraživanju za predviđanje brzine stvaranja medicinskog otpada primijenili višestruku linearnu regresiju i umjetne neuronske mreže. Koeficijent determinacije u modelu višestruke linearne regresije iznosio je 0,24, dok je u modelu umjetne neuronske mreže koeficijent determinacije ( $r^2$ ) iznosio 0,99. U navedenom primjeru umjetne neuronske mreže pokazuju nižu razinu pogreške u odnosu na model višestruke linearne regresije, a ujedno neuronske mreže ukazuju na superiornost u kvaliteti procjene u smislu točnosti.

U Iranu je također provedeno istraživanje u kojem su dva matematička modela, i to umjetne neuronske mreže i višestruka linearna regresija, primijenjena za provjeru izvedbe modela za predviđanje srednje stope nastanka sezonskoga komunalnog otpada u dvadeset urbanih regija provincije Fars, Iran. Četiri utjecajne varijable (stanovništvo, učestalost prikupljanja otpada,

maksimalna sezonska temperatura i nadmorska visina) odabrane su kao ulazni podaci. Rezultati su pokazali kako je korištenje modela umjetne neuronske mreže za predviđanje stopa proizvodnje sezonskoga komunalnog otpada dalo točnije rezultate, a razlika između predviđenih i promatranih vrijednosti nije bila statistički značajna. Navedeno se nije pokazalo točnim za model višestruke linearne regresije gdje je razlika između predviđenih i promatranih vrijednosti bila statistički značajna. Stoga, model umjetne neuronske mreže jasno je pokazao veću točnost ( $r^2 = 0,86$ , srednja apsolutna postotna greška (što je rezultat bliži nuli, to su bolje performanse modela): 8 %) u odnosu na regresijski model ( $r^2 = 0,70$ , srednja apsolutna postotna greška: 13 %). Na temelju rezultata može se zaključiti kako je bolje koristiti neuronsku mrežu za predviđanje stopa proizvodnje sezonskoga komunalnog otpada (Azadi i Karimi-Jashni, 2015).

Na Cipru je provedeno slično istraživanje kojem je glavni cilj bio predvidjeti stopu stvaranja otpada u ugostiteljskom sektoru. Korištena su tri različita prediktorska matematička modela: višestruka linearna regresija, umjetne neuronske mreže i središnji kompozitni dizajn. Cilj je bio predvidjeti srednju stopu stvaranja otpada na temelju podataka o vrsti otpada, sezoni, vrsti smještaja i načinu upravljanja otpadom. U predviđanju neuronske mreže dale su najbolje rezultate s najnižim vrijednostima standardne pogreške predviđanja (SEP = 2,15), srednje apsolutne pogreške (MAE = 1,38) i najveće vrijednosti  $r^2$  (0,99) koje su potvrdile točnost matematičkog modela (Azarmi i sur., 2018).

I u drugim istraživanjima u kojima se radila usporedba neuronskih mreža s drugim matematičkim modelima (Changqing i sur., 2003; Bolf i sur., 2007; Shamshiry i sur., 2014; Azadi i Karimi-Jashni, 2015; Yusoff i sur., 2018), umjetne neuronske mreže dale su bolje rezultate kod predviđanja nastanka otpada u usporedbi s drugim matematičkim modelima. Do sada su mnogi istraživači uspješno primijenili umjetne neuronske mreže u predviđanju komunalnog otpada na svom lokalnom području i upravo se većina modela za predviđanje komunalnog otpada zasniva na podacima određene regije ili na podacima za određeni grad. Tako su neuronske mreže korištene i za procjenu stvaranja komunalnog otpada u gradu Zagrebu (Ribić i sur., 2019). U navedenom istraživanju razvijen je matematički model za procjenu nastanka komunalnog otpada za razdoblje od 2013. do 2016. godine. Korišteni ulazni podaci bili su podijeljeni u dvije skupine: socioekonomski i pokazatelji gospodarenja otpadom. Ova studija pokazuje kako bi se socioekonomske varijable kao što su ukupan broj kućanstava, broj turista i plaće mogle učinkovito koristiti za predviđanje različitih frakcija otpada, kao što su papir i karton, miješani komunalni otpad i glomazni otpad. Ukupne vrijednosti  $r^2$  bile su između 0,710 i 0,997 što je potvrdilo mogućnosti predviđanja modela. Autori su naglasili kako je

ograničena količina podataka bila korištena u ovom radu, ali matematički model ipak se pokazao sposobnim za postizanje dovoljno dobrih rezultata.

Kulisz i Kujawska (2020) koristili su umjetne neuronske mreže za predviđanje stvaranja komunalnog otpada u Poljskoj. Za razvoj matematičkih modela također su korišteni podaci o otpadu, kao i socioekonomski podaci nekoliko općina. Rezultati istraživanja pokazuju da matematički modeli koje koriste neuronske mreže pokazuju dobru kvalitetu predviđanja u smislu određivanja trendova proizvodnje otpada, kako u lokalnom kontekstu, tako i na nacionalnom nivou. Isto tako, dobiven matematički model može poslužiti za daljnja ispitivanja primjene održivih rješenja u gospodarenju komunalnim otpadom i odgovarajućih tehnologija njihovoga gospodarenja, a prezentirana metodologija može se prilagoditi bilo kojem gradu u Europi koristeći potrebne statističke podatke (Kulisz i Kujawska, 2020).

S obzirom na to da na stvaranje otpada utječe niz parametara i imajući na umu da se uvjeti i načini stvaranja komunalnog otpada mogu razlikovati među regijama, do sada je mali broj istraživanja o predviđanju komunalnog otpada rađen na većim razmjerima (Wu i sur., 2020). Antanasijević i sur. (2013) kreirali su umjetnu neuronsku mrežu za predviđanje nastanka komunalnog otpada u 26 europskih zemalja s ciljem primjene navedenog matematičkog modela za predviđanje podataka za Srbiju i Bugarsku za koje ne postoje izmjereni podaci o komunalnom otpadu, već postoje samo procjene. U tom su istraživanju korištene dvije različite arhitekture umjetnih neuronskih mreža (Pravilo povratnog širenja i opća regresijska neuronska mreža). Opća regresijska neuronska mreža pruža bolje predviđanje nastanka komunalnog otpada za zemlje različite ekonomske razine. Tako, naprimjer, opća regresijska neuronska mreža pruža puno bolja predviđanja s vrijednošću  $r^2$  koja varira od 0,798 do 0,843, u usporedbi s Pravilom povratnog širenja s vrijednošću  $r^2$  u rasponu od 0,613 do 0,647 za skupove podataka o validaciji za 2003. i 2004. godinu. U skladu s rezultatima, može se zaključiti kako umjetne neuronske mreže mogu biti primjenjive za predviđanje nastanka komunalnog otpada na temelju ekonomskih, industrijskih, demografskih i drugih parametara koji se kontinuirano prate. Tako razvijeni matematički model primijenio se i za predviđanje nastanka komunalnog otpada u Bugarskoj i Srbiji. Model opće regresijske neuronske mreže daje vrijednosti koje blisko odgovaraju stvarnim vrijednostima nastanka komunalnog otpada za Bugarsku, s maksimalnom relativnom pogreškom od 17 %, dok je za Srbiju relativna pogreška bila manja od 10 % (Antanasijević i sur., 2013).

Na temelju prikazanih primjera može se reći kako razvijeni matematički modeli u pravilu imaju dobru sposobnost predviđanja te mogu biti korisni za pružanje podrške u donošenju odluka o načinu gospodarenja i upravljanja otpadom. Pri tome bolje rezultate prikazuju matematički

modeli neuronskih mreža. Zbog dosadašnjih pozitivnih primjera u korištenju umjetnih neuronskih mreža kod predviđanja nastanka otpada, kao i svega do sada navedenog, u ovom istraživanju koristit će se upravo umjetne neuronske mreže kao alat za predviđanje nastanka komunalnog otpada, kako na nacionalnoj razini, tako i na razini Europske unije.

## **2.2. Umjetne neuronske mreže**

Pojam „neuronske mreže“ ima dvojako značenje. Prvenstveno se ovaj pojam povezuje s biološkom neuronskom mrežom koja je građena od neurona (Domijan, 2000). Pod pojmom neuronskih mreža također se podrazumijevaju i umjetne neuronske mreže. Umjetne neuronske mreže (engl. *Artificial Neural Network*, ANN) ili samo neuronske mreže matematički su modeli koji svoje osnove temelje na obradi informacija prema matematičkom modelu rada ljudskog mozga i živčanog sustava. Umjetne neuronske mreže su algoritmi za obradu informacija iz sličnih situacija, poput učenja iz prošlih iskustava i donošenja odluka na temelju nepotpunog znanja i na nelinearnostima (Ghazi Zade i Noori, 2008; Kumar i sur., 2011; 155. Ujević Andrijić, 2019).

### **2.2.1. Razvoj i primjena umjetnih neuronskih mreža**

Umjetne neuronske mreže predstavljaju interdisciplinarno područje koje je nastalo kao rezultat zajedničkog i istovremenog istraživanja znanja iz psihologije, neurobiologije, matematike i informatike s ciljem razjašnjavanja odnosa neuralne aktivnosti i kognitivnoga funkcioniranja korištenjem matematičkih koncepata poput linearne algebre, diferencijalnih jednadžbi i dinamičkih sustava (Domijan, 2000). Koncept umjetnih neuronskih mreža prvi put je predstavljen 1940-ih godina kada su McCulloch i Pitts istražujući neurofiziološka obilježja živih bića objavili matematički model neuronske mreže (McCulloch i Pitts, 1943). Interes za ovim alatom rastao je sve do 1960-ih kad su Minsky i Papert pokazali kako se umjetne neuronske mreže ne mogu učinkovito trenirati za bilo koje praktične veličine i potrebe (Minsky i Papert, 1969). Tek su sredinom 1980-ih umjetne neuronske mreže ponovno postale popularan alat u istraživačkoj zajednici kada su Rumelhart i McClelland otkrili algoritam kalibracije, koji se mogao koristiti za osposobljavanje mreža s dovoljnim bazama podataka i složenosti kako bi bile od praktične koristi (Rumelhart i McClelland, 1986). Od tada su se istraživanja umjetnih neuronskih mreža proširila i razvili su se različiti tipovi mreža, algoritama i alata za obuku (Slika 6.). Općenito govoreći, istraživanja umjetnih neuronskih mreža danas su usmjerena na razvoj struktura novih matematičkih modela s ciljem rješavanja praktičnih numeričkih problema (Antanasijević i sur., 2013; Dumančić, 2014).




Slika 6. Vremenski razvoj umjetnih neuronskih mreža

Umjetne neuronske mreže danas su postale vodeći i gotovo nezaobilazni alat kod rješavanja problema klasifikacije i predviđanja i korisno se primjenjuju na širokom spektru problema koje je teško razumjeti, definirati i kvantificirati. Konkretnije, umjetne neuronske mreže imaju primjenu u brojnim područjima života poput medicine, bankarstva, strojarstva, geologije, fizike, obrazovanja, elektrotehnike, poslovanja, vojske, financija, kontrole kvalitete, sigurnosti poslovanja itd. Stoga se može reći kako umjetne neuronske mreže predstavljaju obećavajuću i sve popularniju tehnologiju predviđanja današnjice (Žalac, 1997; Dalbelo Bašić i sur., 2008). Uz navedeno, posljednjih godina neuronske mreže postale su popularan i koristan alat za matematičko modeliranje okolišnih sustava. Neuronske mreže imaju učinkovit način predviđanja okolišnih parametara za odabrano područje na temelju socioekonomskih, industrijskih i demografskih parametara. Tako se neuronske mreže uspješno koriste u području gospodarenja komunalnim otpadom (Kulisz i Kujawska, 2020), što će se istražiti u ovom doktorskom radu, za predviđanje brzine stvaranja medicinskog otpada (Jahandideh i sur., 2009), za predviđanje i kontrolu emisije dioksina u postrojenjima za termičku obradu otpada (Bunsan i sur., 2013), za kratkoročno predviđanje protoka vode u krškom području (Kovačević i sur., 2018), za predviđanje cvjetanja mora (Cho i sur., 2014), za praćenje kvalitete vode (Kim i sur., 2006; Kalawapudi i sur., 2020), za predviđanje emisija i koncentracija najčešćih onečišćivača zraka (Moustris i sur., 2010), za predviđanje rada postrojenja za pročišćavanje otpadnih voda (Hamed i sur., 2004), za predviđanje protoka oborinskih voda kroz odlagališta (Karaca i Özkaya, 2006), za predviđanje kalorijske vrijednosti komunalnog otpada u Kini (Dong i sur., 2003), za praćenje količine suspendirane tvari u vodi (Melesse i sur., 2011), za kartiranje šuma (Carter Ingram i sur., 2005) i na brojnim drugim područjima. Općenito govoreći, neuronske mreže mogu se koristiti kod proučavanja bilo kojeg područja gdje postoji određen odnos između niza neovisnih i ovisnih varijabli ili za pronalaženje povezanosti u podacima (Kumar i sur., 2011; Ribić i sur., 2019).

## 2.2.2. Arhitektura umjetnih neuronskih mreža

Osnovna građevna jedinica umjetnih neuronskih mreža je umjetni neuron. Umjetne neuronske mreže sastoje se od stotina umjetnih neurona koji istovremeno obrađuju podatke, a povezani su (težinskim) koeficijentima koji čine neuronsku strukturu. Navedeni se elementi nazivaju još i elementima obrade (engl. *processing elements*) jer obrađuju informacije. Svaki element obrade ima ponderirane ulaze, prijenosnu funkciju i jedan izlaz. U osnovi elementi obrade (Slika 7.) čine jednadžbu koja uravnotežuje ulaze i izlaze (Agatonovic-Kustrin i Beresford, 2000). Umjetne neuronske mreže rijetko imaju više od nekoliko stotina ili nekoliko tisuća procesorskih elemenata obrade, dok usporedbe radi, ljudski mozak ima 100 milijardi neurona. Općenito govoreći, kada se uspoređuje složenost umjetne neuronske mreže i ljudskog mozga, neuronske mreže su po svojoj složenosti daleko iza sposobnosti ljudskog mozga (Agatonovic-Kustrin i Beresford, 2000).




U1, U2, U3 – ulazi; T1, T2, T3 – težinski koeficijenti; I1 - izlaz; b1 – pristranost (engl. *bais*)

Slika 7. Arhitektura umjetnog neurona. Izvor: Agatonovic-Kustrin i Beresford, 2000

Iako jedan neuron može izvesti određene jednostavne funkcije obrade podataka, snaga matematičkih modela u obliku neuronskih mreža dolazi kod povezivanja neurona u mrežu. Neuroni obično djeluju paralelno i konfigurirani su u slojevima gdje može postojati povratna veza unutar sloja i prema susjednim slojevima. Neuroni u umjetnoj neuronskoj mreži mogu biti sastavljeni u jedan, dva, tri ili čak više slojeva neurona, a funkcija neuronske mreže – obrađivanje određenih problema, ovisi o strukturi mreže. Obično će se u većini matematičkih modela umjetna neuronska mreža sastojati od triju različitih slojeva neurona: ulazni, skriveni i izlazni slojevi. Ulazni sloj ima funkciju primanja ulaznih podataka i slanja tih podataka u skrivene

slojeve. U skrivenom sloju obavljaju se sve računске simulacije na ulaznim podacima, odnosno dolazi do obrade informacija. Skriveni neuroni komuniciraju s drugim neuronima i iz skrivenog sloja informacije se prenose na neurone u izlaznom sloju. Izlazni sloj pruža odgovor neuronske mreže na ulazne podatke i proizvodi ishod. Opća struktura višeslojne umjetne neuronske mreže prikazana je na Slici 8. gdje su neuroni nacrtani kao krugovi, a težinski koeficijenti kao crte koje povezuju krugove u različitim slojevima (Zupan, 1994; Agatonovic-Kustrin i Beresford, 2000; Kulisz i Kujawska, 2020).



Slika 8. Arhitektura višeslojne umjetne neuronske mreže.

Izvor: Ghazi Zade i Noori, 2008

Umjetna neuronska mreža može se sastojati od različitog broja neurona, a broj neurona u skrivenom sloju utječe na broj veza. Tijekom faze treninga ulazi se prilagođavaju (transformiraju) po težinama veze. Stoga, broj veza značajno utječe na performanse mreže. Premalo skrivenih neurona ometat će proces učenja, dok će previše neurona zbog pretreniranja također smanjiti sposobnosti predviđanja jer nakon određenog broja iteracija mreža gubi svojstvo generalizacije (Zupan, 1994; Agatonovic-Kustrin i Beresford, 2000).

### 2.2.3. Glavna obilježja umjetnih neuronskih mreža

Umjetna neuronska mreža predstavlja obećavajuću tehniku matematičkog modeliranja, posebno za baze podataka koje imaju neki oblik nelinearnih odnosa. Neuronske mreže zahtijevaju manje formalni statistički trening, sposobne su otkriti složene nelinearne odnose između ovisnih i neovisnih varijabli i svih mogućih interakcija bez kompliciranih jednadžbi i mogu koristiti više algoritama treninga. Što se tiče specifikacije matematičkih modela, umjetne neuronske mreže ne zahtijevaju znanje o izvoru podataka, ali s obzirom na to da često sadrže



mnogo težina koje se procjenjuju, zahtijevaju velike skupove podataka za proces treninga mreže. Drugim riječima, za uspješno učenje neuronskih mreža potrebno je imati izrazito velik broj podataka. Iako je to ponekad dosta teško, neuronske mreže mogu kombinirati i uključivati podatke koji se temelje na literaturnim podacima, kao i eksperimentalne podatke za rješavanje problema (Agatonovic-Kustrin i Beresford, 2000). Što je više ulaznih podataka, to će neuronska mreža biti uspješnija u kreiranju izlaza (Peixeiro, 2019). Jedno od možda najvažnijih obilježja umjetnih neuronskih mreža je da su manje osjetljive na nepotpune informacije pa mogu raditi s nesavršenim ili manjkavim podacima i svejedno doći do dobrih rezultata. Navedeno znači da su neuronske mreže prilagodljive okolini i da su sposobne obraditi opsežne količine podataka i kreirati predviđanja s ponekad iznenađujućom razinom točnosti (Dalbello Bašić i sur., 2008). Umjetne neuronske mreže su, također, prilično fleksibilne za prilagodbu različitim vrstama problema i mogu se prilagoditi gotovo svim vrstama podataka. Širok spektar primjene umjetnih neuronskih mreža može se sažeti u klasifikaciju ili prepoznavanje uzoraka, predviđanje, grupiranje, matematičko modeliranje i drugo (Agatonovic-Kustrin i Beresford, 2000; Beresford, 2000; Zupan, 1994).

#### **2.2.4. Vrste umjetnih neuronskih mreža i pravila učenja**

Mnogo je vrsta neuronskih mreža koje su dizajnirane do sada, a konstantno se kreiraju i nove mreže. Sve se mogu opisati prijenosnim funkcijama njihovih neurona i pravilom učenja. Umjetna neuronska mreža uči kroz iskustvo s odgovarajućim uzorima učenja, baš kao što to čine i ljudi. Pod učenjem misli se na iterativni postupak podešavanja vrijednosti težinskih faktora kako bi se smanjile pogreške između proračunate vrijednosti matematičkim modelom i stvarne vrijednosti (Ivić i sur., 2012). Neuronske mreže „prikupljaju” znanje otkrivanjem obrazaca i odnosa u podacima. Način na koji su neuroni međusobno povezani ima značajan utjecaj na rad umjetne neuronske mreže.

Dvije vrste arhitekture mogu se identificirati prema odsutnosti ili prisutnosti povratne veze u umjetnim neuronskim mrežama. Neke neuronske mreže imaju povratnu vezu među slojevima (engl. *feedback*). Povratna sprega je vrsta veze kod koje se izlaz jednog sloja vraća natrag na ulaz prethodnog sloja ili na isti sloj. Arhitektura povratne sprege ima veze od izlaznih do ulaznih neurona. Svaki neuron ima jednu dodatnu težinu kao ulaz koji će omogućiti dodatni stupanj slobode pri pokušaju minimiziranja pogrešaka. Takva mreža čuva uspomenu na prethodno stanje tako da sljedeće stanje ne ovisi samo o ulaznom signalu nego i o prethodnim stanjima mreže. Druga vrsta arhitekture (engl. *feedforward*) nema povratnu spregu od izlaznih do

ulaznih neurona i stoga ne vodi evidenciju svojih prethodnih izlaznih vrijednosti (Agatonovic-Kustrin i Beresford, 2000).

Postoji mnogo različitih pravila učenja, ali najčešće se koristi Delta pravilo ili Pravilo povratnog širenja (engl. *backpropagation*). Pravilo povratnog širenja ili širenje unatrag funkcionira tako da ulazni sloj primi podatke i pošalje ih u skrivene slojeve gdje se podaci obrađuju i stižu do izlaznog sloja. Nakon toga, informacije se „puštaju“ nazad kroz mrežu, a vrijednosti težinskih koeficijenata između neurona prilagođavaju se željenom izlazu. Navedeni proces ponavlja se onoliko puta koliko je potrebno da dobiveni izlaz bude najbliži željenom odnosno stvarnom izlazu. Navedeno se postiže tako da se softveru zadaje koliki je najveći broj iteracija koje će ostvariti minimum grešaka, pri čemu mreža uspoređuje ciljani rezultat sa stvarnim rezultatom i izračunava pogrešku. Ponovno valja naglasiti da ako se mreža predugo trenira, pretrenirat će se i izgubit će sposobnost generaliziranja (Antanasijević i sur., 2013; Dumančić, 2014; Agatonovic-Kustrin i Beresford, 2000).

Pravilo povratnog širenja (engl. *backpropagation*) prvi je kreirao Paul Werbos 1974. godine, dok su navedeni algoritam proširili i doradili Rumelhart, Hinton i Williams (Rumelhart i sur., 1985). Pravilo širenja unatrag učinilo je neuronske mreže učinkovitim, široko upotrebljivom i popularnom metodom (Werbos, 1974). Pravilo širenja unatrag uči na primjeru, a broj neurona u ulaznom i izlaznom sloju jednak je broju ulaznih i izlaznih parametara koji se koriste u matematičkom modelu (Antanasijević i sur., 2013; Dumančić, 2014; Agatonovic-Kustrin i Beresford, 2000).

Nešto drugačije pravilo učenja u odnosu na metode povratnog širenja je Kohonen neuronska mreža. Glavna razlika je ta što je Kohonen umjetna neuronska mreža „samoorganizirajući“ sustav koji je sposoban riješiti probleme bez nadzora. U nenadziranim problemima (poput klastera) nije potrebno unaprijed znati kojem klasteru ili grupi pripadaju objekti treninga. Kohonen neuronska mreža automatski se prilagođava na takav način da su slični ulazni objekti povezani s topološkim bliskim neuronima u mreži. Izraz „topološki bliski neuroni“ znači da će neuroni koji su fizički smješteni blizu reagirati slično na slične ulazne podatke, dok neuroni koji su udaljeniji u rasporedu mreže reagiraju sasvim drugačije na slične ulaze. Najvažnija razlika između Pravila povratnog širenja i Kohonen pravila jest da neuroni kod Pravila povratnog širenja pokušavaju kvantitativno dati odgovor što bliži cilju, dok u Kohonenu pokušavaju naučiti/pronaći precizno i točno određeno mjesto u neuronskoj mreži koje je najviše „slično“ ulaznom vektoru (Zupan, 1994).

### 2.2.5. Kreiranje umjetne neuronske mreže

Prvi zadatak koji korisnik mora obaviti kada pokušava primijeniti bilo koju metodu učenja za klasično matematičko modeliranje, prepoznavanje uzoraka ili kreiranje umjetne neuronske mreže je odabir skupa podataka za trening. Osoba koja pokušava kreirati bilo koji postupak učenja treba imati na umu kako je za bilo koji postupak učenja najbolja strategija podijeliti dostupne podatke na tri skupa podataka. Ne postoji točno pisano pravilo po kojem bi se podaci mogli podijeliti u uzorke, ali preporučljivo je da najveći dio podataka služi za treniranje odnosno učenje. Samo ime govori kako prvi set podataka služi za učenje u užem smislu, odnosno podešavanje težinskih faktora. Podešavanje težinskih koeficijenata u neuronskoj mreži odvija se u više iterativnih ponavljanja. Kao što je rečeno, najveći dio podataka čini upravo ovaj set i to 60 do 70 %. Drugi set podataka je kontrolni set odnosno set za provjeru (ili set za fino podešavanje) te čini 15 do 20 % podataka. U ovom setu vrijednosti težinskih koeficijenata su fiksne i dodaju se nove ulazne vrijednosti, dok se od mreže očekuje da odredi pripadajući izlazni parametar. U trećem setu, jednako kao i u drugom, koristi se 15 do 20 % podataka za testiranje neuronske mreže (Zupan, 1994). Trening neuronskih mreža svodi se na učenje iz primjera kojih bi trebalo biti što više kako bi izlazi iz mreža bili što točniji. Podaci iz skupa za učenje periodično se propuštaju kroz mreže, a kasnije se dobivene vrijednosti uspoređuju s očekivanim vrijednostima i poboljšavaju mijenjanjem težinskih koeficijenata. Kada se izlazi iz neuronske mreže dobiveni na temelju primjera iz skupa za testiranje konstantno prate, moguće je otkriti iteraciju u kojoj se dobiveni izlaz iz mreže najmanje razlikuje od željenog podatka. Kada umjetna neuronska mreža proizvede željeni izlaz (tj. osposobi se na zadovoljavajuću razinu), spremaju se ponderirane veze između jedinica. Ti se težinski koeficijenti zatim koriste kao analitički alat za predviđanje rezultata za novi skup ulaznih podataka (Agatonovic-Kustrin i Beresford, 2000).

Kao što je već prethodno objašnjeno, neuroni su u mreži organizirani u dva ili više slojeva, gdje je prvi sloj ulazni sloj, a posljednji izlazni. Sloj između ulaznog i izlaznog je unutrašnji skriveni sloj. Kada se razvija neuronska mreža neophodno je izabrati broj skrivenih slojeva i broj neurona u njima. Proces utvrđivanja odgovarajućeg broja skrivenih slojeva i neurona u njima jedan je od najvažnijih zadataka kod kreiranja neuronskih mreža. Pri tome treba imati na umu da više skrivenih slojeva može izazvati pojavu problema lokalnih minimuma i sporije konvergencije u toku faze učenja mreže. Zbog navedenog se savjetuje korištenje samo jednog skrivenog sloja (Peters i Iberg, 1978; Petrović, 2011). Broj skrivenih neurona ovisi o broju ulaza i izlaza i preporučuje se da broj skrivenih neurona bude između broja ulaza i izlaza, i to tako da

broj skrivenih neurona bude jednak  $2/3$  veličine ulaznog sloja plus veličina izlaznog sloja ili manje od udvostručenog broja ulaznih podataka (Demuth i Beale, 1992).

Prije nego što se podaci puste kroz mrežu, za svaki ulazni podatak i za izlazne rezultate koji se koriste u kreiranju neuronske mreže vrši se normalizacija vrijednosti u bazi podataka. Vrijednost normalizacije je u rasponu između 0 i 1, najčešće bez graničnih vrijednosti (u praksi se rijetko događa da atribut ima vrijednost 0, već se svi atributi nalaze u intervalu između 0 i 1). Normalizirane vrijednosti nemaju nikakvo fizičko značenje, već je svrha promjena raspodjele ulaznih varijabli kako bi se bolje uklopile u raspodjelu predviđenih izlaza. Na ovaj se način ubrzava faza učenja mreže (Marković, 2007; Tschegg i sur., 2009).

Nakon kreiranja neuronskih mreža dodatno je potrebno napraviti i analizu osjetljivosti (engl. *sensitivity analysis*) na osnovu razvijenog matematičkog modela u obliku neuronske mreže. Analiza osjetljivosti radi se zbog proučavanja utjecaja promatranih ulaznih varijabli, dobivenih nesigurnosti matematičkog modela i općenito zbog proučavanja ponašanja neuronske mreže (Basheer i Hajmeer, 2000; Taylor, 2006). Cilj analize osjetljivosti je utvrditi koliko je matematički model „osjetljiv“ na promjene vrijednosti parametara modela i na promjene u strukturi modela. Ova analiza na jednostavan način može procijeniti ponašanje sistema jednadžbi koji definiraju matematički model. Ako je određen podatak jako osjetljiv na malu promjenu nekog parametra, navedeno sugerira da će se izlaz iz mreže drastično promijeniti (Tschegg i sur., 2009). Stoga je analizu osjetljivosti potrebno napraviti kako bi se utvrdilo hoće li i pod kojim uvjetima doći do pogrešaka u predviđanju izlaznih rezultata te kako bi se utvrdio utjecaj ulaznih podataka na izlazne rezultate (Trelea i sur., 1997). Zaključno se može reći kako su neuronske mreže koristan i sve češće korišten alat u zadacima koji uključuju klasifikaciju, procjenu i predviđanje, ali glavni nedostatak umjetnih neuronskih mreža je nedostatak interpretacija stečenog znanja na temelju matematičkog modela.

### 3. MATERIJALI I METODE

Istraživanje je provedeno s ciljem kreiranja umjetne neuronske mreže na temelju koje će se predvidjeti europski i nacionalni pokazatelji u gospodarenju četirima vrstama biorazgradivoga komunalnog otpada koji će nastati na razini EU-a i na nacionalnom nivou u vremenskom razdoblju od 2020. do 2025. godine.

#### 3.1. Metodološki pristup

Za provedbu ovog istraživanja koristit će se umjetne neuronske mreže kao alat za izradu matematičkog modela na temelju kojeg se želi predvidjeti količina nastalog biorazgradivoga komunalnog otpada. Matematički model bit će kreiran primjenom softverskog alata za modeliranje (StatSoft Statistica 2010, programsko okruženje R, verzija 4.0.4). Uz sam razvoj matematičkog modela, ovo istraživanje uključit će i optimizaciju te ispitivanje/testiranje i validaciju umjetne neuronske mreže za predviđanje stvaranja različitih vrsta otpada. Za razvoj matematičkog modela korišteni su podaci koji na temelju dostupne literature mogu utjecati na količinu stvaranja otpada. Ulazni sociodemografski i ekonomski podaci prikupljeni su za vremenski niz od 25 godina za razdoblje od 1995. do 2019. godine i za 17 država EU-a: Belgiju, Češku, Dansku, Estoniju, Francusku, Hrvatsku, Irsku, Italiju, Latviju, Litvu, Luksemburg, Mađarsku, Maltu, Nizozemsku, Sloveniju, Španjolsku i Švedsku. Prikupljeni podaci predstavljaju numeričke ili kategorijske varijable. Podaci su prikupljeni koristeći javno dostupne podatke iz nacionalnih i europskih mrežnih statističkih stranica, publikacija, znanstvenih članaka te mrežnih stranica nacionalnih agencija i resornih ministarstava. Od posebne pomoći bila je mrežna stranica Eurostat. Nakon što su se prikupili i provjerili svi podaci, krenulo se s izradom umjetne neuronske mreže. U ovom istraživanju koristit će se višeslojni perceptron model (engl. *Multi-Layer Perceptron* – MLP) koji će se sastojati od ukupno triju slojeva: ulaznog, skrivenog i izlaznog. Navedeni matematički model predstavlja najčešću i najpraktičniju arhitekturu neuronskih mreža (Heidari i sur., 2016).

Izrada umjetne neuronske mreže započinje kreiranjem matematičkog modela, definiranjem seta ulaznih varijabli i izlaznih rezultata te prilagodbom podataka potrebama razvoja modela i njihovim formatiranjem. Za razvoj modela korišteni su podaci u obliku ukupnih godišnjih podataka za svaku državu. Kao set ulaznih varijabli koristit će se sljedeći podaci:

- demografski podaci (broj stanovnika, očekivani životni vijek)

- podaci o ekonomskom napretku (BDP po tržišnim cijenama, BDP po stanovniku, ukupne obveze financijskog sektora, neto inozemni dug, nominalni efektivni tečaj, izravna ulaganja u izvještajnu ekonomiju, indeks cijena kuća)
- podaci o broju (ne)zaposlenih (broj ukupno zaposlenih, stopa nezaposlenosti, stopa nezaposlenosti mladih)
- podaci o robnoj razmjeni (uvoz robe i usluga, izvoz robe i usluga, izvoz nafte i naftnih derivata)
- podaci o razini obrazovanja
- podaci o turizmu (dolasci u objekte turističkog smještaja, broj noćenja u objektima turističkog smještaja)
- podaci o otpadu (godišnja proizvodnja komunalnog otpada u tisućama tona, proizvodnja komunalnog otpada po stanovniku, stopa recikliranja komunalnog otpada, odlaganje otpada).

Tablica 6. prikazuje točan popis korištenih varijabli koji predstavljaju ulazne podatke. Zbog jednostavnosti prilikom obrade podataka i prikaza rezultata, korištene su kratice za sve korištene varijable koje su također prikazane u Tablici 6. Korišteni ulazni podaci prikazani su u Prilogu 2.

Izlazni rezultati bit će:

- količine miješanoga komunalnog otpada (MMPW) u tisućama tona, ključni broj 20 03 01
- količine neopasnog otpadnog papira i kartona (PCW) u tisućama tona, ključni brojevi 15 01 01, 19 12 01 i 20 01 01
- količine neopasnog otpadnog drva (WW) u tisućama tona, ključni broj 15 01 03
- količine neopasnog otpadnog tekstila (TW) u tisućama tona, ključni broj 20 01 10.

Tablica 6. Popis korištenih kratica i pripadajuća objašnjenja

Ulazni podaci	Korištena kratica	Objašnjenje kratice
Broj stanovnika	POP	<i>Population</i>
Očekivani životni vijek	LE	<i>Life Expectancy</i>
Bruto domaći proizvod po tržišnim cijenama	GDP	<i>Gross Domestic Product at market prices</i>
Bruto domaći proizvod po stanovniku	RGDP	<i>Real GDP per capita</i>
Ukupne obveze financijskog sektora	TFS	<i>Total Financial Sector liabilities, by sub-sectors</i>
Neto vanjski (inozemni) dug	NED	<i>Net External Debt</i>
Nominalni efektivni tečaj	NEER	<i>Nominal Effective Exchange Rate</i>
Inozemna izravna ulaganja	DIRE	<i>Direct Investment in the Reporting Economy</i>
Deflacionirane cijene nekretnina	HPI	<i>House Price Index, deflated</i>
Ukupno zaposleni 15. – 64. god.	TEMP	<i>Total Employees from 15 - 64 years</i>
Godišnji podaci o stopi nezaposlenosti	URAD	<i>Unemployment rate</i>
Stopa nezaposlenosti mladih	YUR	<i>Youth Unemployment Rate</i>
Srednji ekvivalent neto prihoda	MENI	<i>Median Eequivalised Net Income</i>
Uvoz roba i usluga	IGS	<i>Imports of Goods and Services</i>
Izvoz roba i usluga	EGS	<i>Exports of Goods and Services</i>
Izvoz nafte i naftnih derivata po zemljama partnerima	EOPP	<i>Exports of Oil and Petroleum Products by partner country</i>
Predškolsko obrazovanje, primarno obrazovanje i niže sekundarno obrazovanje	EL1	<i>Less than primary, primary and lower secondary education</i>
Više sekundarno obrazovanje, post-sekundarno netercijarno obrazovanje i tercijarno obrazovanje	EL2	<i>Upper secondary, post-secondary non-tertiary and tertiary education</i>
Više srednje obrazovanje i post-sekundarno, netercijarno obrazovanje	EL3	<i>Upper secondary and post-secondary non-tertiary education</i>
Visoko obrazovanje	ELT	<i>Tertiary education</i>
Dolasci u turističke smještajne objekte	ATAE	<i>Arrivals at Tourist Accommodation Establishments</i>
Noćenja u turističkim smještajnim objektima	NSTA	<i>Nights Spent at Tourist Accommodation establishments</i>
Nastali komunalni otpad – prikaz u tisućama tona	GMWT	<i>Generation of Municipal Waste thousand Tonnes</i>
Nastali komunalni otpad – kilogram po stanovniku	GMWK	<i>Generation of Municipal Waste Kilograms per capita</i>
Stopa recikliranja komunalnog otpada	RRMW	<i>Recycling Rate of Municipal Waste</i>
Odlaganje komunalnog otpada	DL	<i>Disposal - Landfill</i>

Ulazni podaci prenose se između slojeva uz pomoć prijenosnih i aktivacijskih funkcija. Te su funkcije uobičajeno linearne za ulazne i izlazne slojeve, a nelinearne aktivacijske funkcije djeluju između ulaznog i skrivenog sloja, kao i između skrivenog i izlaznog sloja.

Prikupljeni podaci obradit će se osnovnim statističkim metodama (deskriptivna statistika, analiza korelacije, analiza varijance) koje se koriste kako bi se podaci mogli lakše grupirati po željenim kriterijima te kako bi se jasnije vidjeli trendovi i odnos između ulaznih i izlaznih podataka. Izradit će se i klaster analiza (engl. *cluster analysis*), kao i analiza glavnih komponenti (engl. *principal component analysis* – PCA).

Prije kreiranja umjetne neuronske mreže, ulazni i izlazni podaci normaliziraju se koristeći *min-max* normalizacije. Svrha ove numeričke transformacije je u izmjeni oblika raspodjele ulaznih podataka kako bi ona što bolje odgovarala raspodjeli izlaznih podataka. Na ovaj način ujedno se ubrzava i faza učenja neuronske mreže (Tschegg i sur., 2009).

Prije početka računanja matematičkog modela, prema preporuci iz programa StatSoft Statistica, set podataka podijelit će se na slučajan način, stohastičkim pristupom na set podataka za učenje (60 % podataka), provjeru (20 %) i testiranje neuronske mreže (20 %).

Zbog razvijanja mreže neophodno je odabrati optimalan broj skrivenih slojeva i optimalan broj neurona u njima. U ovom radu prilikom računanja modela neuronske mreže testirano je više različitih topologija, gdje je broj skrivenih neurona varirao od 5 do 30, a proces treninga mreže izveden je sto tisuća puta sa slučajnim početnim vrijednostima težinskih koeficijenata i nultih vrijednosti. Prvobitna procjena potrebnog broja neurona dobiva se na temelju sljedeće jednadžbe (1).

$$m = n \cdot (x + 1) + y \cdot (n + 1) \quad (1)$$

U navedenoj je jednadžbi  $m$  broj težinskih koeficijenata, odnosno veza između slojeva u neuronskoj mreži,  $n$  broj neurona u skrivenom sloju, a  $x$  i  $y$  predstavljaju broj ulaznih i izlaznih neurona (Charambous, 1992; Demuth i Beale, 1992).

Postupak optimizacije izveden je na temelju minimiziranja pogrešaka validacije. Pretpostavljalo se da je obuka provedena zadovoljavajuće kada su krivulje učenja i unakrsne provjere dosegle nulu. Koeficijenti povezani sa skrivenim slojem (težinski koeficijenti i nulte vrijednosti) uvedeni su u matrice  $W_1$  i  $B_1$ . Slično, koeficijenti povezani s izlaznim slojem opisani su u matricama  $W_2$  i  $B_2$ . Matematički model neuronske mreže ( $Y$ ) može se predstaviti pomoću matričnog zapisa, jednadžbom 2.



$$Y = f_1(W_2 \cdot f_2(W_1 \cdot X + B_1) + B_2) \quad (2)$$

U navedenoj su jednadžbi  $f_1$  i  $f_2$  nelinearne prijenosne funkcije u skrivenim i izlaznim slojevima, a  $X$  je matrica ulaznih varijabli. Matrica  $W_1$  i vektor  $B_1$  koriste se da transformiraju vektor ulaznih podataka u vrijednosti koje su zapisane u skrivenom sloju, a matrica  $W_2$  i vektor  $B_2$  koriste se da transformiraju vrijednosti sadržane u skrivenom sloju u vektor izlaznih podataka.

Težinski koeficijenti ponovno su izračunati tijekom cijelog ciklusa učenja neuronske mreže primjenom operacije racionalizacije kako bi se smanjila pogreška između mreže i prikupljenih rezultata što odgovara sumi kvadrata (SS) i izračunu primijenjenom za ubrzavanje i konsolidaciju konvergencije. Učinkovitost matematičkog modela ispitivana je tijekom izračuna pomoću koeficijenata determinacije. Yoonova metoda korištena je za određivanje relativnog utjecaja ulaznih slojeva na izlazne slojeve. Ova se metoda primijenila na temelju težinskih koeficijenata razvijene neuronske mreže.

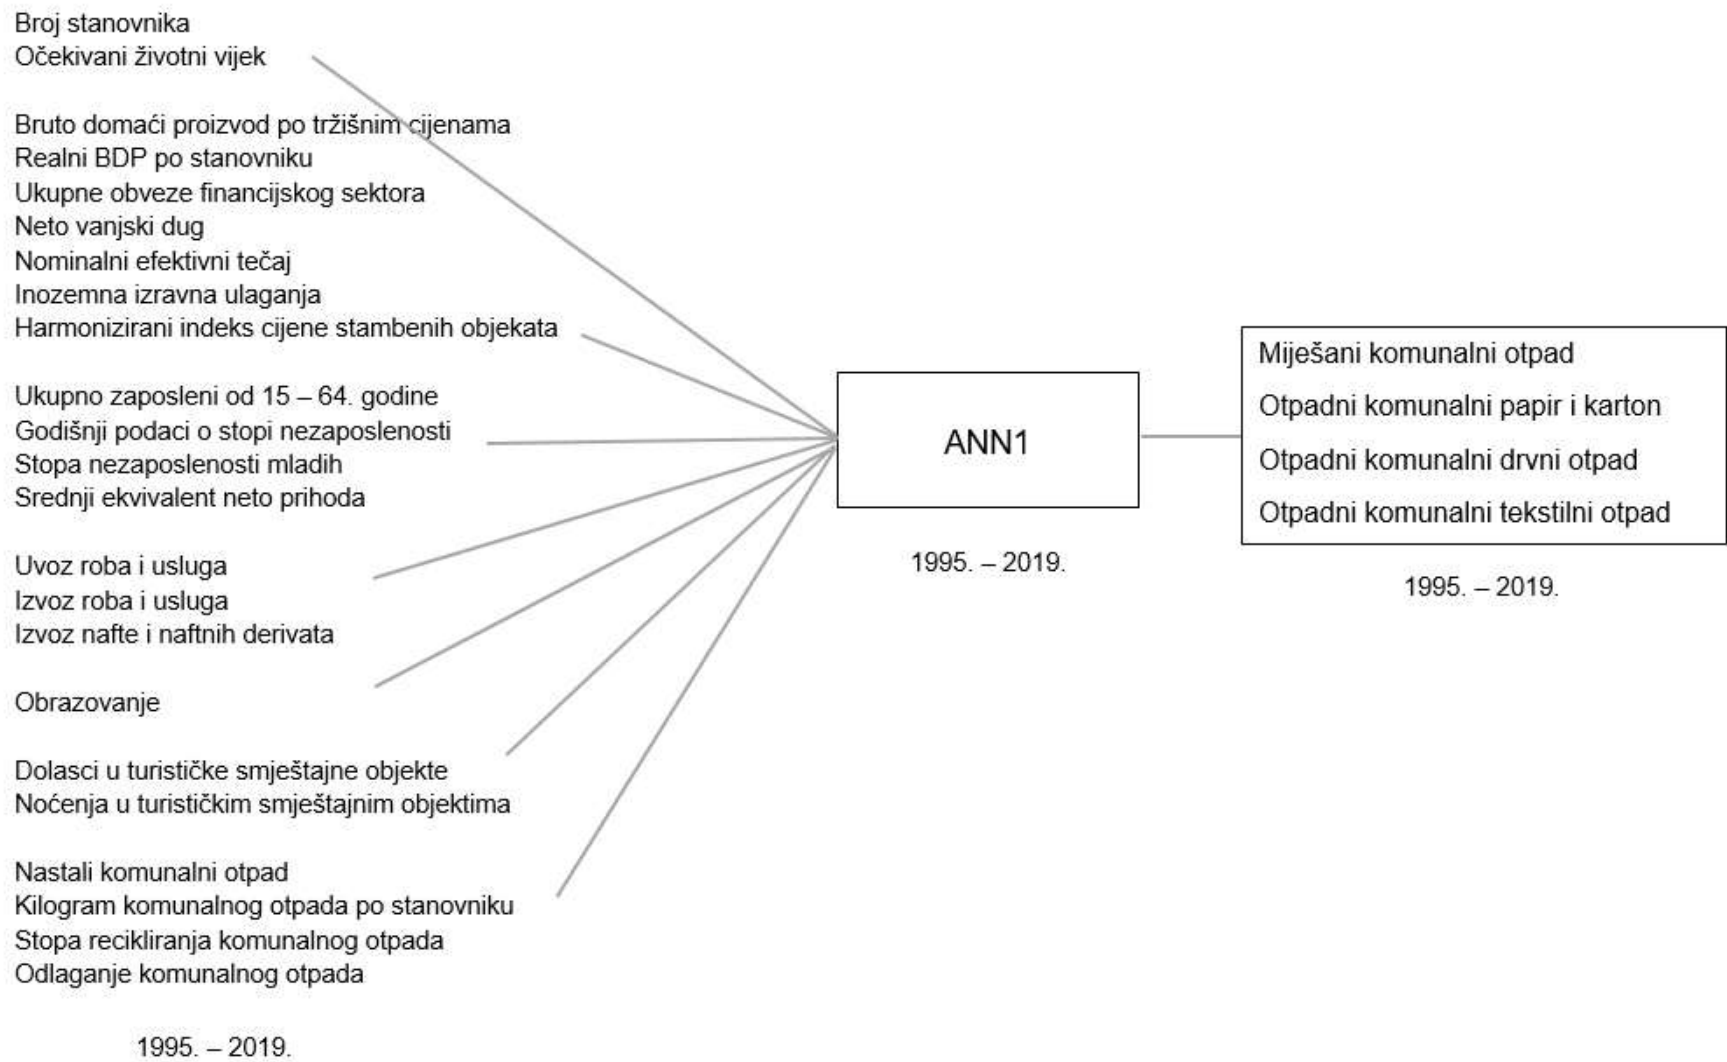
### **3.2. Osnovni koraci pri kreiranju matematičkog modela korištenjem umjetnih neuronskih mreža specifičnih za ovo istraživanje**

U ovom doktorskom radu korišteni su podaci sljedećeg formata: 28 ulaznih podataka i 4 izlazne varijable. Od ulaznih podataka prisutna je jedna kontinuirana varijabla – vrijeme (odnosno godine) i jedna kategorijska varijabla – naziv države. Podaci za 17 država i 25 godina (ukupno set od  $17 \times 25 = 425$  varijabla) čine dovoljno podataka za kreiranje matematičkog modela.

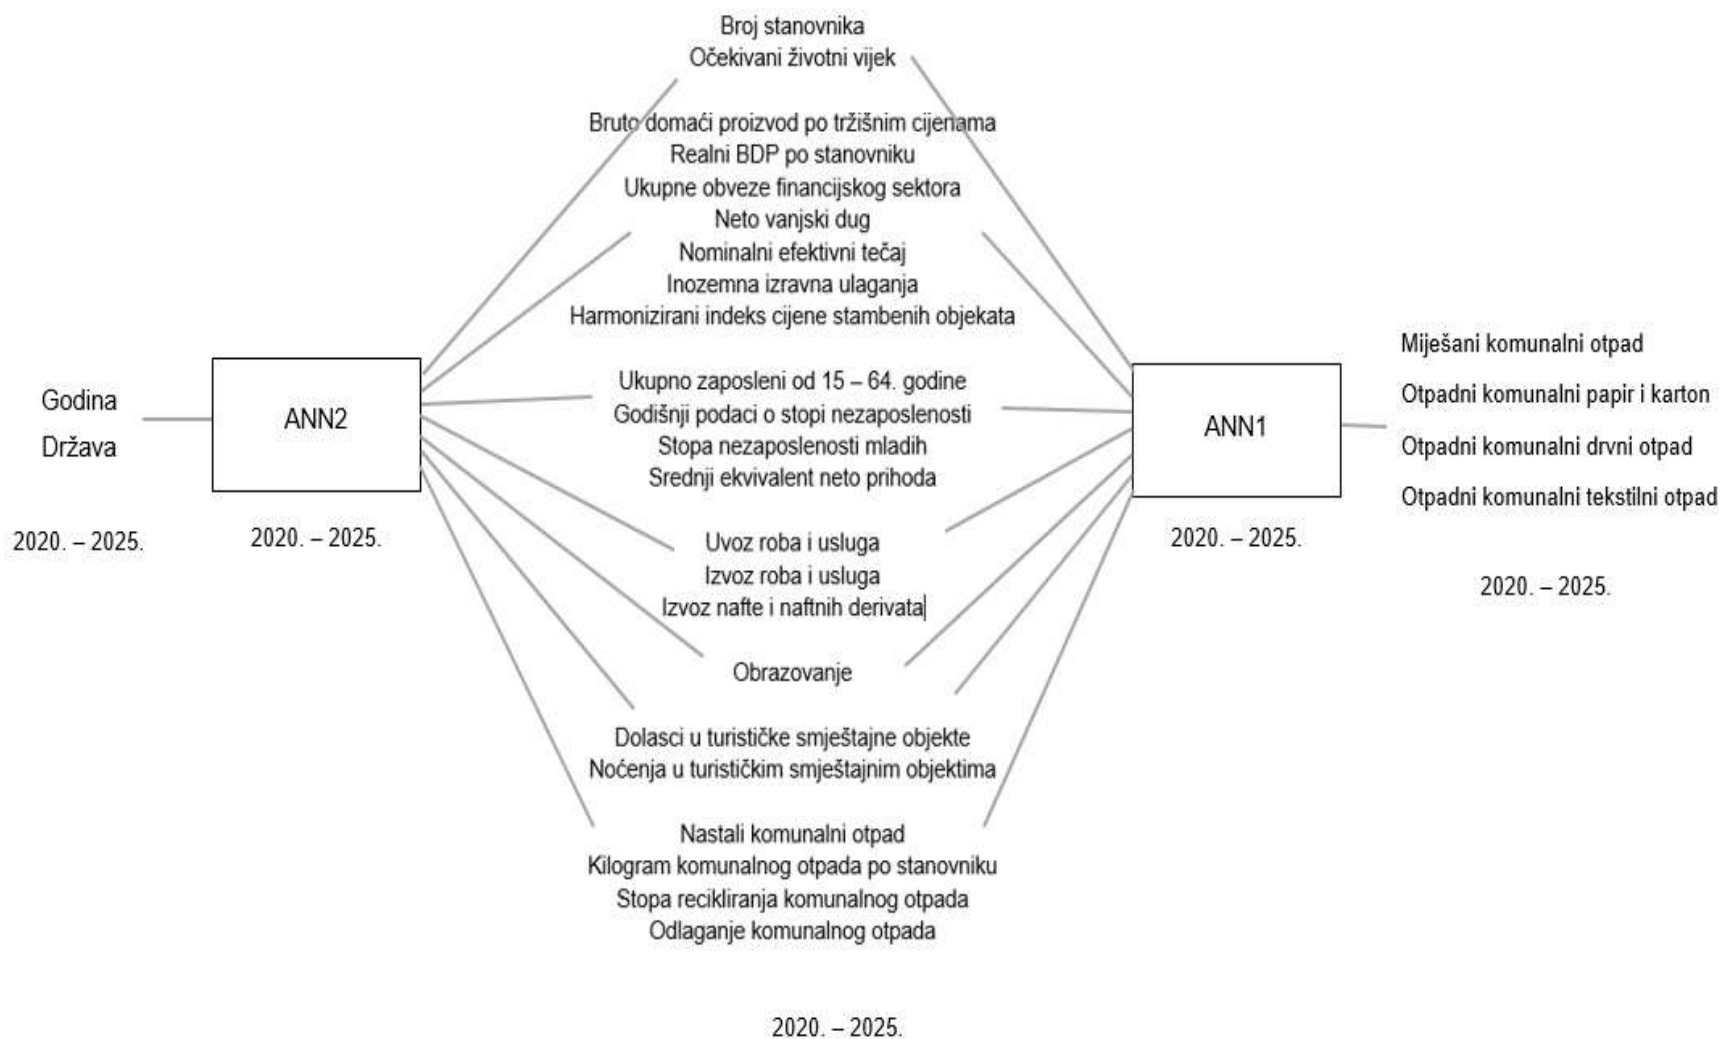
Na temelju prikupljenih ulaznih podataka kreiran je matematički model koji za cilj ima predviđanje izlaznih rezultata (4 frakcije biorazgradivoga komunalnog otpada u tisućama tona) od 1995. do 2019. godine. U bazi ulaznih podataka nedostajali su neki podaci, ali u ovoj fazi umjetna neuronska mreža predviđa i njih. Navedeni proces grafički je prikazan na Slici 9.

S obzirom na to da je cilj istraživanja predvidjeti količine biorazgradivoga komunalnog otpada koje će nastati u bliskoj budućnosti (konkretno od 2020. do 2025. godine), prvo je potrebno imati/predvidjeti ulazne podatke za isto razdoblje (2020. – 2025.). Navedeno je također učinjeno primjenom umjetnih neuronskih mreža (Slika 10.). Potrebno je bilo kreirati 26 modela na temelju varijable – vrijeme (odnosno godine) i kategorijske varijable – naziva države. Sada se u početnom matematičkom modelu koji je kreiran ranije ulazni podaci (od 1995. do 2019.) zamjenjuju „novim“, predviđenim podacima (od 2020. do 2025.). Riječ je o istim ranije spomenutim sociodemografskim i ekonomskim parametrima, ali s podacima za različito

vremensko razdoblje i za različite države. Na temelju ovih podataka dobit će se podaci za 17 država članica Europske unije za 26 ulaznih podataka i četiri izlazna podatka za razdoblje od 2020. do 2025. godine.



Slika 9. Grafički prikaz parametara korištenih pri kreiranju matematičkog modela u ovom istraživanju



Slika 10. Povezanost matematičkih modela korištenih u ovom istraživanju

### 3.3. Matematički model za predviđanje ulaznih podataka za razdoblje od 2020. do 2025. godine (ANN2)

Za uspostavljanje 26 ANN modela korišten je višeslojni model perceptrona (MLP) koji se sastojao od triju slojeva (ulazni, skriveni i izlazni). Ovaj model pokazao se kao prilično sposoban za aproksimiranje nelinearne funkcije (Grieu i sur., 2011; Karlović i sur., 2013). Najprije su ulazni podaci i izlazni rezultati normalizirani da bi se poboljšalo ponašanje neuronske mreže. Tijekom ovog iterativnog procesa ulazni su podaci više puta predstavljeni mreži (Kollo i von Rosen, 2005; Pezo, i sur., 2013). Broyden-Fletcher-Goldfarb-Shanno (BFGS) algoritam korišten je kao iterativna metoda za rješavanje nelinearnih jednadžbi i nalaženje optimalnog rješenja u procesu modeliranja neuronske mreže.

Eksperimentalna baza podataka za ANN nasumično je podijeljena na: podatke za učenje, unakrsnu validaciju i testiranje (sa 60 %, 20 % i 20 % eksperimentalnih podataka). Skup podataka za učenje korišten je za ciklus učenja ANN-a, kao i za procjenu optimalnog broja neurona u skrivenom sloju i za procjenu težinskoga koeficijenta svakog neurona u mreži. Pretpostavljalo se da je uspješna obuka postignuta kada su se krivulje učenja i unakrsne validacije približile nuli.

Koeficijenti povezani sa skrivenim slojem (težinski koeficijenti i nulte vrijednosti) grupirani su u matrice  $W_1$  i  $B_1$ . Slično tome, koeficijenti povezani s izlaznim slojem grupirani su u matrice  $W_2$  i  $B_2$ . Neuronsku mrežu moguće je predstaviti korištenjem matrice notacije, kao i kod matematičkog modela ANN1.

Težinski koeficijenti (elementi matrica  $W_1$  i  $W_2$ ) određeni su tijekom ciklusa učenja ANN-a, tijekom kojega su ažurirani koristeći procedure optimizacije kako bi se minimizirala greška između mrežnih i eksperimentalnih izlaza (Basheer i Hajmeer, 2000; Montaño i Palmer, 2003; Kollo i von Rosen, 2005), prema sumi kvadrata i BFGS algoritmu, koji se koristi za ubrzavanje i stabilizaciju konvergencije. Koeficijenti determinacije korišteni su kao parametri za provjeru performansi dobivenog ANN modela. Dobiveni optimalni modeli neuronske mreže pokazali su dobru sposobnost generalizacije za podatke iz baze i mogli bi se koristiti za vrijednosti socioekonomskih parametara (POP, LE, EL1, EL2, EL3, ELT, GDP, RGDP, TFS, NED, NE ER, DIRE, TEMP, URAD, YUR, MENI, ATAE, NSTA, IGS, EGS, EOPP, HPI, RRMW, DL, GMWK i GMWT) iz širokog spektra ulaznih parametara.

U Prilogu 5. (Tablica 61. – Tablica 112.) predstavljeni su elementi matrica  $W_1$  i vektora  $B_1$  i elementi matrica  $W_2$  i vektora  $B_2$ .

### 3.4. Točnost matematičkog modela

Numerička provjera dobivenog modela umjetne neuronske mreže ispitana je korištenjem koeficijenta determinacije ( $r^2$ ), reduciranog hi-kvadrata ( $\chi^2$ ), srednje pogreške pristranosti (MBE), korijenske srednje pogreške (RMSE) i srednje postotne pogreške (MPE), sume kvadrata grešaka (SSE) i srednjeg apsolutno relativnog odstupanja (AARD). Ovi parametri računali su se na sljedeći način (jednadžbe 3 – 8):

$$\chi^2 = \frac{\sum_{i=1}^N (x_{\text{exp},i} - x_{\text{pre},i})^2}{N - n} \quad (3)$$

$$MBE = \frac{1}{N} \cdot \sum_{i=1}^N (x_{\text{pre},i} - x_{\text{exp},i}) \quad (4)$$

$$RMSE = \left[ \frac{1}{N} \cdot \sum_{i=1}^N (x_{\text{pre},i} - x_{\text{exp},i})^2 \right]^{1/2} \quad (5)$$

$$MPE = \frac{100}{N} \cdot \sum_{i=1}^N \left( \frac{|x_{\text{pre},i} - x_{\text{exp},i}|}{x_{\text{exp},i}} \right) \quad (6)$$

$$SSE = \sum_{i=1}^N (x_{\text{pre},i} - x_{\text{exp},i})^2 \quad (7)$$

$$AARD = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{x_{\text{exp},i} - x_{\text{pre},i}}{x_{\text{exp},i}} \right| \quad (8)$$

U jednadžbama  $\chi_{\text{exp},i}$  označava prikupljene vrijednosti,  $\chi_{\text{pre},i}$  su predviđene vrijednosti izračunate prema matematičkom modelu,  $N$  i  $n$  su broj opažanja (konstante).

U ovom istraživanju metodom pokušaja i pogreške umjetne neuronske mreže „uče“ iz seta podataka za učenje na temelju višestruko ponovljenih iteracija i tendencije da numeričko rješenje konvergira. Umjetne neuronske mreže koje će se koristiti također „uče“ koristeći metodu povratnog širenja ili širenja unatrag (engl. *backpropagation*) algoritma pri kojem se podešavaju težinski koeficijenti svakog neurona u mreži na temelju odstupanja izlaznih rezultata od dostupnih mjerenih vrijednosti (rješavanje skupa nelinearnih jednadžba vrši se korištenjem Levenberg–Marquardt algoritma). Srednja kvadratna greška u izračunatoj vrijednosti izlaza šalje se unazad kroz sistem neurona, pri čemu dolazi do proporcionalnih promjena vrijednosti težinskih koeficijenata koje se podešavaju, u odnosu od pravca gradijenta

greške izlaza u usporedbi s poznatim vrijednostima, s ciljem minimiziranja pogreške. Cilj je obraditi što veći broj uzoraka u fazi učenja kako bi se osigurala najbolja kvaliteta izlaznih parametara u odnosu na ulazne, što se postiže kada razvijen matematički model pokazuje najniže vrijednosti SS-a, čime se postiže optimizacija. Kako bi se izbjegla prekomjerna specijalizacija modela, primjenjuje se postupak ranog zaustavljanja učenja mreže koji je inkorporiran u postupak učenja u trenutku kada se dobiju najmanje vrijednosti sume kvadrata. Osim sume kvadrata, kao parametar za provjeru točnosti mreže upotrijebljen je i koeficijent determinacije  $r^2$ . Nakon odabira najbolje mreže matematički model može se implementirati korištenjem algebarskog sistema jednadžbi radi predviđanja željenih vrijednosti (količine miješanoga komunalnog otpada, količine neopasnog otpadnog papira i kartona, količine neopasnog otpadnog drva i tekstila) zamjenom odgovarajućih težinskih koeficijenata i koeficijenata u matricama u jednadžbi.

Nakon razvoja matematički model potrebno je optimizirati te napraviti analizu osjetljivosti ulazno-izlaznih varijabli da bi se utvrdilo hoće li i pod kojim uvjetima doći do grešaka u predviđanju izlaznih promjenjivih parametara i utvrditi utjecaj ulaznih varijabli na promatrane izlaze.

### **3.5. Ograničenja prikupljenih podataka**

Kod korištenja umjetnih neuronskih mreža kvaliteta rezultata ovisi o kvaliteti ulaznih podataka. Što su ulazni podaci brojniji i kvalitetniji, i sami rezultati bit će kvalitetniji i bolji. Vodeći se navedenom činjenicom, u ovom istraživanju željelo se koristiti što je moguće više čimbenika koji bi mogli utjecati na nastanak otpada. Veliko ograničenje ovog istraživanja leži upravo u podacima o otpadu. Naime, iako se sociodemografski i ekonomski podaci, kao i podaci o turizmu, kontinuirano prate u svim državama EU-a i dostupni su na godišnjoj, kvartalnoj ili čak mjesečnoj razini, to nije slučaj s podacima o otpadu. Kao što je već ranije spomenuto, ne postoji globalna baza koja bi pokrivala područje otpada s potrebnim podacima. Na području EU-a Eurostat prikuplja, između ostalog, i podatke o otpadu. Države članice prema trenutnoj zakonskoj obvezi konačne podatke o komunalnom otpadu prijavljuju prema formuli t + 18. Navedeno znači da će konačne podatke o komunalnom otpadu države članice prijaviti osamnaest mjeseci od završetka izvještajne godine. Nakon validacije navedeni podaci bit će objavljeni i na službenim stranicama Eurostata. Objavljeni podaci smatraju se službenim podacima i korišteni su i za potrebe ovog doktorskog rada. Dodatan problem je to što se podaci po vrstama i postupanju s otpadom prijavljuju svake parne godine, a navedeni podaci također se prijavljuju prema formuli t + 18. Podaci o otpadu vode se na spomenut način zbog

kompleksnosti cjelovitog sustava gospodarenja otpadom, kao i zbog zahtjevne prijave i velike količine podataka, što uzrokuje poteškoće kod praćenja i provjere podataka o otpadu.

Iako je „kašnjenje“ podataka o otpadu prepoznato kao veliki problem, na njega se u ovom istraživanju nije moglo utjecati, ali matematički model koji će se izraditi u sklopu ovog doktorskog rada u budućnosti se može nadograđivati novijim podacima. Prvenstveno je cilj uvidjeti može li se uopće s dugogodišnjim nizom sociodemografskih, ekonomskih i drugih podataka iz 17 država EU-a izraditi neuronska mreža koja će sa zadovoljavajućom razinom točnosti predvidjeti količinu biorazgradivog otpada koji će nastati u bliskoj budućnosti.



## 4. REZULTATI

### 4.1. Matematički model za predviđanje četiriju frakcija biorazgradivoga komunalnog otpada od 2020. do 2025. godine

Razvijeni matematički model neuronske mreže (ANN1) pokazao je obećavajuća svojstva generalizacije za prikupljenu bazu podataka i mogao se koristiti za točno predviđanje nastanka otpada: 20 mreža (MLP 44-20-4) za dobivanje najvećih vrijednosti  $r^2$  (tijekom ciklusa obuke), pri čemu su vrijednosti  $r^2$  za izlazne rezultate (količine miješanoga komunalnog otpada u tisućama tona – MMPW, količine neopasnog otpadnog papira i kartona u tisućama tona – PCW, količine neopasnog otpadnog drva u tisućama tona – WW, količine neopasnog otpadnog tekstila u tisućama tona – TW) bile: 0,999; 0,998; 0,997 i 0,998 (Tablica 7.).


Tablica 7. Sažetak matematičkog modela umjetne neuronske mreže (performanse i pogreške) za faze učenja, testiranja i provjere valjanosti

Naziv mreže	Performanse			Pogreška			Algoritam treninga	Funkcija pogreške	Skrivena aktivacija	Aktivacija izlaza
	Učenje	Provjera	Test	Učenje	Provjera	Test				
MLP 44-20-4	0,998	0,965	0,988	13109,4	31821,5	70423,3	BFGS 171	SS	Logistički	E

\*E – Eksponencijalna

U Prilogu 3. Tablica 59. prikazuje koeficijente matrice  $W_1$  i vektora  $B_1$  (prikazano u stupcu pristranosti), a Tablica 60. (također Prilog 3.) prikazuje elemente matrice  $W_2$  i vektora  $B_2$  (pristranost) za skriveni sloj.

Dobiveni matematički model za predviđanje varijable ishoda bio je složen (984 težinskih koeficijenata) i odgovarao je povećanom stupnju nelinearnosti u podacima. Ispravnost razvijenog matematičkog modela mogla bi se vizualno izmjeriti rasipanjem specifičnih točaka s dijagonalne linije na Slici 11. Očekivana kvaliteta bila je u većini slučajeva iznimno blizu prikupljenim podacima u smislu vrijednosti  $r^2$ .



Slika 11. Prikupljeni podaci i očekivane vrijednosti dobivene matematičkim modelom

Procjena kvalitete uklapanja prikupljenih podataka i izlaza izračunatih matematičkim modelom izražena kao snaga modela (zbroj  $r^2$  između izmjerenih i izračunatih statističkih testova kvaliteta uklapanja modela) tijekom koraka obuke, ispitivanja i provjere valjanosti prikazana je u Tablici 8.

Tablica 8. Testovi „dobrog uklapanja“ za kreirani matematički model

Izlazne varijable	$\chi^2$	RMSE	MBE	MPE	SSE	AARD	$r^2$
Miješani komunalni otpad	$4,3 \cdot 10^4$	$2,1 \cdot 10^2$	3,5	$1,6 \cdot 10^1$	$9,4 \cdot 10^6$	$4,2 \cdot 10^4$	0,999
Otpadni papir i karton	$6,6 \cdot 10^3$	$8,0 \cdot 10^1$	1,2	$6,0 \cdot 10^1$	$1,4 \cdot 10^6$	$1,5 \cdot 10^4$	0,997
Drvni otpad	$1,7 \cdot 10^3$	$4,1 \cdot 10^1$	-5,1	$9,2 \cdot 10^1$	$3,7 \cdot 10^5$	$1,1 \cdot 10^4$	0,989
Tekstilni otpad	$8,9 \cdot 10^1$	9.4E+00	1,2	$3,2 \cdot 10^2$	$1,9 \cdot 10^4$	$1,1 \cdot 10^3$	0,992

$\chi^2$  – reducirani hi-kvadrat, RMSE – korijenske srednje pogreške, MBE – srednje pogreške pristranosti, MPE – srednje postotne pogreške, SSE – suma kvadrata, AARD – prosječno apsolutno relativno odstupanje,  $r^2$  – koeficijent determinacije.

Kreirani matematički model dovoljno je dobro predvidio podatke za širok raspon varijabli. Predviđene vrijednosti bile su vrlo blizu izmjerenih vrijednosti u većini slučajeva s obzirom na vrijednosti  $r^2$ . Procijenjene SS vrijednosti modela bile su istog reda veličine kao i pogreške prijavljene u literaturi za izlazne varijable, a nepodudarnost podataka nije dostigla značajnu razliku. Navedeno implicira da je matematički model na zadovoljavajući način predvidio izlazne varijable. Povećana vrijednost  $r^2$  pokazala je da se model dobro uklapa u podatke. Uočene su greške matematičkog modela i izračunato je odgovarajuće predviđanje odgovora pomoću regresijskog modela umjetne neuronske mreže. Greške modela aproksimirale su slučajne pogreške koje su napravile odnos između podataka iz baze i izlaznih varijabli izračunatih na temelju ANN modela. Greške modela ponašaju se nasumično, što ukazuje na to da model dobro odgovara podacima.

Tablica 9. Testovi „dobrog uklapanja“ za razvijeni matematički model

Izlazne varijable	Asimetričnost ( <i>Skewness</i> )	Zakrivljenost ( <i>Kurtosis</i> )	Aritmetička sredina	Standardna devijacija	Varijanca
Miješani komunalni otpad	2,182	12,794	3,5	$2,1 \cdot 10^2$	$4,3 \cdot 10^4$
Otpadni papir i karton	-2,429	21,814	1,2	$8,1 \cdot 10^1$	$6,5 \cdot 10^3$
Drvni otpad	-2,236	13,302	-5,1	$4,1 \cdot 10^1$	$1,7 \cdot 10^3$
Tekstilni otpad	-6,046	67,700	1,2	9,3	$8,7 \cdot 10^1$

Također, provedena je rezidualna analiza razvijenog matematičkog modela. Asimetričnost se mjeri kao odstupanje distribucije od normalne simetrije. Ako je iskrivljenost značajno različita od nule, tada je raspodjela asimetrična, dok su normalne raspodjele savršeno simetrične. Zakrivljenost mjeri „vrhunac“ distribucije. Ako se kurtoza značajno razlikuje od nule, tada je raspodjela ili ravna ili ima više vrhova od normalne raspodjele; kurtoza normalne distribucije je nula (Tablica 9).

## 4.2. Matematički model za predviđanje ulaznih podataka za razdoblje od 2020. do 2025. godine (ANN2)

U ovom poglavlju prikazani su razvijeni matematički model neuronske mreže ANN2 i utjecaj varijabla „Godina“ i „Naziv država“ na vrijednosti socioekonomskih parametara korištenjem modela umjetnih neuronskih mreža (ANN).

Prema performansama ANN mreža, optimalan broj neurona u skrivenom sloju za proračun vrijednosti socioekonomskih parametara bio je 5 – 9 (neuronske mreže MLP 18-8-1, MLP 18-6-1, MLP 18-5-1, MLP 18-6-1, MLP 18-8-1, MLP 18-9-1, MLP 18-5-1, MLP 18-7-1, MLP 18-5-1, MLP 18-9-1, MLP 18-9-1, MLP 18-8-1, MLP 18-6-1, MLP 18-7-1, MLP 18-5-1, MLP 18-4-1, MLP 18-8-1, MLP 18-8-1, MLP 18-3-1, MLP 18-9-1, MLP 18-7-1, MLP 18-7-1, MLP 18-8-1, MLP 18-6-1, MLP 18-7-1 i MLP 18-5-1, za predikciju parametara POP, LE, EL1, EL2, EL3, ELT, GDP, RGDP, TFS, NED, NEER, DIRE, TEMP, URAD, YUR, MENI, ATAE, NSTA, IGS, EGS, EOPP, HPI, RRMW, DL, GMWK i GMWT, na temelju varijabla „Godina“ i „Naziv država“) da bi se dobile visoke vrijednosti koeficijenta determinacije,  $r^2$  (1,000; 0,997; 0,996; 0,994; 0,999; 0,996; 0,999; 0,998; 0,997; 0,999; 0,837; 0,981; 0,999; 0,962; 0,889; 0,996; 0,999; 0,989; 0,997; 0,998; 0,999; 0,953; 0,993; 0,998; 0,993 i 1,000, za ANN modele tijekom perioda obuke) i relativno niske vrijednosti sume kvadrata greške. Razvijeni ANN modeli ilustrirali su statistički neznačajno odstupanje u odnosu na eksperimentalne podatke, što je potvrdilo njihovu točnost (Tablica 10.).

Ukupne vrijednosti  $r^2$  za predviđanje parametara POP, LE, EL1, EL2, EL3, ELT, GDP, RGDP, TFS, NED, NEER, DIRE, TEMP, URAD, YUR, MENI, ATAE, NSTA, IGS, EGS, EOPP, HPI, RRMW, DL, GMWK i GMWT, na temelju varijabla „Godina“ i „Naziv država“, tijekom svih ciklusa formiranja neuronske mreže (1,000; 0,996; 0,995; 0,994; 0,997; 0,995; 0,999; 0,998; 0,997; 0,997; 0,835; 0,976; 1,000; 0,942; 0,874; 0,996; 0,999; 0,991; 0,997; 0,998; 0,999; 0,951; 0,990; 0,998; 0,991 i 1,000) također potvrđuju da rezultati dobiveni ANN modelima odgovaraju prikupljenim podacima.

Tablica 10. Pregled rezultata rada višeslojne neuronske mreže (performanse i greške) za cikluse učenja (treninga), testiranja i validacije mreže

Parametar	Naziv mreže	Pouzdanost mreže			Greška mreže			Algoritam treninga	Funkcija greške	Funkcija aktivacije skrivenog sloja	Funkcija aktivacije izlaznog sloja
		Trening	Test	Validacija	Trening	Test	Validacija				
POP	MLP 18-8-1	1,000	1,000	1,000	$2,77 \cdot 10^9$	$3,70 \cdot 10^9$	$9,97 \cdot 10^9$	BFGS 336	SS	L*	L
LE	MLP 18-6-1	0,997	0,994	0,998	0,039	0,072	0,033	BFGS 75	SS	TH*	E
EL1	MLP 18-5-1	0,996	0,993	0,995	0,838	1,198	1,333	BFGS 128	SS	L	L
EL2	MLP 18-6-1	0,994	0,991	0,995	1,360	1,612	1,800	BFGS 144	SS	TH	I
EL3	MLP 18-8-1	0,999	0,997	0,992	0,210	0,440	1,976	BFGS 250	SS	TH	TH
ELT	MLP 18-9-1	0,996	0,995	0,992	0,328	0,382	0,805	BFGS 109	SS	TH	E
GDP	MLP 18-5-1	0,999	0,999	1,000	$1,93 \cdot 10^8$	$1,61 \cdot 10^8$	$9,09 \cdot 10^7$	BFGS 115	SS	TH	L
RGDP	MLP 18-7-1	0,998	0,999	0,999	$5,94 \cdot 10^5$	$6,49 \cdot 10^5$	$3,56 \cdot 10^5$	BFGS 175	SS	L	L
TFS	MLP 18-5-1	0,997	0,995	0,999	$3,93 \cdot 10^4$	$2,98 \cdot 10^5$	$6,06 \cdot 10^3$	BFGS 265	SS	TH	TH
NED	MLP 18-9-1	0,999	0,999	0,992	$3,18 \cdot 10^2$	$3,20 \cdot 10^2$	$3,21 \cdot 10^2$	BFGS 10000	SS	L	TH
NEER	MLP 18-9-1	0,837	0,834	0,827	3,14	3,15	3,18	BFGS 1953	SS	TH	L
DIRE	MLP 18-8-1	0,981	0,974	0,965	$3,87 \cdot 10^2$	$3,89 \cdot 10^2$	$3,90 \cdot 10^2$	BFGS 8316	SS	TH	E
TEMP	MLP 18-6-1	0,999	0,999	1,000	$2,03 \cdot 10^4$	$1,97 \cdot 10^4$	$6,40 \cdot 10^3$	BFGS 183	SS	L	L
URAD	MLP 18-7-1	0,962	0,938	0,887	0,643	1,313	1,162	BFGS 63	SS	TH	L
YUR	MLP 18-5-1	0,889	0,830	0,872	4,577	10,953	7,640	BFGS 118	SS	TH	I
MENI	MLP 18-4-1	0,996	0,995	0,996	$2,33 \cdot 10^5$	$3,90 \cdot 10^5$	$2,14 \cdot 10^5$	BFGS 36	SS	TH	E
ATAE	MLP 18-8-1	0,999	0,999	0,999	$1,59 \cdot 10^{12}$	$1,55 \cdot 10^{12}$	$1,41 \cdot 10^{12}$	BFGS 196	SS	TH	E
NSTA	MLP 18-8-1	0,989	0,995	0,995	$4,64 \cdot 10^{13}$	$2,39 \cdot 10^{13}$	$2,56 \cdot 10^{13}$	BFGS 26	SS	E*	L
IGS	MLP 18-3-1	0,997	0,998	0,996	$8,07 \cdot 10^7$	$4,54 \cdot 10^7$	$1,55 \cdot 10^8$	BFGS 70	SS	TH	E
EGS	MLP 18-9-1	0,998	0,999	0,997	$6,25 \cdot 10^7$	$2,64 \cdot 10^7$	$1,18 \cdot 10^8$	BFGS 78	SS	TH	E
EOPP	MLP 18-7-1	0,999	0,999	1,000	$3,63 \cdot 10^{10}$	$6,74 \cdot 10^{10}$	$3,90 \cdot 10^9$	BFGS 9	SS	TH	L
HPI	MLP 18-7-1	0,953	0,950	0,945	3,391	3,403	3,432	BFGS 1806	SS	TH	E
RRMW	MLP 18-8-1	0,993	0,985	0,986	2,196	5,094	4,395	BFGS 70	SS	E	E
DL	MLP 18-6-1	0,998	0,998	0,998	$4,52 \cdot 10^4$	$8,21 \cdot 10^4$	$6,55 \cdot 10^4$	BFGS 61	SS	L	TH
GMWK	MLP 18-7-1	0,993	0,990	0,987	$1,12 \cdot 10^2$	$1,53 \cdot 10^2$	$1,90 \cdot 10^2$	BFGS 209	SS	L	E
GMWT	MLP 18-5-1	1,000	1,000	1,000	$2,67 \cdot 10^4$	$7,74 \cdot 10^4$	$3,13 \cdot 10^4$	BFGS 201	SS	L	L

\*L – logistička; E – eksponencijalna; TH – *tangent hiperbolicus*; I – funkcija identiteta

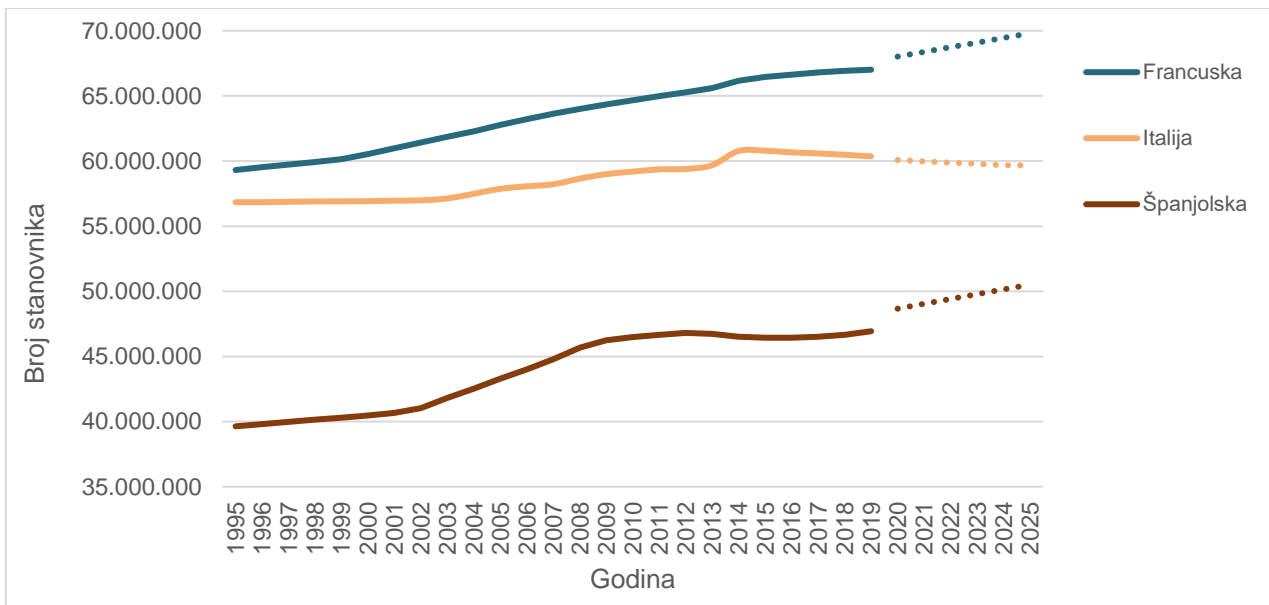
### **4.3. Rezultati predviđanja socioekonomskih pokazatelja za razdoblje od 2020. do 2025. godine**

U nastavku su za svaki parametar grafički ili tabelarno prikazani dobiveni podaci. Podaci na grafovima prikazani su tako da su podaci preuzeti iz literature označeni punom linijom. Podaci označeni točkastim nizom predstavljaju predviđene rezultate, odnosno podatke koji su dobiveni kreiranim modelom koristeći umjetne neuronske mreže.


#### **4.3.1. Broj stanovnika**

Za potrebe razvoja ovog matematičkog modela kao podatak o broju stanovnika uzeta je procjena za broj stanovnika svake države članice EU-a na dan 1. siječnja u razdoblju od 1995. do 2019. godine (Tablica 27.). Razvojem modela pomoću umjetnih neuronskih mreža kao rezultat dobivena je procjena broja stanovnika za razdoblje od 2020. do 2025. godine. U razdoblju od 2020. do 2025. godine deset država članica EU-a (Belgija, Češka, Danska, Francuska, Irska, Luksemburg, Nizozemska, Slovenija, Španjolska i Švedska) imaju trend porasta broja stanovnika, dok sedam država (Estonija, Hrvatska, Italija, Latvija, Litva, Mađarska i Malta) imaju predviđen pad broja stanovnika (Slika 12. i 13.). Broj stanovnika u 17 država promatranih u ovom istraživanju u 2019. godini iznosio je 257.713.812. Predviđanja za 2020. godinu prikazuju lagani porast broja stanovnika od 1 % i predviđa se da će u 2020. godini u 17 promatranih država biti 259.870.489 stanovnika. Također se predviđa da će u 17 promatranih država broj stanovnika u 2025. godini biti za 2 % veći od onog u 2019. godini odnosno da će iznositi 264.095.252. Tri države s najvećim brojem stanovnika su Francuska, Italija i Španjolska.

Prema kreiranom modelu predviđeni broj stanovnika u Hrvatskoj u 2021. godini iznosi 4.073.947. Navedeni podatak prati predviđanja Eurostata i prema kreiranom modelu nastavlja se proces depopulacije koji je prisutan u gotovo cijelom promatranom razdoblju. Valjda spomenuti kako je u 2021. godini u Hrvatskoj proveden popis stanovništva, a prema prvim rezultatima, broj stanovnika u Hrvatskoj u 2021. godini iznosi 3.888.529 stanovnika (Državni zavod za statistiku, 2021). Broj stanovnika prema rezultatima popisa stanovništva je za 185.418 stanovnika manji od predviđenog broja stanovnika (iz kreiranog modela). Iako je koeficijent determinacije za parametar broja stanovnika 1,000 (Prilog 5.), vidljivo je da je došlo do izraženijeg smanjenja broja stanovnika od predviđenog. Pretpostavlja se da je na izraženije smanjenje broja stanovnika utjecala koronakriza, gospodarska situacija u državi, kao i slobodno kretanje radne snage između država članica EU-a.



Slika 12. Prikaz broja stanovnika u Francuskoj, Italiji i Belgiji od 1995. do 2025. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



Slika 13. Prikaz broja stanovnika u preostalim 14 država EU-a od 1995. do 2025. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

Podaci o broju stanovnika uspoređeni su s količinama nastalog otpada. Rezultati pokazuju kako su države s najmanjim brojem stanovnika (Malta i Luksemburg) imale i najmanju količinu nastalog otpada. S druge strane, države s najvećim brojem stanovnika (Francuska, Italija, Španjolska) imaju i najveću količinu nastalog otpada. Navedeno vrijedi za sve promatrane vrste otpada, uz blaže oscilacije, primjerice kod tekstilnog otpada. U Tablica 11. u svakom su stupcu države poredane po veličini promatrane kategorije od manjeg prema većem.



Tablica 11. Broj stanovnika i količine nastalog miješanoga komunalnog otpada, papira i kartona, otpada od drva i tekstilnog otpada u 2018. godini


Država	Broj stanovnika	Država	Miješani komunalni otpad (tisuća tona)	Država	Papir i karton (tisuća tona)	Država	Otpad od drva (tisuća tona)	Država	Tekstilni otpad (tisuća tona)
Malta	475.701	Malta	180	Malta	14	Luksemburg	6	Latvija	0
Luksemburg	602.005	Luksemburg	184	Luksemburg	51	Malta	9	Malta	1
Estonija	1.319.133	Slovenija	299	Estonija	56	Hrvatska	12	Estonija	1
Latvija	1.934.379	Estonija	329	Latvija	69	Latvija	12	Irska	2
Slovenija	2.066.880	Češka	400	Litva	93	Litva	16	Slovenija	3
Litva	2.808.901	Latvija	529	Hrvatska	121	Mađarska	22	Litva	3
Hrvatska	4.105.493	Litva	768	Slovenija	165	Slovenija	42	Hrvatska	3
Irska	4.830.392	Francuska	<sup>1</sup>	Mađarska	334	Irska	49	Švedska	3
Danska	5.781.190	Švedska	1.160	Češka	343	Estonija	51	Danska	4
Mađarska	9.778.371	Danska	1.206	Irska	532	Češka	75	Luksemburg	5
Švedska	10.120.242	Hrvatska	1.215	Danska	549	Danska	235	Mađarska	7
Češka	10.610.055	Irska	1.595	Švedska	715	Španjolska	307	Češka	15
Belgija	11.398.589	Mađarska	2.580	Nizozemska	1.471	Nizozemska	507	Španjolska	46
Nizozemska	17.181.084	Nizozemska	2.944	Belgija	1.507	Švedska	526	Nizozemska	93
Španjolska	46.658.447	Belgija	4.212	Španjolska	2.397	Belgija	743	Belgija	103
Italija	60.483.973	Italija	12.481	Italija	3.706	Italija	1.223	Francuska	149
Francuska	66.918.941	Španjolska	17.778	Francuska	4.043	Francuska	1.712	Italija	165

<sup>1</sup> Nema podataka.

### 4.3.2. Životni vijek

Najniži životni vijek u 2019. godini imala je Latvija gdje je očekivani životni vijek iznosio 76 godina. Najviši životni vijek u 2019. godini imala je Španjolska i on je iznosio 84 godina (Tablica 28.). U prosjeku životni vijek u 17 promatranih država za 2019. godinu iznosi nepunu 81 godinu (80,9). U svim promatranim državama u ovom istraživanju predviđa se porast životnog vijeka od 2020. do 2025. godine (


Slika 14.). Predviđanja za 2020. godinu prikazuju lagani porast te bi u prosjeku životni vijek u 17 promatranih država trebao iznositi nepunu 81,5 godinu (81,4). Također se predviđa da će u 17 promatranih država životni vijek u 2025. godini biti za 2 % veći od onog u 2019. godini te da će životni vijek građana iznositi nepune 83 godine (82,7).




Slika 14. Prikaz očekivanog životnog vijeka stanovnika 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

### 4.3.3. BDP po tržišnim cijenama

Najniži BDP po tržišnim cijenama u 2019. godini imala je Malta (13.390.000.000 eura). Najviši BDP po tržišnim cijenama u 2019. godini imala je Francuska (2.425.708.000.000 eura) (Tablica 29.). U 15 promatranih država predviđa se porast BDP-a po tržišnim cijenama do 2025. godine (Slika 15. i 16.). Jedino se kod Malte i Irske predviđa prvo pad BDP-a po tržišnim cijenama, nakon čega slijedi porast i do 2025. godine vraćanje na vrijednosti iz 2019. godine. Prema kreiranom modelu, BDP po tržišnim cijenama do 2025. godine trebao bi se povećati za 13 % u odnosu na vrijednost iz 2019. godine te bi BDP po tržišnim cijenama za 17 promatranih država trebao iznositi 9.677.100 milijuna eura.



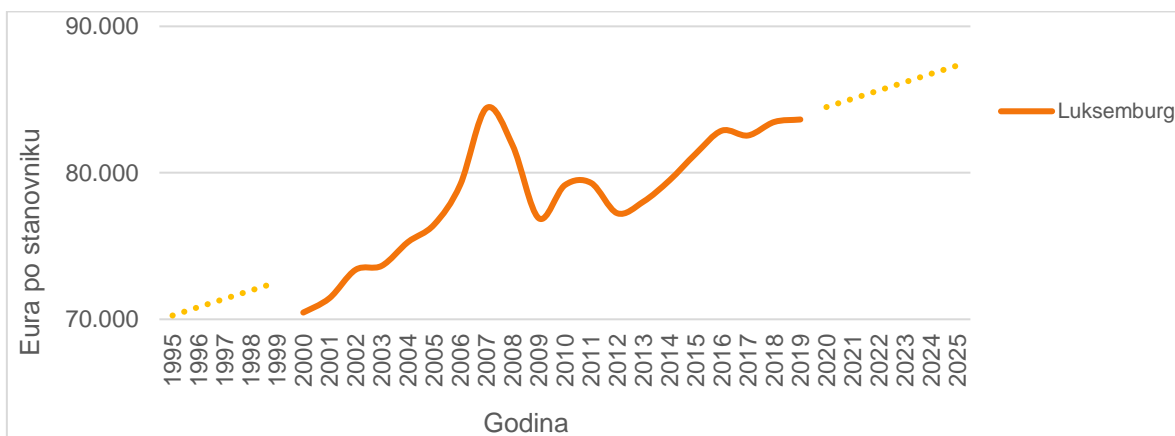
Slika 15. Prikaz BDP-a po tržišnim cijenama u Belgiji, Francuskoj, Italiji, Nizozemskoj i Španjolskoj od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.




Slika 16. Prikaz BDP-a po tržišnim cijenama u preostalim 12 promatranim državama EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### 4.3.4. BDP po stanovniku

Najniži BDP po stanovniku u 2019. godini imala je Hrvatska (12.410 eura po stanovniku). Najviši BDP po stanovniku u 2019. godini imali su stanovnici Luksemburga (83.640 eura po stanovniku) (Tablica 30.). U 15 promatranih država predviđa se porast BDP-a po stanovniku do 2025. godine (Slika 17 i 18.). Jedino se kod Italije i Španjolske predviđa lagani pad BDP-a po stanovniku. Prema kreiranom modelu, BDP po stanovniku do 2025. godine trebao bi se povećati za 7 % u odnosu na vrijednost iz 2019. godine te bi realni BDP po stanovniku za 17 promatranih država trebao iznositi 571.557 eura po stanovniku.




Slika 17. Prikaz BDP-a po stanovniku u Luksemburgu od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.




Slika 18. Prikaz BDP-a po stanovniku u preostalim 16 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### **4.3.5. Ukupne obveze financijskog sektora**

Povezano s BDP-om, korišten je i parametar ukupne obveze financijskog sektora. Ukupne obveze financijskog sektora mjere razvoj zbroja obveza (koji uključuje valutu i depozite, dužničke vrijednosne papire, zajmove, udjele u vlasničkim i investicijskim fondovima, osiguranje, mirovine i standardizirane sheme jamstava, financijske izvedenice i opcije dionica zaposlenika i druge račune) iz sektora financijskih korporacija. Podaci su prikazani u nekonsolidiranim izrazima (tj. podaci uzimaju u obzir transakcije unutar istog sektora), u % BDP-a i za podsektore: središnja banka; korporacije koje uzimaju depozite osim središnje banke; MMF; investicijski fondovi koji nisu novčani fondovi; ostali financijski posrednici, osim osiguravajućih društava i mirovinskih fondova; financijski pomoćnici; zarobljene financijske institucije i zajmodavci novca; osiguravajuća društva i mirovinski fondovi. I ovdje se po svojim vrijednostima ističe Luksemburg kao država s najvećim vrijednostima, znatno većima u usporedbi s drugim promatranim državama. U razdoblju od 1995. do 2019. ukupne obveze financijskog sektora kreću se u vrijednostima između 34,6 (Litva za 1996. godinu) i 28.042,3 (Luksemburg za 2015. godinu) (Tablica 31.). U svim državama (osim Češke) predviđen je porast ovog parametra od 2020. do 2025. godine (Slika 19. i Slika 20.).



Slika 19. Prikaz ukupnih obveza financijskog sektora kao % BDP-a u Irskoj, Luksemburgu, Malti i Nizozemskoj od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



Slika 20. Prikaz ukupnih obveza financijskog sektora kao % BDP-a u preostalim 14 promatranim državama EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### 4.3.6. Neto vanjski dug

Vanjski dug predstavlja zaduženost zemlje prema inozemstvu, a obuhvaća dio javnog duga i zaduživanje poduzeća, kućanstava i banaka prema inozemstvu (Eurostat, 2021e). U razdoblju od 1995. do 2019. neto vanjski dug kreće se u vrijednostima između -2.972,4 (Luksemburg za 2010. godinu) i 95,8 (Španjolska za 2011. i 2014. godinu) (Tablica 32.). U razdoblju od 2020. do 2025. godine predviđa se da će neto vanjski dug za sedam promatranih država (Belgiju, Češku, Dansku, Estoniju, Irsku, Luksemburg, Maltu) imati negativnu vrijednost, dok će u ostalim državama neto vanjski dug imati pozitivnu vrijednost. Predviđa se da će najveću vrijednost imati Španjolska (120,41 % BDP-a), dok se najmanje vrijednosti neto vanjskog duga predviđaju za Luksemburg (Tablica 12.).

Tablica 12. Prikaz predviđenog neto vanjskog duga u 17 država EU-a od 2020. do 2025. godine

Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	-22,92	-18,49	-14,07	-9,65	-5,22	-0,80
Hrvatska	52,83	54,07	55,30	56,54	57,77	59,01
Češka	-9,10	-9,20	-9,29	-9,39	-9,48	-9,57
Danska	-17,41	-20,92	-24,43	-27,94	-31,45	-34,96
Estonija	-15,17	-17,96	-20,75	-23,54	-26,33	-29,12
Francuska	43,80	45,43	47,07	48,71	50,34	51,98
Mađarska	33,31	33,34	33,38	33,42	33,46	33,49
Irska	-406,69	-420,24	-433,78	-447,32	-460,87	-474,41
Italija	59,28	60,58	61,89	63,19	64,49	65,80
Latvija	37,12	37,48	37,85	38,21	38,58	38,94
Litva	22,22	21,81	21,41	21,00	20,60	20,19
Luksemburg	-1.964,02	-1.933,54	-1.903,06	-1.872,59	-1.842,11	-1.811,63
Malta	-264,45	-260,07	-255,69	-251,30	-246,92	-242,54
Nizozemska	22,93	20,51	18,09	15,68	13,26	10,84
Slovenija	35,08	36,69	38,30	39,91	41,52	43,13
Španjolska	104,50	107,68	110,86	114,05	117,23	120,41
Švedska	51,32	51,54	51,77	51,99	52,22	52,44



### 4.3.7. Nominalni efektivni tečaj

Nominalni efektivni tečaj je ponderirani prosjek bilateralnih nominalnih tečajeva u odnosu na valute odabranih trgovačkih partnera. U razdoblju od 1995. do 2019. neto vanjski dug kreće se u vrijednostima između -16,8 (Mađarska) i 28,9 (Latvija) (Tablica 33.). Predviđanja pokazuju da će se od 2020. do 2025. vrijednost efektivnog tečaja kretati između 3,0 (predviđanje za Mađarsku za 2025. godinu) i -7,2 % (predviđanje za Litvu za 2025. godinu) (Tablica 13.).

Tablica 13. Prikaz predviđenog nominalnog efektivnog tečaja u 17 država EU-a od 2020. do 2025. godine

Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	0,3	0,3	0,3	0,3	0,2	0,2
Hrvatska	-0,4	-0,5	-0,7	-0,9	-1,0	-1,2
Češka	0,6	0,5	0,4	0,2	0,1	-0,1
Danska	0,1	0,1	0,0	-0,1	-0,1	-0,2
Estonija	-1,6	-1,9	-2,3	-2,6	-3,0	-3,4
Francuska	0,0	0,0	-0,1	-0,2	-0,2	-0,3
Mađarska	1,6	1,9	2,2	2,5	2,7	3,0
Irska	-0,1	-0,1	-0,2	-0,2	-0,3	-0,3
Italija	0,1	0,0	-0,1	-0,1	-0,2	-0,3
Latvija	-2,5	-3,0	-3,4	-3,8	-4,3	-4,7
Litva	-3,6	-4,3	-5,0	-5,7	-6,5	-7,2
Luksemburg	0,2	0,2	0,2	0,2	0,1	0,1
Malta	-0,3	-0,4	-0,5	-0,6	-0,6	-0,7
Nizozemska	0,2	0,2	0,2	0,2	0,1	0,1
Slovenija	1,5	1,6	1,8	1,9	2,1	2,2
Španjolska	0,5	0,5	0,5	0,5	0,4	0,4
Švedska	-2,0	-2,1	-2,3	-2,5	-2,7	-2,9

#### 4.3.8. Inozemna izravna ulaganja

Strana ulaganja predstavljaju sve vrste ulaganja stranih pravnih i fizičkih osoba u gospodarske djelatnosti neke zemlje (HNB, 2016). Inozemna ulaganja također se mogu smatrati financijskim fenomenom koji se odnosi na prekogranična kretanja kapitala između matičnih multinacionalnih društava i njihovih inozemnih podružnica. Ova konceptualizacija postavlja specifične vrste političkih i znanstvenih pitanja, uključujući odnos izravnih stranih ulaganja prema platnoj bilanci i tečajevima ili cijenama faktora (Kerner, 2014). U razdoblju od 1995. do 2019. godine Luksemburg ima i najnižu vrijednost (-900 % BDP-a) i najveću vrijednost (1296 % BDP-a). U ostalim državama u istom razdoblju podaci se kreću između -167,9 do 451,2 % BDP-a (Tablica 34.). Predviđanja pokazuju da će se od 2020. do 2025. vrijednost inozemnih izravnih ulaganja kretati između 168 % (predviđanje za Maltu za 2025. godinu) i 114 % BDP-a (predviđanje za Luksemburg za 2020. godinu) (Tablica 14.).

Tablica 14. Prikaz predviđenih vrijednosti za inozemna izravna ulaganja 17 država EU-a od 2020. do 2025. godine

Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	-5,6	-7,3	-8,9	-10,6	-12,2	-13,9
Hrvatska	1,2	1,0	0,8	0,5	0,3	0,1
Češka	3,6	3,5	3,3	3,2	3,1	3,0
Danska	-0,8	-1,0	-1,2	-1,4	-1,6	-1,8
Estonija	4,3	4,0	3,6	3,3	3,0	2,6
Francuska	1,0	0,9	0,8	0,7	0,6	0,5
Mađarska	5,2	4,9	4,7	4,4	4,2	3,9
Irska	22,5	22,4	22,3	22,1	22,0	21,9
Italija	1,0	1,0	1,0	1,0	1,0	1,0
Latvija	2,6	2,5	2,5	2,4	2,3	2,2
Litva	1,8	1,7	1,6	1,4	1,3	1,1
Luksemburg	113,8	89,7	65,6	41,5	17,4	-6,8
Malta	-62,7	-83,8	-104,8	-125,8	-146,8	-167,9
Nizozemska	4,5	2,0	-0,5	-3,0	-5,5	-8,0
Slovenija	2,4	2,4	2,5	2,5	2,5	2,6
Španjolska	2,4	2,3	2,3	2,3	2,2	2,2
Švedska	0,6	0,3	0,0	-0,3	-0,6	-0,9

#### 4.3.9. Harmonizirani indeks cijene stambenih objekata

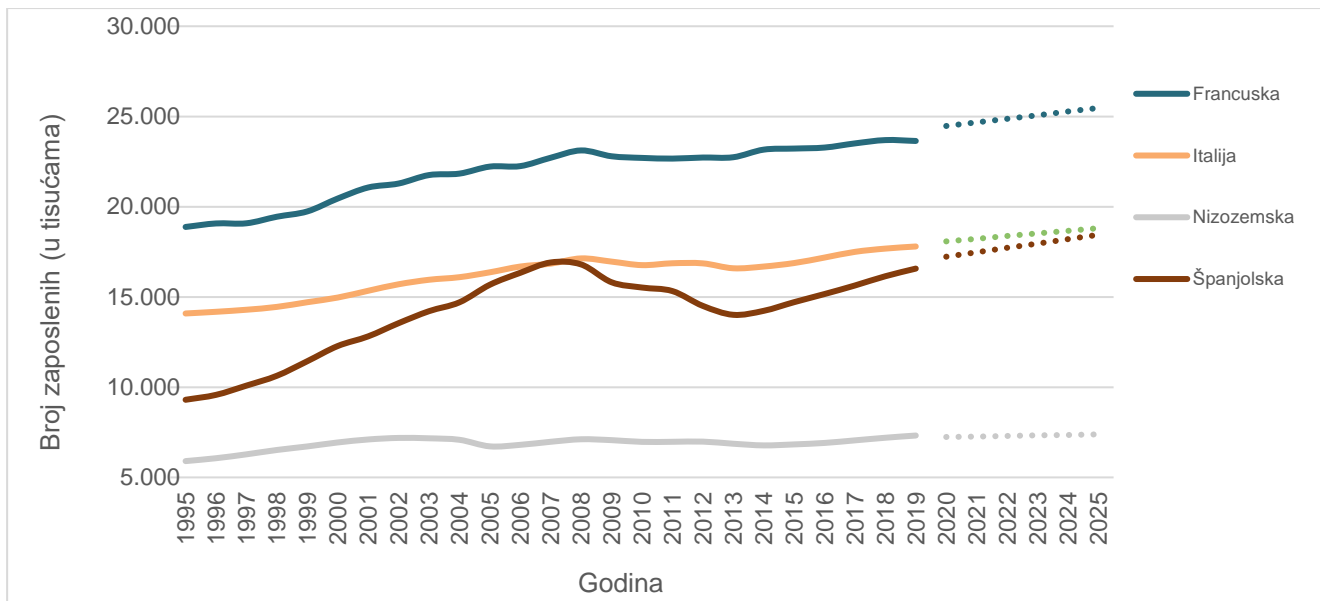
Harmonizirani indeks cijene stambenih objekata mjeri inflaciju cijena stambenih objekata u odnosu na opću inflaciju. Ovaj parametar predstavlja promjenu prosječne godišnje stope (Eurostat, 2021b). Ako je iznos pozitivan, znači da su cijene nekretnina rasle u odnosu na promatrano razdoblje. Statistički ured Europske unije podatke o harmoniziranom indeksu cijene stambenih objekata prati od 2001. godine. Od 2001. godine do 2019. godine podaci su bili u rasponu od -36,3 % (Estonija, podatak za 2009. godinu) i 41,7 % (Estonija, podatak za 2006. godinu) (Tablica 35.). Predviđanja pokazuju da će od 2020. do 2025. vrijednost harmoniziranog indeksa cijena stambenih objekata padati u svim promatranim državama osim u Mađarskoj (Tablica 15.)

Tablica 15. Prikaz predviđenih iznosa harmoniziranog indeksa cijene stambenih objekata u 17 država EU-a od 2020. do 2025. godine


Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	-0,5	-0,8	-1,1	-1,5	-1,8	-2,1
Češka	2,9	2,8	2,7	2,6	2,5	2,4
Danska	0,7	0,5	0,4	0,2	0,0	-0,2
Estonija	2,1	1,9	1,7	1,5	1,3	1,1
Francuska	-2,6	-3,2	-3,8	-4,4	-5,0	-5,6
Hrvatska	0,0	-0,1	-0,3	-0,4	-0,5	-0,6
Irska	1,4	1,3	1,2	1,2	1,1	1,0
Italija	-5,0	-5,6	-6,1	-6,6	-7,1	-7,6
Latvija	-1,4	-2,1	-2,8	-3,5	-4,2	-4,9
Litva	-0,8	-1,3	-1,9	-2,4	-2,9	-3,5
Luksemburg	2,6	2,4	2,1	1,8	1,6	1,3
Mađarska	15,9	18,1	20,3	22,4	24,6	26,8
Malta	-0,1	-0,7	-1,2	-1,8	-2,4	-3,0
Nizozemska	1,4	1,4	1,5	1,5	1,5	1,6
Slovenija	-1,1	-1,6	-2,1	-2,5	-3,0	-3,4
Španjolska	-3,7	-4,3	-4,8	-5,4	-6,0	-6,6
Švedska	2,8	2,6	2,4	2,1	1,9	1,7

#### **4.3.10. Ukupno zaposleni**

U razdoblju od 1995. do 2019. ukupan broj zaposlenih od 15. do 64. godine kreće se u vrijednostima između 125.000 (podaci za Maltu za 2004. godinu) do 23.693.000 zaposlenih (podaci za Francusku za 2018. godinu) (Tablica 36.). U 2019. godini u 17 promatranih država EU-a ukupno je bilo 92.055.500 zaposlenih u dobi između 15. i 64. god. U deset promatranih država u ovom istraživanju predviđa se porast ukupnog broja zaposlenih do 2025. godine (Slika 21.), dok će u ostalih sedam država doći do blagog smanjenja ukupnog broja zaposlenih. Predviđanja za 2020. godinu prikazuju lagani porast od 1 % i ukupan broj zaposlenih trebao bi iznositi 93.222.900. (Slika 21. i Slika 22.). Također se predviđa da će u 17 promatranih država ukupan broj zaposlenih u 2025. godini biti čak za 6 % veći od onog u 2019. godini te da će biti zaposleno 97.187.100 stanovnika. Slika 21. pokazuje vidljiv učinak gospodarske krize iz 2008. godine na podacima iz Španjolske gdje se vidi pad broja zaposlenih u razdoblju od 2008. godine te oporavak i porast broja zaposlenih tek od 2013. godine nadalje. Za pretpostaviti je da će koronakriza također u određenoj mjeri utjecati na izračunate podatke u razdoblju od 2020. do 2025. godine.



Slika 21. Prikaz ukupno zaposlenih od 15. do 64. godine u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



Slika 22. Prikaz ukupno zaposlenih od 15. do 64. godine u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### 4.3.11. Godišnji podaci o stopi nezaposlenosti

Od 1995. godine stopa nezaposlenosti pada sve do 2008. godine što se ponovno može objasniti učincima gospodarske krize iz 2008. godine. Kako kod koje države, ali do smanjenja broja nezaposlenosti ponovno dolazi otprilike od 2013. godine nadalje. U 2019. godini najnižu stopu nezaposlenosti imala je Češka gdje je stopa nezaposlenosti iznosila 2 %. Najvišu stopu nezaposlenosti u 2019. godini imala je Španjolska s 14 % (Tablica 37.). U 15 promatranih država (osim u Italiji i Litvi) predviđa se porast stope nezaposlenosti do 2025. godine (Tablica 16.). U Italiji i Litvi predviđa se stagniranje stope nezaposlenosti na vrijednost iz 2019. godine. U razdoblju od 2020. do 2025. godine predviđa se da će država s najnižim stopama biti Malta (4 % nezaposlenih, podatak za 2025. godinu), a država s najvećom stopom nezaposlenosti Španjolska (19 % nezaposlenih, podatak za 2025. godinu).

Tablica 16. Prikaz predviđenih godišnjih podataka o stopi nezaposlenosti u 17 država EU-a od 2020. do 2025. godine.

Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	6,8	6,7	6,7	6,6	6,5	6,4
Hrvatska	13,3	13,5	13,6	13,7	13,8	13,9
Češka	4,6	4,5	4,4	4,3	4,2	4,1
Danska	6,1	6,1	6,1	6,2	6,2	6,2
Estonija	6,7	6,5	6,3	6,1	5,9	5,7
Francuska	9,2	9,2	9,2	9,2	9,2	9,2
Mađarska	6,6	6,5	6,4	6,4	6,3	6,2
Irska	9,6	9,6	9,7	9,8	9,9	10,0
Italija	9,9	10,0	10,0	10,0	10,0	10,0
Latvija	9,3	9,1	8,9	8,7	8,4	8,2
Litva	7,6	7,3	7,0	6,7	6,4	6,2
Luksemburg	6,6	6,7	6,9	7,1	7,3	7,4
Malta	4,6	4,5	4,3	4,2	4,1	4,0
Nizozemska	5,3	5,3	5,3	5,4	5,4	5,4
Slovenija	7,2	7,2	7,2	7,3	7,3	7,3
Španjolska	18,4	18,5	18,7	18,8	18,9	19,0
Švedska	7,0	7,0	6,9	6,9	6,9	6,9

#### 4.3.12. Stopa nezaposlenosti mladih

Stopa nezaposlenosti mladih je stopa nezaposlenosti ljudi u dobi od 15. do 24. godine kao postotak radne snage iste dobi. Učinci gospodarske krize iz 2018. godine vidljivi su i u ovom parametru, stoga ne čudi da je kao posljedica krize najveća stopa nezaposlenosti mladih zabilježena 2010. godine (Litva 27,3 %, Latvija 25,6 % i Španjolska 23,4 %). Najnižu stopu nezaposlenosti mladih u 2019. godini imala je Hrvatska (-15 %), dok je najvišu stopu nezaposlenosti u 2019. godini imala Švedska s 1 % (Tablica 38.). Predviđa se da će stopa nezaposlenosti mladih u Europi od 2020. do 2025. padati u 13 promatranih država, dok se za Španjolsku, Dansku, Irsku i Italiju predviđa porast stope nezaposlenosti mladih. Najviša stopa nezaposlenosti mladih predviđa se za Španjolsku i ona će iznositi 3,5 % u 2025. godini (Tablica 17.).


Tablica 17. Prikaz predviđenih stopa nezaposlenih mladih u 17 država EU-a od 2020. do 2025. godine

Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	-1,7	-1,8	-1,9	-2,0	-2,1	-2,2
Češka	-6,1	-6,6	-7,1	-7,6	-8,1	-8,6
Danska	0,6	0,6	0,7	0,8	0,8	0,9
Estonija	-4,3	-4,6	-4,9	-5,2	-5,5	-5,8
Francuska	-2,7	-3,1	-3,5	-3,9	-4,3	-4,7
Hrvatska	-7,0	-7,5	-8,0	-8,4	-8,9	-9,4
Irska	0,6	0,7	0,9	1,0	1,1	1,3
Italija	0,5	0,5	0,6	0,6	0,6	0,6
Latvija	-3,1	-3,2	-3,3	-3,4	-3,6	-3,7
Litva	-4,8	-5,1	-5,3	-5,6	-5,9	-6,2
Luksemburg	-0,5	-0,7	-0,8	-0,9	-1,0	-1,2
Mađarska	-5,6	-6,1	-6,6	-7,0	-7,5	-8,0
Malta	-2,8	-3,0	-3,2	-3,4	-3,7	-3,9
Nizozemska	-0,5	-0,5	-0,5	-0,5	-0,5	-0,5
Slovenija	-2,7	-2,8	-2,9	-3,0	-3,2	-3,3
Španjolska	2,3	2,5	2,8	3,0	3,3	3,5
Švedska	-0,2	-0,2	-0,2	-0,2	-0,2	-0,2

### 4.3.13. Srednji ekvivalent neto prihoda

Primarni izvor podataka o prihodima i uvjetima života od 1994. do 2001. bio je Panel kućanstava Europske zajednice (engl. *European Community Household Panel*), a 2003. godine podatke o dohotku i životnim uvjetima sakuplja Europski ured za statistiku. Godine 2002. podaci o prihodu nisu dostupni zbog čega postoji „rupa“ u podacima za tu godinu.

Razina neto prihoda kontinuirano raste u cijelom promatranom razdoblju (1995. – 2019.) (Tablica 39.), a predviđa se nastavak takvog trenda i u narednom razdoblju između 2020. i 2025. godine (Slika 23.). Najniži srednji ekvivalent prihoda zabilježen je u Litvi (2.058 eura, podaci za 2005. godinu). Najviši ekvivalent neto prihoda imao je Luksemburg (36.354 eura, podaci za 2019. godinu). Ukupni neto prihod za promatranih 17 država u 2019. godini iznosio je 301.905 eura. Predviđanja za 2020. godinu prikazuju porast od 3 % te bi neto prihod za promatrane države trebao iznositi 310.765 eura. Također se predviđa da će u 17 promatranih država neto prihod u 2025. godini biti za čak 15 % veći od onog u 2019. godini te bi isti trebao iznositi 348.651 eura.




Slika 23. Srednji ekvivalent neto prihoda u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



#### 4.3.14. Uvoz roba i usluga

Uvoz roba i usluga u pravilu raste u cijelom promatranom razdoblju (1995. – 2019.) uz jedino odstupanje od 2008. do 2011. kada zbog gospodarske krize dolazi do pada uvoza (Slika 24.). U razdoblju od 1995. do 2019. godine najniža vrijednost uvoza roba i usluga zabilježena je u Latviji 1995. godine i uvoz roba i usluga iznosio je 1.626 milijuna eura. Najvišu vrijednost uvoza roba i usluga imala je Francuska 2019. godine i ukupni uvoz roba i usluga iznosio je 794.444 milijuna eura (Tablica 40.). Ukupni uvoz roba i usluga u 17 država EU-a u 2019. godini iznosio je 3.982.427 milijuna eura. Predviđanja za 2020. godinu prikazuju pad od 2 % te bi ukupni iznos uvoza roba i usluga trebao biti 3.917.203 milijuna eura. Predviđanja za 2025. godinu pokazuju porast uvoza za čak 13 % u odnosu na 2019. godinu i on bi trebao iznositi 4.490.908 milijuna eura.




Slika 24. Uvoz roba i usluga u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### 4.3.15. Izvoz roba i usluga

Isto kao i kod uvoza, izvoz roba i usluga u pravilu raste u cijelom promatranom razdoblju (1995. – 2019.) uz jedino odstupanje od 2008. do 2011. U razdoblju od 1995. do 2019. godine najniža vrijednost izvoza roba i usluga zabilježena je u Latviji 1995. godine i izvoz roba i usluga iznosio je 1.430 milijuna eura. Najvišu vrijednost izvoza roba i usluga imala je Francuska 2019. godine, a ukupni izvoz roba i usluga iznosio je 770.689 milijuna eura (Tablica 41.). Ukupni izvoz roba i usluga u 17 država EU-a u 2019. godini iznosio je 4.272.473 milijuna eura. Predviđanja za 2020. godinu prikazuju pad od 2 % te bi ukupni izvoz roba i usluga trebao iznositi 4.167.576 milijuna eura. Predviđanja za 2025. godinu pokazuju porast izvoza za 12 % u odnosu na 2019. godinu te bi on trebao iznositi 4.781.671 milijuna eura (Slika 25.).

Ukupne količine izvoza roba i usluga u 17 promatranih država veće su od uvoza robe i usluga što znači da su države u pravilu u vanjskoj trgovinskoj bilanci ili čak u vanjskom trgovinskom suficitu.



Slika 25. Izvoz roba i usluga iz 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### 4.3.16. Izvoz nafte i naftnih derivata

Podaci o izvozu nafte i naftnih derivata po zemljama partnerima<sup>2</sup> služe kao još jedan oblik robne razmjene. Podaci se kreću od 1.000.000 tona izvezene nafte i naftnih derivata (podaci za Latviju za 2001. i 2002. godinu) sve do 113.886.092 tone izvezene nafte i naftnih derivata (podaci za Nizozemsku za 2016. godinu) (Tablica 42.). Prema prikupljenim podacima, Nizozemska odskoče u količini izvezene nafte i naftnih derivata. Navedeno ne mora nužno iznenađivati s obzirom na to da su prema podacima konzultantske kuće PricewaterhouseCoopers u 2012. godini najveći proizvođači nafte i plina u Europi bile Norveška, Velika Britanija i Nizozemska (Energetika-net, 2013). S obzirom na to da su u ovom istraživanju obuhvaćene samo države članice EU-a, podaci za Norvešku i Veliku Britaniju nisu uzimani u obzir.

U 2018. godini u svih 17 promatranih država izvezlo se 267.489.800 tona nafte i naftnih derivata. Prema podacima dobivenim u ovom istraživanju, do 2025. godine očekuje se povećanje izvezenih količina nafte i naftnih derivata za 17 % u usporedbi s 2018. godinom. Prema tom izračunu, u 2025. godini ukupno će biti izvezeno (u svim promatranim državama zajedno) 313.660.800 tona nafte i naftnih derivata (Tablica 18.)

---

<sup>2</sup> Za kruta fosilna goriva, prirodni plin, sirovu naftu, naftne derivate i biogoriva zemlja partner „uvoza“ odnosi se na zemlju krajnjeg podrijetla, zemlju u kojoj je proizveden energetska proizvod. Zemlja partner „izvoza“ odnosi se na krajnju zemlju potrošnje energenata.

Tablica 18. Prikaz predviđenih količina izvoza nafte i naftnih derivata u 17 država EU-a od 2020. do 2025. godine

Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	31.731	32.240	32.748	33.257	33.765	34.274
Češka	2.240	2.294	2.348	2.402	2.456	2.510
Danska	12.894	12.826	12.759	12.691	12.623	12.555
Estonija	1.330	1.390	1.449	1.509	1.569	1.629
Francuska	22.731	22.802	22.872	22.943	23.013	23.084
Hrvatska	1.962	1.969	1.977	1.985	1.993	2.001
Irska	1.688	1.708	1.729	1.749	1.770	1.790
Italija	31.495	31.945	32.395	32.845	33.294	33.744
Latvija	859	897	935	972	1.010	1.048
Litva	9.583	9.858	10.133	10.408	10.683	10.958
Luksemburg	9	9	9	8	8	8
Mađarska	3.641	3.710	3.780	3.849	3.919	3.988
Malta	448	491	533	576	619	661
Nizozemska	121.512	124.468	127.423	130.379	133.334	136.290
Slovenija	1.827	1.913	1.999	2.085	2.171	2.257
Španjolska	25.136	26.027	26.919	27.811	28.702	29.594
Švedska	15.790	16.086	16.382	16.678	16.975	17.271

#### 4.3.17. Obrazovanje

Kako bi se provjerila povezanost stvaranja otpada s razinom obrazovanja, u ovom istraživanju korištena su čak četiri parametra obrazovanja. Parametri su grupirani sukladno pripadnosti jednom od razreda prema međunarodnoj standardnoj klasifikaciji obrazovanja (engl. *International Standard Classification of Education – ISCED*). ISCED 2011 je međunarodno priznata klasifikacija obrazovanja koja se koristi kako bi prikupljeni podaci diljem svijeta bili usporedivi. Razina postignutog obrazovanja pojedinca jest najviša uspješno završena razina prema ISCED-u (Statistički ljetopis 2018; Eurostat, 2020b). Navedena klasifikacija ima osam razina:

Razina 0 – manje od osnovnog obrazovanja

Razina 1 – osnovno obrazovanje

Razina 2 – niže srednje obrazovanje

Razina 3 – više srednje obrazovanje

Razina 4 – netercijarno obrazovanje nakon srednjeg obrazovanja

Razina 5 – visokoškolsko obrazovanje kratkog ciklusa

Razina 6 – prvostupnička ili ekvivalentna razina


Razina 7 – master ili ekvivalentna razina

Razina 8 – doktorska ili ekvivalentna razina.

Korištene kategorije u ovom istraživanju su:

1. Predškolsko obrazovanje, primarno obrazovanje i niže sekundarno obrazovanje


Prema međunarodnoj standardnoj klasifikaciji obrazovanja iz 2011. godine, ova kategorija obrazovanja uključuje razine 0, 1 i 2. U svim promatranim državama EU-a obvezno obrazovanje obuhvaća osnovnoškolsko i niže srednjoškolsko obrazovanje (ISCED 1 i 2) (Europska komisija, 2018), stoga ne čudi da graf na Slika 26. prikazuje trend pada vrijednosti, odnosno smanjenje postotka stanovnika s navedenom razinom obrazovanja. U razdoblju od 1995. do 2019. godine vrijednosti se kreću između 5 % (Litva, podaci za 2019. godinu) do 81,9 % (Malta, podaci za 2000. godinu) (Tablica 43.). U svim promatranim državama predviđa se smanjenje stopa stanovništva u dobi od 24. do 64. godine sa završenim samo osnovnoškolskim i niže srednjoškolskim obrazovanjem.



Slika 26. Predškolsko obrazovanje, primarno obrazovanje i niže sekundarno obrazovanje u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

## 2. Više sekundarno obrazovanje, post-sekundarno, netercijarno obrazovanje i tercijarno obrazovanje

Prema međunarodnoj standardnoj klasifikaciji obrazovanja, ova kategorija obrazovanja uključuje razine 3, 4, 5, 6, 7 i 8. Drugim riječima, ova kategorija obuhvaća sve stanovnike koji imaju završeno sekundarno obrazovanje (srednjoškolsko obrazovanje) ili više. Iako ove kategorije obrazovanja nisu dio obveznog obrazovanja, i u ovoj kategoriji udio stanovnika s navedenim razinama obrazovanja raste u cijelom promatranom razdoblju (Slika 27.). U razdoblju od 1995. do 2019. godine vrijednosti se kreću od 17,2 % (Hrvatska, podaci za 1995. godinu) do 95 % (Litva, podaci za 2019. godinu) (Tablica 44.). Jedino se za Dansku predviđa pad vrijednosti od nekoliko posto, dok se u svim drugim promatranim državama predviđa porast broja stanovnika ove obrazovne kategorije.




Slika 27. Više sekundarno obrazovanje, post-sekundarno netercijarno obrazovanje u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

### 3. Više srednje obrazovanje i post-sekundarno, netercijarno obrazovanje

Prema međunarodnoj standardnoj klasifikaciji obrazovanja, ova kategorija obrazovanja uključuje razine 3 i 4. Drugim riječima, ova kategorija obuhvaća sve stanovnike koji imaju završeno sekundarno obrazovanje (srednjoškolsko obrazovanje) ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje, ali daje mogućnost nastavka obrazovanja prema visokom obrazovanju ili daje mogućnost zapošljavanja.

Slika 28. prikazuje za većinu država porast broja ljudi sa srednjoškolskim obrazovanjem. U razdoblju od 1995. do 2019. godine vrijednosti se kreću u rasponu od 9,5 % (Malta, podaci iz 2002. godine) do 76,9 % (Češka, podaci iz 2005. godine) (Tablica 44.). Porast vrijednosti za ovu kategoriju u razdoblju od 2020. do 2025. godine predviđa se za deset promatranih država.

Nejasno je zašto se predviđa pad broja stanovnika s ovom razinom obrazovanja u državama kao što su Danska, Estonija, Latvija, Luksemburg i Švedska.




Slika 28. Više srednje obrazovanje i post-sekundarno, netercijarno obrazovanje u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### 4. Visoko obrazovanje

Prema međunarodnoj standardnoj klasifikaciji obrazovanja iz 2011. godine, ova kategorija obrazovanja uključuje razine 5, 6, 7 i 8, odnosno sve razine visokog obrazovanja (preddiplomska, diplomatska i poslijediplomska razina). Iako su ukupne vrijednosti u ovoj kategoriji niže od prethodnih, nastavlja se rast broja stanovnika s ovom razinom obrazovanja, a s najvećim postotkom prednjači Luksemburg (Slika 29.). Navedeno se može objasniti dugom povijesti obrazovne politike u Europi (upravo najstarija sveučilišta nastala su na području Europe). Povećanju broja visokoobrazovanih ljudi zasigurno je pridonijelo i općenito poboljšanje životnog standarda, promjena načina života, pristupačnost visokog školstva, a u današnje vrijeme i sve pristupačnija mobilnost studenata zasigurno dodatno




motivira i otvara vrata visokom obrazovanju. U prilog tome govori i činjenica da je najniža vrijednost zabilježena 1995. godine u Hrvatskoj i ona iznosi 5 %. Najveća vrijednost zabilježena je u 2019. godini (47 %) u Luksemburgu (Tablica 45.).




Slika 29. Broj visoko obrazovanih u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### 4.3.18. Dolasci u turističke smještajne objekte

U razdoblju od 1995. do 2019. godine broj dolazaka u turističke smještajne objekte kreće se od 340.550 turista u Latviji 1995. godine do 174.628.055 turista u Francuskoj u 2019. godini (Slika 30. i Slika 31.). U 2019. godini ukupan broj dolazaka turista u svih 17 promatranih država iznosio je 631.472.859. Države s najvećim brojem turističkih dolazaka su Francuska, Italija i Španjolska (Slika 30.). Predviđa se da će broj dolazaka u turističke smještajne objekte do 2025. godine porasti za 8 % (680.214.353 dolazaka u turističke smještajne objekte) u usporedbi s podacima iz 2019. godine. Ako se porastu dolazaka turista pridoda i podatak da u prosjeku porast turista za 1 % uzrokuje ukupni porast komunalnog otpada od 0,28 % (Mateu-Sbert i sur., 2013; Arbulú i sur., 2015), u bliskoj budućnosti može se očekivati porast količina nastaloga komunalnog otpada, posebice otpada iz turizma.




Slika 30. Prikaz dolazaka u turističke smještajne objekte u Francuskoj, Italiji i Španjolskoj od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



Slika 31. Prikaz dolazaka u turističke smještajne objekte u preostalih 14 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.


#### 4.3.19. Noćenja u turističkim smještajnim objektima

U razdoblju od 1995. do 2019. godine broj noćenja u turističkim smještajnim objektima kreće se od 503.519 noćenja u Latviji (podatak za 1995. godinu) do 305.907.462 noćenja u Španjolskoj u 2017. godini. Države s najvećim brojem turističkih noćenja su ponovno Španjolska, Italija i Francuska. Predviđa se da će se broj noćenja u 2020. godini u 16 promatranih država<sup>3</sup> smanjiti za 2 % te da će iznositi 801.204.685. Usprkos predviđenom smanjenju za 2020. godinu, očekuje se da će broj noćenja do 2025. godine porasti za 8 % (867.856.071 noćenje) u usporedbi s podacima iz 2019. godine (Slika 32. i Slika 33.).



Slika 32. Prikaz broja noćenja u turističkim smještajnim objektima u Francuskoj, Italiji i Španjolskoj od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

<sup>3</sup> Francuska je izuzeta iz izračuna jer nedostaju podaci za sve godine.




Slika 33. Prikaz broja noćenja u turističkim smještajnim objektima u preostalih 14 promatranih država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.


Osim socioekonomskih i gospodarskih pokazatelja, u ovom istraživanju prikupljeni su i pokazatelji o otpadu koji su prikazani u nastavku.

#### 4.3.20. Nastali komunalni otpad

Slika 34. prikazuje godišnje količine nastaloga komunalnog otpada (prikaz u tisućama tona) u 17 promatranih država. Ukupna količina nastaloga komunalnog otpada u 1995. godini iznosila je 108.196.000 tona. U 2018. godini količina nastaloga komunalnog otpada porasla je za 17 % i iznosila je 126.734.000 tona. Na temelju kreiranog matematičkog modela dobivene su vrijednosti nastaloga komunalnog otpada od 2020. godine do 2025. godine. Za 2020. godinu predviđena količina nastaloga komunalnog otpada iznosi 131.288.000 za svih 17 država (povećanje od 4 % u odnosu na 2018. godinu). Za 2025. godinu predviđa se porast od 6 % u odnosu na količinu iz 2018. godine, odnosno nastanak 133.749.000 tona komunalnog otpada. Slika 34. prikazuje da Francuska, Italija i Španjolska u količinama komunalnog otpada odskaču od drugih zemalja (Slika 35.).



Slika 34. Količine nastaloga komunalnog otpada, prikaz u tisućama tona, za Francusku, Italiju, Nizozemsku i Španjolsku od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



Slika 35. Količine nastaloga komunalnog otpada, prikaz u tisućama tona, za preostalih 13 promatranih država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

#### 4.3.21. Količina nastalog otpada po stanovniku


Na količinu komunalnog otpada po stanovniku utječu količine nastalog otpada, ali i broj stanovnika. U razdoblju od 1995. do 2019. godine količina kilograma po stanovniku kretala se između 210 kilograma po stanovniku (podatak za Hrvatsku iz 1995. godine) do 862 kilograma (Danska, 2011) (Tablica 52.). Gospodarska kriza u 2008. godini utjecala je i na ovaj parametar jer su količine kilograma po stanovniku rasle do 2008. godine, nakon čega slijedi lagani pad. U razdoblju od 2020. godine do 2025. godine u 12 od 17 promatranih država predviđa se porast kilograma otpada po stanovniku. Najveće količine otpada po stanovniku predviđaju se za Dansku u 2025. godini te bi prema procjeni u Danskoj svaki stanovnik proizveo 966 kilograma otpada (Tablica 19.)

Tablica 19. Prikaz predviđenih količina nastalog komunalnog otpada po stanovniku (kg/stanovnik) u 17 država EU-a od 2020. do 2025. godine.

Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	427	425	422	420	418	416
Češka	328	329	331	332	334	335
Danska	903	915	928	941	953	966
Estonija	340	337	334	331	328	324
Francuska	538	540	541	543	544	546
Hrvatska	463	472	481	490	499	507
Irska	634	634	634	634	635	635
Italija	523	524	525	526	527	528
Latvija	420	427	433	440	446	453
Litva	449	452	454	457	460	462
Luksemburg	647	647	647	647	648	648
Mađarska	365	360	355	350	345	340
Malta	684	692	701	710	718	727
Nizozemska	531	528	525	523	520	518
Slovenija	428	424	419	414	409	404
Španjolska	454	448	441	435	428	422
Švedska	471	472	474	476	477	479

#### 4.3.22. Stopa recikliranja komunalnog otpada

Stopa recikliranja komunalnog otpada u porastu je u cijelom promatranom razdoblju ( Slika 36.). Količina recikliranog otpada (recikliranje materijala i kompostiranje) porasla je s 37 milijuna tona (87 kg po stanovniku) u 1995. na 107 milijuna tona (239 kg po stanovniku) u 2019. godini po prosječnoj godišnjoj stopi od 4,3 %. Udio recikliranoga komunalnog otpada povećan je s 19 na 48 % (Eurostat, 2021d). U razdoblju od 1995. do 2019. godine stopa recikliranja kreće se u vrijednostima između 0 % i najviše stope od 59 % (podatak za Sloveniju za 2018. godinu). Zadnji podaci o stopama recikliranja komunalnog otpada za sve promatrane države su iz 2018. godine kada su Belgija, Litva, Luksemburg, Nizozemska i Slovenija bile najuspješnije u stopama recikliranja s iznosom preko 50 %. U razdoblju od 2020. do 2025. godine predviđa se nastavak porasta stope recikliranja u svim državama osim u Hrvatskoj i Malti.



Slika 36. Stopa recikliranja komunalnog otpada u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



#### 4.3.23. Odlaganje komunalnog otpada

Ukupna količina odloženoga komunalnog otpada smanjila se na prostoru EU-a u razdoblju od 1995. do 2019. godine, a predviđa se nastavak takvog trenda i u razdoblju od 2020. do 2025. godine. Ukupna količina odloženog otpada na prostoru EU-a smanjila se sa 121 milijuna tona u 1995. godini na 53 milijuna tona u 2019. godini (Eurostat, 2021d). U 2019. godini 17 promatranih država u ovom istraživanju odložile su oko 34 milijuna tona komunalnog otpada. Prema kreiranom modelu predviđa se da će se do 2025. godine količina odloženoga komunalnog otpada smanjiti za 20 % te da će ukupna količina odloženog otpada iznositi oko 27 milijuna tona. Država s najvećim količinama odloženog otpada je Španjolska (Tablica 20.)

Tablica 20. Prikaz predviđenih količina odloženoga komunalnog otpada (u tisućama tona) u 17 promatranih država EU-a od 2020. do 2025. godine


Godina	2020.	2021.	2022.	2023.	2024.	2025.
Belgija	43	42	45	42	45	42
Češka	1.431	1.372	1.313	1.253	1.194	1.135
Danska	52	50	51	52	50	51
Estonija	97	88	93	85	91	103
Francuska	7.113	6.823	6.532	6.242	5.951	5.660
Hrvatska	1.775	1.851	1.927	2.004	2.080	2.157
Irska	886	838	791	743	696	648
Italija	5.760	5.022	4.284	3.546	2.807	2.069
Latvija	555	554	553	552	551	549
Litva	463	419	375	330	286	241
Luksemburg	29	28	26	24	23	21
Mađarska	1.816	1.716	1.616	1.516	1.416	1.316
Malta	275	280	285	289	294	299
Nizozemska	127	124	125	123	125	124
Slovenija	83	76	82	81	77	82
Španjolska	12.590	12.543	12.496	12.449	12.401	12.354
Švedska	27	25	32	28	31	29

#### **4.3.24. Miješani komunalni otpad i biootpad kao dio miješanoga komunalnog otpada**


Miješani komunalni otpad je otpad koji preostaje kada se iz otpada koji je nastao u kućanstvima izdvoje korisni materijali kao što su papir i karton, biootpad, plastika, staklo, metal, tekstil i drugo. Nastajanje miješanoga komunalnog otpada gotovo je nemoguće izbjeći. Ono što se može učiniti jest odvojeno sakupiti što veće količine korisnih vrsta i na taj način smanjiti količinu miješanoga komunalnog otpada koja će nastati. Stoga, kako bi se količina miješanoga komunalnog otpada svela na najmanju moguću mjeru, potrebno je neprestano ulagati u obrazovanje i infrastrukturu koja bi omogućila što veće primarno odvajanje korisnih vrsta. One količine miješanoga komunalnog otpada koje ipak nastanu potrebno je zbrinuti na ekonomski isplativ te ekološki i zdravstveno siguran način. Podaci o miješanom komunalnom otpadu ne prate se putem Eurostatove baze podataka, kao ni u bilo kojoj drugoj bazi, stoga je bilo izazovno pronaći podatke o količini miješanoga komunalnog otpada za svih 17 država članica Europske unije koje su se promatrale u ovom istraživanju. Zbog navedenog su podaci za Švedsku pronađeni tek od 2003. godine nadalje. Za Francusku nedostaju podaci za 2018. godinu, dok za 2019. godinu podaci nedostaju za čak deset promatranih država. Nedostatak podataka iz 2019. godine objašnjava se činjenicom da se u tim državama podaci o otpadu vjerojatno prate po formuli  $n - 2$ . Zadnja godina za koju su prikupljeni svi podaci je 2017. godina i u toj godini u svih 17 država nastalo je ukupno 63.735.000 tona miješanoga komunalnog otpada. U usporedbi s 1995. godinom (kada je nastalo 69.568.000 tona<sup>4</sup>), radi se smanjenju od 8 %. Vidi se da Italija, Španjolska i Francuska iskaču u ukupnim količinama. U ostalim državama količina miješanoga komunalnog otpada kreće se od 104.000 tona (Malta, 1995.) do 6.468.000 tona (Belgija, 2004.) (Slika 37. i Slika 38.).

---

<sup>4</sup> Nedostaju podaci Švedske.



Slika 37. Količine nastalog miješanoga komunalnog otpada u Francuskoj, Italiji i Španjolskoj od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



Slika 38. Količine nastalog miješanoga komunalnog otpada u preostalim 14 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

Tablica 21. prikazuje količine miješanoga komunalnog otpada koje su predviđene na temelju kreiranog matematičkog modela pomoću umjetnih neuronskih mreža za od 2020. do 2025. godine. U navedenom razdoblju nastavlja se trend kao i u razdoblju od 1995. do 2019. godine kada po količinama ponovno iskaču Španjolska, Francuska i Italija. Usprkos tome, od 2020. do 2025. godine ukupne količine za svih 17 država su u padu. Iako su količine miješanoga komunalnog otpada od 2020. do 2025. godine u padu, po vrijednostima predviđena količina za 2020. godinu neznatno je veća od ukupnih količina iz 1995. godine.

Tablica 21. Predviđena količina miješanoga komunalnog otpada koja će nastati od 2020. do 2025. godine prikazana u tisućama tona

Država/godina	2020.	2021.	2022.	2023.	2024.	2025.
Španjolska	18.567,99	18.600,10	18.632,22	18.664,33	18.696,44	18.728,55
Francuska	18.337,58	18.350,91	18.364,24	18.377,57	18.390,90	18.404,24
Italija	14.535,78	14.121,97	13.708,16	13.294,35	12.880,55	12.466,74
Belgija	4.103,72	4.104,62	4.105,53	4.106,43	4.107,33	4.108,23
Nizozemska	3.297,46	3.271,45	3.245,44	3.219,43	3.193,42	3.167,41
Mađarska	2.623,94	2.573,29	2.522,64	2.471,99	2.421,34	2.370,69
Irska	1.724,61	1.738,74	1.752,87	1.767,01	1.781,14	1.795,27
Danska	1.505,21	1.526,35	1.547,48	1.568,62	1.589,76	1.610,89
Hrvatska	1.383,93	1.395,08	1.406,23	1.417,38	1.428,53	1.439,68
Švedska	1.050,10	1.019,26	988,43	957,60	926,76	895,93
Litva	775,69	756,74	737,79	718,84	699,89	680,94
Latvija	571,13	573,06	574,99	576,93	578,86	580,79
Češka	407,80	404,65	401,50	398,34	395,19	392,04
Estonija	287,17	281,82	276,47	271,12	265,77	260,42
Slovenija	210,45	181,70	152,95	124,20	95,45	66,70
Malta	196,86	199,51	202,16	204,81	207,45	210,10
Luksemburg	180,18	179,95	179,72	179,50	179,27	179,04
Ukupno (1000 t):	69.759,60	69.279,21	68.798,82	68.318,43	67.838,04	67.357,65

Slika 39. prikazuje prostorni prikaz ukupnih količina miješanoga komunalnog otpada koji će nastati u državama od 2020. do 2025. godine.

Ako se prisjetimo prosječnog sastava komunalnog otpada u EU-u (Tablica 3.), na temelju dobivenih vrijednosti možemo izračunati koliko će papira i kartona (30 %), kuhinjskog (30 %) i

vrtnog (zelenog) otpada (12,5 %) (i drugih vrsta) nastati kao dio miješanoga komunalnog otpada. Na temelju udjela pojedinih vrsta otpada u komunalnom otpadu, dobivene su vrijednosti u Tablica 22. Iz navedenog proizlazi da će u 2020. godini oko 21 milijuna tona kuhinjskog otpada i oko 8,7 milijuna tona vrtnog (zelenog) otpada biti bačeno kao dio miješanoga komunalnog otpada. Na taj način baca se potencijalna sirovina za dobivanje komposta ili ulazna sirovina za bioplinška postrojenja te nepotrebno dolazi do rasipanja vrijednih materijala. Tome treba dodati i oko 21 milijuna tona papira i kartona koji se također mogao ponovno iskoristiti za dobivanje recikliranog papira ili u neke druge svrhe.



Slika 39. Količina miješanoga komunalnog otpada koja će u ispitivanim državama nastati od 2020. do 2025. godine

Tablica 22. Količine papira i kartona, kuhinjskog otpada i vrtnog (zelenog) otpada koje nisu odvojeno sakupljene, već čine dio miješanoga komunalnog otpada

Godina	Ukupno nastalo miješanoga komunalnog otpada (1000 t)	Papir i karton (1000 t)	Kuhinjski otpad (1000 t)	Vrtni (zeleni) otpad (1000 t)
2020.	69.759,60	20.927,88	20.927,88	8.719,95
2021.	69.279,21	20.783,76	20.783,76	8.659,90
2022.	68.798,82	20.639,65	20.639,65	8.599,85
2023.	68.318,43	20.495,53	20.495,53	8.539,80
2024.	67.838,04	20.351,41	20.351,41	8.479,76
2025.	67.357,65	20.207,30	20.207,30	8.419,71


#### 4.3.25. Papir i karton

Recikliranjem papira i kartona štede se prirodni resursi i ne ugrožava se bioraznolikost. Dakle, razumljivo je da je recikliranje papira i kartona ekološki puno prihvatljivije u odnosu na spaljivanje ili odlaganje (Villanueva i Wenzel, 2007; Petrić i sur., 2012). Kod odvojenog sakupljanja papira i kartona posebna pozornost trebala bi se posvetiti što učinkovitijem sustavu odvojeno sakupljenog papira (što čišće frakcije) kako bi reciklirani papir bio što bolje kvalitete. Podaci o papirnom i kartonskom otpadu na razini EU-a prate se od 2004. godine nadalje. Podaci se prijavljuju službenom statističkom uredu EU-a svake dvije (parne) godine. Za godine koje nedostaju napravljena je procjena. Prije 2004. godine prikupljeni su podaci samo za Belgiju, Dansku, Češku i Hrvatsku. Zadnja godina za koju su države članice prijavljivale podatke o količini papira i kartona bila je 2018. godina. U toj godini ukupno je sakupljeno 16.165.000 tona papira što je smanjenje od 8 % u odnosu na prvu godinu praćenja (2004. godina) kada je ukupna količina papira i kartona za 17 promatranih država iznosila 17.612.000 tona. Količine papira i kartona po državama koje se predviđaju od 1995. do 2025. prikazane su na Slika 40.

Tablica 23. prikazuje količine papira i kartona koje su predviđene na temelju kreiranog matematičkog modela pomoću umjetnih neuronskih mreža od 2020. do 2025. godine. U navedenom razdoblju, kao i kod miješanoga komunalnog otpada, predviđa se lagani pad količina, a količine se kreću oko 15 milijuna tona godišnje. Države s najvećim količinama papira i kartona su, kao i kod miješanoga komunalnog otpada, Italija, Francuska i Španjolska (Slika 40.).

Tablica 23. Predviđena količina papira i kartona koja će nastati od 2020. do 2025. godine prikazana u tisućama tona

Država/godina	2020.	2021.	2022.	2023.	2024.	2025.
Italija	3.915,93	3.993,94	4.071,96	4.149,97	4.227,98	4.305,99
Francuska	3.762,02	3.666,07	3.570,12	3.474,17	3.378,21	3.282,26
Španjolska	2.001,69	1.936,54	1.871,38	1.806,23	1.741,08	1.675,93
Belgija	1.461,45	1.427,17	1.392,90	1.358,62	1.324,35	1.290,07
Nizozemska	1.435,50	1.400,60	1.365,71	1.330,82	1.295,93	1.261,04
Švedska	723,10	726,07	729,04	732,01	734,98	737,95
Danska	602,82	617,58	632,35	647,11	661,87	676,64
Češka	371,46	382,27	393,07	403,88	414,69	425,50
Mađarska	306,84	298,65	290,46	282,27	274,07	265,88
Irska	188,58	152,14	115,69	79,25	42,81	6,36
Slovenija	156,30	162,20	168,09	173,99	179,88	185,78
Hrvatska	127,01	126,77	126,53	126,29	126,05	125,81
Latvija	126,94	134,90	142,87	150,83	158,79	166,76
Litva	106,79	110,97	115,15	119,33	123,51	127,69
Luksemburg	54,40	54,36	54,32	54,28	54,25	54,21
Estonija	54,00	56,53	57,36	59,83	60,73	61,36
Malta	21,02	22,22	23,42	24,62	25,82	27,02
Ukupno (1000 t):	15.415,86	15.268,99	15.120,43	14.973,50	14.825,01	14.676,24



Slika 40. Količine nastalog papira i kartona u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.



Slika 41. prikazuje prostorni prikaz ukupne količine otpadnog papira i kartona koja će nastati u promatranim državama u razdoblju od 2020. do 2025. godine.



Slika 41. Količina otpadnog papira i kartona koja će nastati u 17 promatраних држава EU-a од 2020. до 2025. године

#### 4.3.26. Drvo


Drvni otpad zbog svog potencijala smatra se vrijednim materijalom za recikliranje i energetske uporabe. Povijesno gledano, glavna opcija iskorištavanja drvnog otpada bilo je spaljivanje zbog njegove relativno visoke ogrjevne vrijednosti. Međutim, drvni otpad može biti prikladan za niz mogućnosti, od izravne ponovne uporabe do recikliranja. Sa sve većim fokusom na recikliranje i cirkularnu ekonomiju u Europi, drvni otpad predstavlja važan izvor sekundarnih sirovina (Faraca i sur., 2019; Berger i sur., 2020) te je bacanje drvnog otpada kao dio miješanoga komunalnog otpada ili kao dio neke druge vrste otpada rasipanje s prirodnim resursima.

Podaci o otpadnom drvu na razini EU-a prate se također od 2004. godine nadalje. Podaci se prijavljuju službenom statističkom uredu EU-a svake dvije (parne) godine. Za godine koje nedostaju napravljena je procjena. Zadnja godina za koju su države članice prijavljivale podatke o količinama otpadnog drva bila je 2018. godina (zbog toga nedostaju podaci za 2019. godinu). U toj godini ukupno je sakupljeno 5.546.000 tona drva, što je povećanje od 38 % u odnosu na prvu godinu praćenja (2004. godina) kada je ukupna količina drva za 17 promatranih država iznosila 4.020.150 tona. Predviđene količine otpadnog drva po državama za razdoblje od 1995. do 2025. prikazane su na Slika 42.

Tablica 24. prikazuje količine otpadnoga komunalnog drva koje su predviđene na temelju kreiranog matematičkog modela pomoću umjetnih neuronskih mreža za razdoblje od 2020. do 2025. godine. U navedenom razdoblju predviđa se porast količina, a količine se kreću između 5,6 i 6,4 milijuna tona godišnje. Države s najvećim količinama drva su Francuska i Italija (Slika 42.).

Tablica 24. Predviđena količina otpadnog drva koja će nastati od 2020. do 2025. godine prikazana u tisućama tona

Država/godina	2020.	2021.	2022.	2023.	2024.	2025.
Francuska	1.970,94	2.054,45	2.137,96	2.221,48	2.304,99	2.388,50
Italija	1.142,21	1.170,05	1.197,90	1.225,74	1.253,58	1.281,43
Švedska	625,01	671,90	718,79	765,68	812,58	859,47
Belgija	598,79	615,24	631,69	648,14	664,60	681,05
Nizozemska	491,74	496,31	500,88	505,45	510,02	514,58
Španjolska	281,75	253,65	225,55	192,55	160,65	128,75
Danska	205,47	201,08	196,69	192,30	187,91	183,52
Češka	71,24	74,62	77,99	81,37	84,74	88,11
Estonija	52,15	52,72	53,26	53,69	54,21	54,59
Slovenija	48,76	50,62	52,49	54,35	56,21	58,07
Irska	37,67	40,61	38,73	39,78	37,91	38,73
Mađarska	20,14	17,56	19,34	19,90	18,18	19,00
Malta	15,07	15,99	16,91	17,82	18,74	19,66
Latvija	13,69	17,92	12,16	16,39	12,62	14,86
Hrvatska	12,53	13,29	14,05	14,81	15,57	16,33
Litva	11,17	14,20	17,23	12,26	13,29	16,32
Luksemburg	4,46	4,38	4,30	4,22	4,13	4,05
Ukupno (1000 t):	5.602,80	5.764,60	5.915,91	6.065,92	6.209,92	6.367,02



Slika 42. Količine nastalog otpadnog drva u 17 država EU-a od 1995. do 2025. godine. Podaci označeni točkastim nizom predstavljaju vrijednosti dobivene ANN modelom.

Slika 43. prikazuje prostorni prikaz ukupnih količina otpadnoga komunalnog drva koje će nastati od 2020. do 2025. godine po državama.



Slika 43. Količina otpadnog drva koja će nastati u razdoblju od 2020. do 2025. godine po državama

#### 4.3.27. Tekstil

U današnje se vrijeme modni stilovi brzo i često mijenjaju. U isto vrijeme tekstilna industrija proizvodi jeftinu i lako dostupnu odjeću pa stoga ne čudi što potrošači često i bez „griznje savjesti“ bacaju odjeću i obuću. Zbog toga je možda potrebno posebnu pozornost obratiti na utjecaj čimbenika kao što su BDP, zarada i sl. na količine nastalog tekstilnog otpada, ponajviše zbog problema neprimjerenoga gospodarenja s tekstilnim otpadom (Dobilaite i sur., 2017).

Podaci o količini tekstilnog otpada na razini EU-a prate se, kao i kod papira i drva, od 2004. godine nadalje. Podaci se prijavljuju službenom statističkom uredu EU-a svake dvije (parne) godine. Za godine koje nedostaju napravljena je procjena. Zadnja godina za koju su države članice prijavljivale podatke o količinama otpadnog tekstila bila je 2018. godina. U toj godini ukupno je sakupljeno 602.570 tona tekstilnog otpada, što je smanjenje od 13 % u odnosu na prvu godinu praćenja (2004. godina) kada je ukupna količina tekstilnog otpada za 17 promatranih država iznosila 691.000 tona (Tablica 58.). U razdoblju od 2020. do 2025. godine predviđa se da će najveće količine tekstilnog otpada nastati u Italiji, Francuskoj i Belgiji, a najmanje u Latviji (Tablica 25.).

Tablica 25. Prikaz predviđenih količina tekstilnog otpada koje će nastati u 17 država EU-a od 2020. do 2025. godine, prikazano u tisućama tona

Država/godina	2020.	2021.	2022.	2023.	2024.	2025.
Italija	162,14	167,34	172,54	177,75	182,95	188,15
Francuska	127,19	110,92	94,65	78,38	62,11	45,84
Belgija	123,64	127,29	130,94	134,59	138,24	141,89
Nizozemska	88,96	89,87	90,78	91,69	92,60	93,51
Španjolska	42,50	43,12	43,73	44,35	44,96	45,57
Češka	15,21	16,19	17,16	18,14	19,12	20,09
Luksemburg	7,46	7,80	8,13	8,47	8,80	9,14
Mađarska	7,21	8,42	6,73	7,78	8,82	7,83
Irska	5,62	7,62	6,25	6,96	5,27	6,62
Litva	3,06	3,20	3,34	3,48	3,63	3,77
Slovenija	2,26	2,31	2,37	2,42	2,47	2,52
Hrvatska	2,26	2,44	2,62	2,80	2,98	3,17
Švedska	2,04	2,21	2,38	2,55	2,72	2,89
Danska	1,96	2,10	2,24	2,38	2,52	2,66
Estonija	1,05	1,09	1,12	1,16	1,19	1,23
Malta	0,76	0,81	0,87	0,93	0,99	1,05
Latvija	0,08	0,08	0,08	0,08	0,09	0,09
Ukupno (1000 t):	593,40	592,81	585,96	583,92	579,47	576,03

Slika 44. prikazuje prostorni prikaz ukupnih količina otpadnog komunalnog tekstila koje će nastati u državama u razdoblju od 2020. do 2025. godine.



Slika 44. Količina otpadnog tekstila koja će nastati u promatranim državama EU-a od 2020. do 2025. godine

#### **4.4. Analiza glavnih komponenti (engl. *Principal Component Analysis – PCA*)**

Glavni cilj analize glavnih komponenti je izdvajanje važnih informacija iz „baze“, odnosno iz skupa podataka, te izraziti te informacije kao skup novih ortogonalnih varijabli koje se nazivaju glavne komponente (Ringér, 2008; Abdi i Williams, 2010; Noori i sur., 2010).

Točke prikazane na PCA grafu, koje su geometrijski blizu jedna drugoj, ukazuju na sličnost vrijednosti parametara koji opisuju ove točke. Orijentacija vektora koji opisuje varijablu u prostoru faktora ukazuje na trend rasta ove varijable, a duljina vektora proporcionalna je kvadratu koeficijenta korelacije između odgovarajuće vrijednosti varijable i same varijable. Kutovi između varijabli pokazuju stupanj njihove korelacije (mali kutovi odgovaraju visokim stupnjevima korelacije).

##### **4.4.1. PCA – grupa ekonomskih pokazatelja**

PCA prikazanih podataka (grupa ekonomskih pokazatelja) pokazala je kako prve dvije glavne komponente čine 59,38 % ukupne varijance (39,83 % i 19,54 %) u faktorskom prostoru od sedam varijabli (grupa ekonomskih pokazatelja) (Slika 45.).


Uzevši u obzir rezultate PCA analize, varijable iz grupe ekonomskih pokazatelja: inozemna izravna ulaganja (DIRE) (koja su doprinijela 15,0 % ukupne varijance, na temelju korelacija), ukupne obveze financijskog sektora (TFS) (27,1 %) i BDP po stanovniku (RGDP) (24,2 %) pokazali su pozitivan utjecaj prema prvoj glavnoj komponenti PC1, dok je neto vanjski (inozemni) dug (NED) (32,4 %) pokazao negativan utjecaj prema prvoj glavnoj komponenti (Slika 45.)

Pozitivan doprinos proračunu druge glavne komponente primijećen je za deflacionirane cijene nekretnina (HPI) (36,3 % ukupne varijance, na temelju korelacija) i nominalni efektivni tečaj (NEER) (23,0 %), dok je negativan utjecaj na izračunavanje druge glavne komponente primijećen za nominalni efektivni tečaj (GDP) (28,9 %).

U nastavku su nabrojane države članice Europske unije koje imaju povećane vrijednosti parametara u grupi ekonomskih pokazatelja. U usporedbi s drugim državama prikazanim na PCA grafu Francuska i Italija imaju najveće vrijednosti za varijablu koja označava BDP po tržišnim cijenama. Luksemburg ima značajno veće vrijednosti za varijable koje označavaju BDP po stanovniku, ukupne obveze financijskog sektora, kao i neto vanjski (inozemni) dug i inozemna izravna ulaganja. Da vrijednosti za Luksemburg značajno odskoču, jasno pokazuje i



Slika 45. Najveće zabilježene vrijednosti varijable koja označava nominalni efektivni tečaj zabilježene su za Latviju i Litvu. Harmonizirani indeks cijene stambenih objekata ponovno je najveći kod Latvije.



Slika 45. PCA analiza za grupu ekonomskih pokazatelja

GDP – BDP po tržišnim cijenama; RGDP – BDP po stanovniku; TFD – ukupne obveze financijskog sektora; NED – neto vanjski (inozemni) dug; NEER – nominalni efektivni tečaj; DIRE – inozemna izravna ulaganja; HPI – deflacirane cijene nekretnina.


#### 4.4.2. PCA – grupa pokazatelja zaposlenosti i zarade

PCA prikazanih podataka (pokazatelj zaposlenosti i zarade) na Slici 46. pokazuje da prve dvije glavne komponente čine 66,67 % ukupne varijance (36,75 % i 29,92 %) u faktorskom prostoru od četiri varijable (pokazatelj zaposlenosti i zarade).

Uzevši u obzir rezultate PCA pokazatelja zaposlenosti i zarade, varijabla „Ukupno zaposleni“ (TEMP) (koja je doprinijela 17,0 % ukupne varijance, na temelju korelacija), godišnji podaci o stopi nezaposlenosti (URAD) (51,5 %) i stopa nezaposlenosti mladih (YUR) (25,4 %) pokazali su pozitivan utjecaj prema prvoj glavnoj komponenti PC1, dok je srednji ekvivalent neto prihoda (MENI) (32,4 %) pokazao negativan utjecaj prema prvoj glavnoj komponenti (Slika 46.). Negativan doprinos proračunu druge glavne komponente primijećen je za varijablu „Ukupno

zaposleni“ (TEMP) (30,7 % ukupne varijance, na temelju korelacija) i srednjeg ekvivalenta neto prihoda (MENI) (63,3 %).

Varijabla koja označava broj ukupno zaposlenih najveća je kod Francuske i Italije. Španjolska ima najveće vrijednosti za varijablu koja označava godišnji podatak o stopi nezaposlenih, dok Litva ima najveće vrijednosti za varijablu koja označava godišnji podatak o stopi nezaposlenih. Varijabla koja označava srednji ekvivalent neto prihoda za Luksemburg značajno je veća od drugih zemalja prikazanih na PCA grafu.



Slika 46. PCA analiza za grupu pokazatelja zaposlenosti i zarade


TEMP – ukupno zaposleni od 15. do 64. godine; URAD – godišnji podaci o stopi nezaposlenosti; YUR – stopa nezaposlenosti mladih; MENI – srednji ekvivalent neto prihoda.

#### 4.4.3. PCA – grupa pokazatelja obrazovanja

PCA prikazanih podataka za pokazatelj obrazovanja pokazuje da prve dvije glavne komponente čine 91,26 % ukupne varijance (58,14 % i 33,12 %) u faktorskom prostoru od pet varijabli (pokazatelj obrazovanja), Slika 47.

Uzevši u obzir rezultate PCA pokazatelja obrazovanja, varijabla koja označava srednjoškolsko ili više obrazovanje (EL2) doprinijela je s 33,7 % ukupne varijance, na temelju korelacija. Varijabla koja obuhvaća sve stanovnike koji imaju završeno srednjoškolsko obrazovanje ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje (EL3) doprinijela je s 23,9 % i

navedene dvije varijable pokazuju pozitivan utjecaj prema prvoj glavnoj komponenti PC1. Osnovnoškolsko i niže srednjoškolsko obrazovanje (EL1) s 33,2 % pokazuje negativan utjecaj prema prvoj glavnoj komponenti (Slika 47.) Pozitivan doprinos proračunu druge glavne komponente primijećen je za varijablu „Očekivani životni vijek“ (LE) (45,2 % ukupne varijance, na temelju korelacija) i za varijablu ELT koja označava sve razine visokog obrazovanja (40,7 %), dok je negativan rezultat izračunavanja druge glavne komponente primijećen za EL3 (13,0 %). Najveće vrijednosti očekivanog životnog vijeka u usporedbi s drugim državama imala je Španjolska. Najveće vrijednosti za varijablu koja označava osnovnoškolsko i niže srednjoškolsko obrazovanje imala je Malta (vidljivo na Slika 47.). Litva ima najveće vrijednosti za varijablu koja označava srednjoškolsko ili više obrazovanje. Češka ima najveće vrijednosti za varijablu koja označava srednjoškolsko obrazovanje ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje. Luksemburg ima veće vrijednosti u usporedbi s drugim zemljama za varijablu koja označava visoko obrazovanje.



Slika 47. PCA analiza za grupu pokazatelja obrazovanja


EL1 – predškolsko obrazovanje, primarno obrazovanje i niže sekundarno obrazovanje; EL2 – više sekundarno obrazovanje, post-sekundarno i tercijarno obrazovanje; EL3 – više srednje obrazovanje i post-sekundarno, netercijarno obrazovanje; ELT – visoko obrazovanje; LE – očekivani životni vijek.

#### 4.4.4. PCA – grupa pokazatelja o otpadu

PCA prikazanih podataka (podaci o otpadu) pokazala je da prve dvije glavne komponente čine 80,14 % ukupne varijance (46,68 % i 33,46 %) u faktorskom prostoru od četiri varijable (grupe podataka o otpadu), Slika 48.

Uzevši u obzir rezultate PCA analize za grupe podataka o otpadu, varijabla koja označava količinu odloženoga komunalnog otpada (DL) (s doprinosom od 45,4 % ukupne varijance, na temelju korelacija) i varijabla koja označava količinu nastaloga komunalnog otpada (GMWT (49,7 %) pokazale su pozitivan utjecaj prema prvoj glavnoj komponenti PC1 (Slika 48.). Pozitivan doprinos proračunu druge glavne komponente primijećen je za varijablu koja označava stopu recikliranja komunalnog otpada (RRMW, 50,40 % ukupne varijance, na temelju korelacija) i varijabla koja označava količinu komunalnog otpada po stanovniku (GMWK, 42,4 %).

Najveću vrijednost stope recikliranja komunalnog otpada ima Slovenija. Najveće količine odloženoga komunalnog otpada imala je Italija. Francuska, Italija i Španjolska imaju znatno veću količinu nastaloga komunalnog otpada u usporedbi s drugim promatranim državama, dok Danska odskaka po količinama komunalnog otpada po stanovniku.



Slika 48. PCA analiza za podatke o otpadu

GMWT – nastali komunalni otpad, prikaz u tisućama tona; GMWK – nastali komunalni otpad, kilogram po stanovniku; RRMW – stopa recikliranja komunalnog otpada; DL – odlaganje komunalnog otpada.


#### 4.4.5. PCA – grupa pokazatelja biorazgradivoga komunalnog otpada

PCA prikazanih podataka (koji predstavljaju vrste biorazgradivoga komunalnog otpada) pokazala je kako prve dvije glavne komponente čine 91,70 % ukupne varijance (76,96 % i 14,74 %) u faktorskom prostoru od četiri varijable (grupe biorazgradivoga komunalnog otpada), Slika 49.

Uzevši u obzir rezultate PCA grupe biorazgradivoga komunalnog otpada, miješani komunalni otpad (MMPW) (koji je doprinio 26,2 % ukupne varijance, na temelju korelacija), otpadni papir i karton (PCW) (31,1 %), otpadni drveni otpad (WW) (21,9 %) i tekstilni otpad (TW) (20,8 %) pokazali su negativan utjecaj prema prvoj glavnoj komponenti PC1 (Slika 49.).

Positivan doprinos proračunu druge glavne komponente primijećen je za otpadni drveni otpad (WW) (36,6 % ukupne varijance, na temelju korelacija), dok je negativan rezultat izračunavanja druge glavne komponente primijećen za tekstilni otpad (TW) (56,2 %).

Slika 49. pokazuje da Italija, Španjolska i Francuska iskaču u ukupnim količinama miješanoga komunalnog otpada. Francuska značajno iskače u usporedbi s drugim promatranim državama i kod količine otpadnog papira i kartona, drva i tekstilnog otpada.



Slika 49. PCA analiza za grupu podataka koja predstavlja vrste biorazgradivoga komunalnog otpada

MMPW – količine miješanoga komunalnog otpada u tisućama tona; PCW – količine neopasnog otpadnog papira i kartona u tisućama tona; WW – količine neopasnog otpadnog drva u tisućama tona; TW – količine neopasnog otpadnog tekstila u tisućama tona.

## 5. RASPRAVA

### 5.1. Utjecaj ulaznih varijabli na stvaranje otpada

#### 1. Broj stanovnika

Jedna od glavnih prijetnja održivosti u današnje vrijeme je stvaranje sve veće količine komunalnog otpada zbog brzog širenja populacije i, s time, zbog rasta razine potrošnje. Na globalnoj razini proizvodnja otpada ima deseterostruki porast u prošlom stoljeću (Castillo-Giménez i sur., 2019). Stoga, ne čudi kako je upravo parametar broja stanovnika odabran kao prva ulazna vrijednost za kreiranje matematičkog modela. Prema Kulisz i Kujawskoj (2020), najmanje države članice Europske unije imaju zabilježenu najnižu razinu nastalog otpada i obrnuto, veće države članice imaju zabilježene veće količine otpada (Kulisz i Kujawska, 2020). Podaci u ovom istraživanju potvrdili su spomenutu činjenicu kako su države s najmanjim brojem stanovnika (Malta i Luksemburg) imale i najnižu razinu nastalog otpada. Države s najvećim brojem stanovništva (Francuska, Italija, Španjolska) imaju i najveću količinu nastalog otpada. Navedeno vrijedi za sve promatrane vrste otpada, uz blaže oscilacije, primjerice kod tekstilnog otpada.

U Prilogu 5.6 je grafički prikaz utjecaja ulaznih varijabli na količine izlaznih rezultata. Slika 50., 51., 52. i 53. pokazuju kako broj stanovnika pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 3,26 % za miješani komunalni otpad, 3,77 % za otpadni komunalni papir i karton, 1,73 % za otpad od drva i 1,80 % za testilni otpad. Iz navedenog je razvidno kako su rezultati ovog istraživanja u skladu s dosadašnjim istraživanjima (Badruddin i sur., 2002; Gui i sur., 2019; Kulisz i Kujawska, 2020). Moglo bi se zaključiti da su nastale količine svih četiriju promatranih vrsta otpada povezane s brojem ljudi te kako broj stanovnika itekako utječe na nastanak otpada.

#### 2. Životni vijek

Očekivani životni vijek važan je teorijski indikator koji se koristi kao pokazatelj ukupnog razvoja zemlje. Iako se očekivani životni vijek u posljednjih deset godina povećao u većini zemalja svijeta, valja naglasiti kako duži život ne znači nužno zdraviji, aktivniji i neovisniji život. Navedeno je važno imati na umu s obzirom na sve veći broj starijih i vrlo starih ljudi u EU-u (Omanović i sur., 2020; Eurostat, 2020c).

U istraživanju Ghinea i sur. (2016) varijable „Populacija u dobi od 15. do 59. godine“ i „Ukupni komunalni otpad“ značajni su čimbenici za analizu i snažno utječu na nastanak otpada, dok je životni vijek manje značajni čimbenik i može se zaključiti kako učinak pokazatelja očekivanog

životnog vijeka nije statistički značajan ( $p = 0,301$ ). Rezultati prikazani na Slikama 50. – 53. (Prilog 6.) pokazuju da životni vijek u ovom istraživanju negativno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: -3,88 % za miješani komunalni otpad, -1,97 % za otpadni komunalni papir i karton, -6,22 % za otpad od drva i -7,61 % za tekstilni otpad. Iz navedenog je vidljivo kako su rezultati ovog istraživanja u suprotnosti s istraživanjem Ghinea i sur. (2016). Također, podaci daju naslutiti kako se očekivani životni vijek u ovom kontekstu ne može promatrati kao pokazatelj razvoja jer bi u tom slučaju utjecaj na stvaranje otpada trebao biti pozitivan.

### **3. Ekonomski pokazatelji**

Rast stanovništva i sve veći izbor proizvoda na tržištu rezultirali su masovnom proizvodnjom, a navedeno je vidljivo diljem svijeta. U skladu s time, i ukupna količina nastalog otpada povezana je s brojem ljudi i veličinom gospodarstva u pojedinim zemljama (Dyson i Chang, 2005; Karak i sur., 2012). Očekuje se kako će financijska razina države, kao i životni standard njezinih građana, utjecati na stvaranje komunalnog otpada. S druge strane, politike sprečavanja i smanjenja nastanka otpada mogu uravnotežiti potencijalno povećanje otpada. Ekonomska kriza i pogoršanje životnog standarda na sličan način mogu utjecati na smanjivanje količine nastalog otpada. Kao primjer može se uzeti ekonomska kriza 2008. godine. Između 2008. i 2009. ukupni prihod pao je za 6,4 % u EU-28 (vidljivo i kao pad BDP-a po tržišnim cijenama, Slika 12.), dok se količina komunalnog otpada u EU-28 između 2008. i 2009. godine smanjila samo 1 %, ali trend smanjenja količine komunalnog otpada zaustavio se tek 2015. godine.

BDP je makroekonomski indikator koji prikazuje ukupnu vrijednost proizvoda i usluga stvorenih unutar granica jedne države tijekom godinu dana (Državni zavod za statistiku, 2018). Porast ili pad BDP-a izravno je povezan sa stanjem gospodarstva jer ako država proizvodi, BDP raste. Zbog toga rastu zaposlenost i plaće, ljudi više zarađuju i u mogućnosti su više trošiti. Što je gospodarski rast veći, društvo više troši i očekuje se veća proizvodnja otpada. U obrnutoj situaciji, država prolazi kroz gospodarsku krizu, BDP pada, ljudi manje zarađuju i, povezano s time, manje troše odnosno kupuju (Namlis i Komilis, 2019).

Kusch i Hills (2017) dokazali su kako postoji snažna veza između gospodarskog razvoja (kao glavni gospodarski i ekonomski indikator koristio se upravo BDP) i nastanka električnog i elektroničkog otpada (EE otpad). Otpadnu električnu i elektroničku opremu opisuje visoka ekonomska elastičnost, što znači da će gospodarski rast rezultirati odgovarajućim povećanjem EE otpada ( $r^2 = 0,86$ ) (Kusch i Hills, 2017). Slično istraživanje provode Namlisa i Komilisa

(2019) kojem je bio cilj rada istražiti potencijalni utjecaj četiriju socioekonomskih indeksa na stvaranje otpada. U njihovom istraživanju EE otpad, papirni i drveni otpad, otpadna ulja, male baterije, otpadni metali i gume bili su u pozitivnoj korelaciji s BDP-om što ukazuje da gospodarski rast izravno utječe na stvaranje otpada. Podaci za sve nabrojene vrste otpada bili su statistički značajni, a najbolji rezultati dobiveni su upravo za EE otpad u korelaciji s BDP-om (Namlis i Komilis, 2019). Kako bi se istražila veza između BDP-a i stvaranja miješanoga komunalnog otpada, otpadnoga komunalnog papira i kartona, drva i tekstila, u ovom istraživanju korištene su dvije vrijednosti BDP-a: BDP po tržišnim cijenama i BDP po stanovniku. Pretpostavka je bila da s povećanjem BDP-a (BDP-a po tržišnim cijenama i BDP-a po stanovniku) dolazi i do povećanja količina nastalog otpada.

Rezultati prikazani na Slikama 50. – 53. (Prilog 6.) pokazuju da BDP po tržišnim cijenama u ovom istraživanju pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 2,98 % za miješani komunalni otpad, 4,29 % za otpadni komunalni papir i karton, 4,62 % za otpad od drva i 1,65 % za tekstilni otpad. Time je potvrđena početna pretpostavka. Rezultati su također u skladu s dosadašnjim istraživanjima Kuscha i Hillsa (2017) i Namlisa i Komilisa (2019) koji potvrđuju da je BDP utjecajan čimbenik za stvaranje otpada.

S druge strane, BDP po stanovniku daje sasvim suprotne rezultate i negativno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: -2,80 % za miješani komunalni otpad, -1,82 % za otpadni komunalni papir i karton, -3,11 % za otpad od drva i -0,95 % za tekstilni otpad. Istraživanje provedeno u Finskoj dokazuje kako može doći do situacije razdvajanja proizvodnje komunalnog otpada i BDP-a. Autori objašnjavaju kako su poboljšane mjere sprečavanja nastanka otpada, kao i u tadašnje vrijeme novi Zakon o gospodarenju otpadom, pridonijeli tome da BDP više nema ključnu ulogu u stvaranju otpada (Sokka i sur., 2007). Iz navedenog se može zaključiti da iako je BDP važan čimbenik koji utječe na stvaranje otpada, mjere sprečavanja nastanka otpada, kao i edukacija te promjena svijesti građana mogu značajno utjecati na stvaranje otpada. Time BDP i stvaranje otpada više nisu u potpuno jasnoj i jednostavnoj vezi kao što se pretpostavljalo.

Povezano s BDP-om, u ovom je istraživanju korišten i parametar ukupne obveze financijskog sektora. Ukupne obveze financijskog sektora negativno utječu na sve četiri promatrane vrste otpada s relativnim utjecajem od: -3,48 % za miješani komunalni otpad, -3,17 % za otpadni komunalni papir i karton, -3,07 % za otpad od drva i -1,92 % za tekstilni otpad. S obzirom na to da je mjerna jedinica za parametar ukupne obveze financijskog sektora postotak BDP-a, ovaj je parametar direktno povezan s količinama i promjenom BDP-a. Također, Winklerovo istraživanje (2009) potvrđuje kako struktura financijskog sustava utječe na gospodarski rast.



Levine (2005) dodatno objašnjava kako ekonomski rast ovisi o efikasnosti financijskog sustava. Iz navedenog bi se moglo zaključiti da ako financijski sustav nije efikasan i ako dođe do povećavanja ukupnih obveza financijskog sektora, može doći do smanjenja nastanka otpada jer je navedeno povezano i s gospodarskom situacijom, životnim uvjetima, smanjenom likvidnošću i padom BDP-a. U skladu s navedenim, rezultati dobiveni istraživanjem u skladu su s istraživanjima Winklera (2009) i Levinea (2005).

Neto vanjski dug je pojam koji označava zaduživanje zemlje u inozemstvu kako bi podmirila razliku između državnog rashoda koji je veći od državnih prihoda. Prilikom otplate vanjskog duga sredstava izlaze iz države, raste trgovinski deficit i opsluživanje može imati ozbiljne posljedice na stvarni gubitak proizvodnih mogućnosti zemlje dužnika. Ako javni dug nije uravnotežen ili ako država krivo alocira dobivene resurse, može doći do inflacije i nelikvidnosti, a uz druge makroekonomske prilike, pojam vanjski dug usko je vezan za pojam financijska kriza. Uzročno-posljedično u takvim situacijama financijska kriza vodi smanjenju stope BDP-a, a u situacijama kad BDP pada, ljudi imaju manje novca i manje troše (Bolfek i Knežević, 2011). Povezano s time, u takvim se situacijama može očekivati i smanjenje nastanka otpada (Ralašić, 2021). Međutim, ako se države ili nacije zadužuju kako bi kupile neku vrstu imovine ili kapitala, a posuđen novac koriste za izgradnju tvornica ili razvoj tehnologije i/ili energetike, govorimo o produktivnom dugu. Kod produktivnog duga, ako država ne pati od makroekonomske nestabilnosti, dolazi do gospodarskog razvoja i smanjenja siromaštva (Ajayi i Oke, 2012).

Utjecaj neto vanjskog duga na stvaranje otpada analiziran je korištenjem godišnjeg neto vanjskog duga kao postotka BDP-a. U ovom istraživanju neto vanjski dug pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 2,17 % za miješani komunalni otpad, 1,82 % za otpadni komunalni papir i karton, 5,13 % za otpad od drva i 0,49 % za tekstilni otpad. S obzirom na to da je neto vanjski dug utjecao na povećanje nastanka otpada, može se pretpostaviti kako nijedna od 17 promatranih država ne pati od makroekonomskih nestabilnosti te da je neto vanjski dug bio u obliku pozitivnog duga koji je pozitivno utjecao na gospodarstvo, a, povezano s time, i na količine nastalog otpada. Navedeni rezultati podupiru zaključke Ajayi i Oke (2012).

Promjenom nominalnog i realnog tečaja mijenja se omjer vrijednosti između domaće i strane valute, mijenjaju se kupovna moć i cijene na tržištu te se na taj način utječe na konkurenciju na tržištu (Koški, 2009). Kao što se cijene mogu mijenjati zbog promjene nominalnog tečaja, na sličan način ljudi svjesno mogu mijenjati cijenu proizvoda i usluga. Jedan takav primjer je i snižavanje cijena pred istekom roka korištenja nekog proizvoda. Na taj način želi se dovesti do porasta prodaje i sprečavanja nastanka otpada (Helmer, 2021). Pritom se misli na snižavanje

cijena prehrambenim proizvodima koji su pred istekom roka kako bi se spriječilo nastajanje otpada od hrane. Čini se logičnim da bi sniženje cijena uzrokovano padom nominalnog efektivnog tečaja na sličan način moglo potaknuti ljude na kupovinu, a, povezano s time, i na stvaranje otpada. U ovom istraživanju nominalni efektivni tečaj ima relativni utjecaj od: 0,18 % za miješani komunalni otpad, -0,21 % za otpadni komunalni papir i karton, 1,62 % za otpad od drva i -1,61 % za tekstilni otpad. Početna pretpostavka točna je za miješani komunalni otpad i otpadni papir i karton.

Inozemna izravna ulaganja obuhvaćaju sve vrste ulaganja u gospodarske djelatnosti neke zemlje zbog čega je ovo važan makroekonomski čimbenik koji (izravno i neizravno) utječe na gospodarski rast. Priljevi izravnih inozemnih ulaganja mogu utjecati na gospodarski rast pružanjem menadžerskih vještina i boljih tehnologija te povećanjem produktivnosti u zemlji domaćinu. Izravna strana ulaganja ujedno su i jedan od najvažnijih načina prijenosa tehnologije iz razvijenih zemalja u zemlje u razvoju (Sokhanvar, 2019). Tako su primjerice Feeny i sur. (2014.) ispitali učinak izravnih stranih ulaganja na gospodarski rast 209 zemalja u razdoblju od 1971. do 2010. Rezultati su pokazali kako u uzorku svih zemalja povećanje izravnih stranih ulaganja od 10 % BDP-a dovodi do povećanja stope rasta BDP-a za 2 % (Feeny i sur., 2014). Spomenut primjer pokazuje blagotvorni učinak izravnih stranih ulaganja na gospodarski rast, iako u provedenim istraživanjima učinak inozemnih ulaganja nije uvijek u jasnoj pozitivnoj vezi s gospodarskim rastom. Sokhanvar (2019) u svojem istraživanju primjećuje negativan učinak izravnih stranih ulaganja na rast BDP-a u većini zemalja iz uzorka. Navedeno pokazuje kako uključivanje određene države u proces integracije, liberalizacija trgovine i veća izravna strana ulaganja ne moraju uvijek biti od koristi za gospodarstvo (Sokhanvar, 2019).

U ovom istraživanju korišteni podaci o inozemnim ulaganjima izraženi su kao postotak BDP-a kako bi se uklonio učinak razlika u veličini gospodarstava zemalja izvjestiteljica. Ovaj ekonomski parametar obično se ne koristi kod projekcija nastanka otpada, ali može dati određenu ekonomsku sliku zemlje koja se istražuje jer se inozemna izravna ulaganja obično rade u zemljama u razvoju (Bilas i Franc, 2006; Eurostat, 2021a). Rezultati provedenog istraživanja pokazuju kako varijabla „Inozemna izravna ulaganja“ ima relativni utjecaj od: -2,10 % za miješani komunalni otpad, -2,27 % za otpadni komunalni papir i karton, 1,21 % za otpad od drva i -2,11 % za tekstilni otpad. Na temelju dobivenih rezultata može se zaključiti da inozemna izravna ulaganja negativno utječu na stvaranje miješanoga komunalnog otpada, otpadnoga komunalnog papira i kartona te tekstilnog otpada. Može se pretpostaviti kako inozemna izravna ulaganja nisu značajnije utjecala na porast BDP-a i, povezano s time, nije došlo do povećanja nastanka otpada. Navedeni podaci mogu podržati rezultate Sokhanvara

(2019) koji pokazuju da inozemna izravna ulaganja ne moraju uvijek pratiti porast BDP-a, a, povezano s time, ni porast količina nastalog otpada.

Harmonizirani indeks cijene stambenih objekata (ili indeks realnih cijena nekretnina) ovisan je o stanju na tržištu i iznosu inflacije s obzirom na to da se u omjer stavlja inflacija cijena stambenih objekata u odnosu na opću inflaciju. Najjednostavnije rečeno, inflacija predstavlja rast cijena dobara i usluga zbog čega se za isti iznos prije inflacije moglo kupiti više nego nakon inflacije. Drugim riječima, inflacijom se smanjuje vrijednost valute u određenom vremenskom razdoblju (Europska središnja banka, 2021). U ovom provedenom istraživanju varijabla „Harmonizirani indeks cijene stambenih objekata“ ima relativni utjecaj od: 1,44 % za miješani komunalni otpad, 2,38 % za otpadni komunalni papir i karton, 5,66 % za otpad od drva i -0,27 % za tekstilni otpad. Prema dobivenim rezultatima, harmonizirani indeks cijene stambenih objekata pozitivno utječe na količine nastalog miješanoga komunalnog otpada, otpadni komunalni papir i karton i komunalni drveni otpad.

#### **4. Zaposlenost i zarada**

Svakodnevna potrošnja ovisi o količini raspoloživoga novca za potrošnju. Kao što je već prethodno navedeno, što je više novca slobodno za potrošnju, veća je potrošačka moć, a u isto vrijeme nastaje i više (komunalnoga) otpada. Navedeno osobito vrijedi za stanovnike urbanih sredina gdje su zaposlenost i prosječno primanje veći nego kod stanovnika ruralnih krajeva. Stanovnici sela i predgrađa te stanovnici područja s nižom zaposlenošću i nižim plaćama obično zbog svog načina života i uvjeta u kojima žive proizvode manje količine otpada po stanovniku nego stanovnici gradova (Grebeš, 2017). U istraživanju provedenom u sklopu ovog doktorskog rada varijabla „Ukupno zaposleni“ ima relativni utjecaj od: 2,84 % za miješani komunalni otpad, 3,65 % za otpadni komunalni papir i karton, 0,41 % za otpad od drva i -0,34 % za tekstilni otpad. Dobiveni rezultati za miješani komunalni otpad, papir i karton te drvo u skladu su s Grebešinim istraživanjem (2017) u kojem autorica navodi kako više otpada nastaje ondje gdje je veća zaposlenost (Grebeš, 2017).

Suprotan parametar od broja ukupno zaposlenih je podatak o broju nezaposlenih. Što je više nezaposlenih, potrošačka moć je manja, a život je teži. Manje se troši i kupuje, a količina otpada je manja (Prvonožec, 2020). U istraživanju provedenom u sklopu ovog doktorskog rada varijabla „Godišnji podaci o stopi nezaposlenih“ ima relativni utjecaj od: 0,30 % za miješani komunalni otpad, -1,94 % za otpadni komunalni papir i karton, -0,68 % za otpad od drva i 0,95 % za tekstilni otpad. Dobiveni rezultati za otpadni papir, karton i drvo imaju negativan utjecaj na proizvodnju otpada i u skladu su s istraživanjem Prvonožac (2020).

Stopa nezaposlenosti mladih u dobi od 15. do 24. godine još je jedan parametar kojim se želi istražiti utjecaj stope nezaposlenosti na stvaranje otpada. Prvonožac (2020) u svom radu objašnjava kako visoke stope nezaposlenosti mladih utječu na pad broja poreznih obveznika, povećanje socijalnih naknada, pad kupovne moći stanovništva. Zbog smanjene potražnje dobara i usluga smanjuje se proizvodnja, a visoke stope nezaposlenih imaju negativan utjecaj i na mirovinske i zdravstvene sustave. U ovom istraživanju varijabla „Stopa nezaposlenosti mladih“ ima relativni utjecaj od: -0,25 % za miješani komunalni otpad, -2,70 % za otpadni komunalni papir i karton, -2,01 % za otpad od drva i 1,53 % za tekstilni otpad. Iz rezultata se može zaključiti kako stopa nezaposlenosti mladih negativno utječe na proizvodnju miješanoga komunalnog otpada, otpada od papira i kartona i otpada od drva. Kada se analizira utjecaj stopa nezaposlenosti na stvaranje otpada, zanimljivo je istaknuti istraživanje Halla i Nguyen (2012). Oni navode kako bi smanjenje stopa odlaganja i povećanje stopa recikliranja moglo pružiti priliku za dodatno zapošljavanje u sektoru gospodarenja otpadom. Prema autorima, najveća područja zapošljavanja u sektoru gospodarenja otpadom (s 40 %) su skupljanje i razvrstavanje otpada iz kućanstva i rad u reciklažnim dvorištima. Za usporedbu, rad na odlaganju, spaljivanju i kompostiranju otpada zajedno čini oko 5 % zaposlenih u sektoru gospodarenja otpadom. Isti postotak (5 %) ima i prikupljanje i obrada opasnog otpada. Polovica svih poslova odnosi se na oporabu i recikliranje (Hall i Nguyen, 2012). Iz navedenog se može zaključiti kako sustav gospodarenja otpadom temeljen na hijerarhiji otpada može pružiti izvrsne temelje za mogućnost zapošljavanja, čime bi se otvarila nova radna mjesta i potakle pozitivne promjene za okoliš.

Naravno, s brojem zaposlenih povezan je i prihod koji se određenim radom zarađuje. Niz studija (Sabarinah, 1997; Bandara i sur., 2007; Foday i sur., 2012; Ogwueleka, 2013) pokazao je kako prihod pozitivno utječe na stvaranje otpada. Međutim, neki su istraživači (Medina, 1997; Badruddin i sur., 2002; Passarini i sur., 2011) primijetili kako ne postoji točna i jasna povezanost između proizvodnje otpada i prihoda. Utvrđeno je kako povezanost prihoda s količinom proizvedenog otpada ovisi o stupnju razvoja pojedine države. Također se može reći kako veza između prihoda i stvaranja otpada nije jednoznačni pokazatelj jer ponekad može doći do razdvajanja proizvodnje otpada i prihoda. Naprimjer, na području sjeverne Italije uočeno je relativno razdvajanje između stvaranja otpada i godišnjeg prihoda po stanovniku, iako je navedeno područje po pitanju gospodarske aktivnosti prilično homogena regija (Passarini i sur., 2011).

U ovom istraživanju varijabla „Srednji ekvivalent neto prihoda“ pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 1,57 % za miješani komunalni otpad, 2,02 %

za otpadni komunalni papir i karton, 6,68 % za otpad od drva i 4,58 % za tekstilni otpad. Pozitivan utjecaj neto prihoda na stvaranje otpada u skladu je s istraživanjima Sabarinah, 1997; Bandara i sur., 2007; Foday i sur., 2012 i Ogwueleka, 2013, koja pokazuju da prihod pozitivno utječe na stvaranje otpada. Također, u istraživanju provedenom na 39 općina u Brazilu uočena je statistički značajna linearna korelacija između dohotka po glavi stanovnika i godišnje proizvodnje komunalnog otpada ( $r^2 = 0,391$ ) (Namlis i Komil, 2019).

## 5. Vanjska trgovina

„Vanjska trgovina je gospodarska djelatnost koja obuhvaća razmjenu robe i usluga s inozemstvom, odnosno sveukupnu razmjenu materijalnih i nematerijalnih dobara između zemalja.“ (Andrijanić, 2005) Vanjska trgovina utječe i na cijene na domaćem tržištu jer se cijena domaćeg tržišta mora prilagoditi cijeni na svjetskom tržištu, a cijena svjetskog tržišta nastaje na temelju ponude i potražnje između različitih država. Vanjska trgovina ovisi o stupnju razvijenosti gospodarstva, veličini i strukturi tržišta, gospodarskom kretanju u svijetu i o ekonomskoj politici određene zemlje (Grdović Gnip, 2009). Jedan od razloga zašto se značajne količine resursa ne troše ondje gdje nastaju je jednostavna činjenica da stanovništvo i resursi nisu jednako raspoređeni diljem svijeta. Upravo globalna razmjena (u obliku vanjske trgovine) omogućuje stanovništvu da živi i troši neovisno o lokalnim resursima. Na taj se način lokalno gospodarstvo može razvijati bez obzira na raspoloživost domaćih resursa (Haberl i sur., 2016). Povezano s time, zemlje s visokim stopama uvoza i s visokim dohotkom pokazuju veći materijalni otisak (engl. *material footprint*). Materijalni otisak je pokazatelj koji nam omogućuje da uzmemo u obzir punu količinu sirovina korištenih za zadovoljavanje razine domaće potrošnje određene zemlje (Wiedmann i sur., 2013).

U ovom istraživanju želio se istražiti odnos vanjske trgovine na stvaranje otpada. Tako varijabla „Uvoz roba i usluga“ negativno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: -0,71 % za miješani komunalni otpad, -0,42 % za otpadni komunalni papir i karton, -1,93 % za otpad od drva i -1,13 % za tekstilni otpad. Iz navedenog je vidljivo da je utjecaj uvoza roba i usluga na stvaranje otpada sasvim suprotan od utjecaja uvoza roba i usluga na materijalni otisak.

Izvoz roba i usluga promatra se kao pokretač gospodarskog i društvenog razvoja iz niza razloga. Poduzeća koja izvoze robu ili usluge kontinuirano trebaju pratiti inovacije na tržištu te raditi na poboljšavanju roba i usluga kako bi zadržali tržište. S druge strane, izvoz osigurava povećanu prodaju i dobit. S obzirom na prednosti izvoza, može se sažeti da povećanje izvoza dovodi do povećanja pristupa valutama, što povećava nacionalni dohodak (Bakari i Mabrouki,

2017), a izvoz će također povećati deviznu zaradu i stvoriti više mogućnosti zapošljavanja na domaćem tržištu (Hosseini i Tang, 2014).

U provedenom istraživanju varijabla „Izvoz roba i usluga“ ima relativni utjecaj od: -1,54 % za miješani komunalni otpad, nema utjecaja (0,00 %) na otpadni komunalni papir i karton, -2,68 % za otpad od drva i 2,12 % za tekstilni otpad. Rezultati upućuju na činjenicu da izvoz negativno utječe na miješani komunalni otpad i otpad od drva. Izvoz nema nikakav utjecaj na nastanak otpada od papira i kartona. Izvoz roba i usluga ima pozitivan utjecaj jedino na tekstilni otpad. S obzirom na to da tekstilna industrija igra važnu ulogu u europskoj prerađivačkoj industriji u kojoj se zapošljava oko 1,7 milijuna ljudi i ostvaruje promet od oko 166 milijardi eura, pozitivan utjecaj izvoza roba i usluga na nastanak tekstilnog otpada ne treba iznenađivati. Tome svakako treba pridodati i činjenicu da je tekstilna industrija EU-a vodeća na svjetskim tržištima (European Commission, 2022). Prema podacima iz 2017. godine, tri najveća svjetska izvoznika tekstila bila su Kina, EU i Indija. Sveukupno, Kina, EU-28 i Indija činile su 66,3 % svjetskog izvoza tekstila (Rahman i sur., 2019).

Globalna ovisnost o nafti, prirodnom plinu i ugljenu, kao i šteta koju ta ovisnost nanosi, dobro je poznata, a cijena nafte važan je gospodarski čimbenik u cijelom svijetu. Cijena nafte i razina inflacije često se smatraju povezanim u uzročno-posljedičnoj vezi. Kako cijena nafte raste, inflacija, kao mjera općega kretanja cijena u cijelom gospodarstvu, ide u istom smjeru. S druge strane, kako cijena nafte pada, inflatorni pritisci počinju popuštati. Nafta i inflacija su povezane jer je nafta glavni *input* u gospodarstvu i koristi se u mnogim aktivnostima kao što su gorivo za transport i grijanje domova. Stoga, ako se povećaju ulazni troškovi, povezano s time, rastu i troškovi krajnjih proizvoda. Naprimjer, ako cijena nafte poraste, porast će i trošak proizvodnje i prijevoza plastike, a tvrtka koja se bavi proizvodnjom plastike dio troškova će biti primorana prenijeti na cijenu završnog proizvoda. Na taj način podizanje cijene stvara inflaciju (Lioudis, 2021). Izvoz nafte i naftnih derivata posebno je važan za države izvoznice s obzirom na to da je eksploatacija velikih količina nafte i plina dovela do neviđenog porasta domaće proizvodnje država izvoznica nafte. Tako je u posljednjim dvama desetljećima omjer iranskih prihoda od izvoza nafte i BDP-a fluktuirao oko 26 % (Esfahani i sur., 2012). Zbog velikog utjecaja nafte na cijelo globalno gospodarstvo, u ovom istraživanju u obzir je uzet i izvoz nafte i naftnih derivata kao još jedan parametar vanjske trgovine koji se koristio za utvrđivanje odnosa u nastanku otpada.

U ovom istraživanju pokazalo se kako izvoz nafte i naftnih derivata pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 2,38 % za miješani komunalni otpad, 2,30 % za otpadni komunalni papir i karton, 4,74 % za otpad od drva i 4,53 % za tekstilni otpad.

Navedeno je u skladu s ranije rečenim da cijena nafte povećava BDP i općenito pozitivno utječe na gospodarstvo, ekonomiju i životni standard države izvoznice, a, prema dobivenim rezultatima, dolazi i do povećanja nastanka otpada.

Kod analiziranja ove teme svakako je važno spomenuti da eksploatacija, izvoz i korištenje fosilnih goriva značajno utječu na globalno zatopljenje. Međutim, znanstvenici smatraju kako ograničavanje izvoza fosilnih goriva neće ubrzati prijelaz na neki od oblika obnovljivih izvora energije (Cimino i Hufbauer, 2014). Također, utvrđeno je da cijena nafte ima značajan utjecaj na obnovljive izvore energije. To je potvrđeno smanjenjem cijena nafte u 2014. te naknadnim smanjenjem potrošnje obnovljivih izvora energije. Stoga se može doći do zaključka kako se s rastom dostupnosti fosilnih goriva, smanjuje korištenje obnovljivih izvora energije. Kako bi se ipak ubrzala zamjena fosilnih goriva za neki oblik obnovljivih izvora energije, treba kao primjer uzeti Dansku i Nizozemsku koje pobijaju ovisnost cijene fosilnih goriva i obnovljivih izvora energije (Eder i sur., 2018).

## **6. Obrazovanje**

Među ostalim socioekonomskim čimbenicima za koja su dosadašnja istraživanja potvrdila utjecaj na stvaranje komunalnog otpada je i obrazovanje (Bandara i sur., 2007; Trang i sur., 2017). Kako bi se provjerila povezanost stvaranja otpada s razinom obrazovanja, u ovom istraživanju korištena su četiri parametra obrazovanja.

Varijabla koja označava osnovnoškolsko i niže srednjoškolsko obrazovanje ima relativni utjecaj od: -2,15 % za miješani komunalni otpad, -1,38 % za otpadni komunalni papir i karton, 0,18 % za otpad od drva i 3,53 % za tekstilni otpad.

Varijabla koja označava srednjoškolsko ili više obrazovanje negativno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: -2,54 % za miješani komunalni otpad, -1,55 % za otpadni komunalni papir i karton, -3,56 % za otpad od drva i -6,55 % za tekstilni otpad.

Varijabla koja obuhvaća sve stanovnike koji imaju završeno srednjoškolsko obrazovanje ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje ima relativni utjecaj od: -2,81 % za miješani komunalni otpad, 0,19 % za otpadni komunalni papir i karton, -4,22 % za otpad od drva i -4,28 % za tekstilni otpad.

Varijabla koja označava visoko obrazovanje ima relativni utjecaj od: -0,02 % za miješani komunalni otpad, -3,50 % za otpadni komunalni papir i karton, 0,35 % za otpad od drva i -5,19 % za tekstilni otpad.

U istraživanju Monavari i sur. (2012) rezultati pokazuju da su prihod i razina obrazovanja najutjecajnije parametri u smanjenju nastanka otpada iz kućanstava. Ujedno navedena dva parametra najviše utječu i na sastav otpada. Analiza otkriva negativnu korelaciju između

proizvodnje organskog otpada, plastike i drva s razinom obrazovanja. Suprotno tome, rezultati pokazuju značajne pozitivne korelacije između razine obrazovanja kućanstva s generiranjem otpadnog papira ( $P < 0,01$ ) (Monavari i sur., 2012). Rezultati dobiveni u ovom doktorskom radu pokazuju negativan utjecaj razine obrazovanja, što je u skladu s istraživanjem Monavari i sur. (2012), uz iznimke za otpad od papira i kartona (varijabla koja obuhvaća sve stanovnike koji imaju završeno srednjoškolsko obrazovanje ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje), otpad od drva (varijabla koja označava najnižu razinu obrazovanja i varijabla koja označava visoko obrazovanje) te za tekstilni otpad (varijabla koja označava najnižu razinu obrazovanja). Slične rezultate dobili su Gui i suradnici koji su utvrdili da razina obrazovanja ima vrlo umjeren negativan utjecaj u stvaranju otpada (Gui i sur., 2019). Ovdje je zanimljivo spomenuti istraživanje provedeno u São Paulu (Brazil). U tom istraživanju visoka korelacija između prihoda i obrazovanja otkriva kako je pristup obrazovanju u Brazilu ograničen приходima. Stoga je obrazovanje povezano s nastankom komunalnog otpada zbog veze između obrazovanja i prihoda (Argentino de Moraes Vieira i Matheus, 2017).

## **7. Turizam**

U stvaranju komunalnoga otpada, osim lokalnog stanovništva, sudjeluju i posjetitelji, odnosno turisti koji se u kontekstu stvaranja komunalnog otpada mogu promatrati kao dodatno stanovništvo. Ako imamo na umu da turist prilikom dolazaka, obilazaka i noćenja svojim aktivnostima proizvodi otpad, može se proporcionalno porastu broja dolazaka i noćenja očekivati i porast količina otpada iz turizma. Zbog navedenog možemo reći da turizam predstavlja dodatni izvor komunalnog otpada (Arbulú, 2015; Grbeš, 2017). Kako bi se proučio utjecaj turizma na količinu nastalog otpada u EU-u, u ovom istraživanju korištena su dva parametra povezana s turizmom: broj dolazaka u turističke smještajne objekte i broj noćenja u turističkim smještajnim objektima.

U istraživanju varijabla „Dolasci u turističke smještajne objekte“ ima relativni utjecaj od: 1,98 % za miješani komunalni otpad, 3,32 % za otpadni komunalni papir i karton, -0,67 % za otpad od drva i 0,93 % za tekstilni otpad. Varijabla koja označava noćenja u turističkim smještajnim objektima pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 0,59 % za miješani komunalni otpad, 1,26 % za otpadni komunalni papir i karton, 0,07 % za otpad od drva i 3,94 % za tekstilni otpad.

Prema dobivenim rezultatima, turizam pozitivno utječe na stvaranje miješanoga komunalnog otpada, otpadnoga komunalnog papira i kartona, otpada od drva i tekstilnog otpada, a rezultati su u skladu s istraživanjima Kumar i sur., 2011; Mateu-Sbert i sur., 2013 i Arbulú i sur., 2015. Jedino kod varijable „Dolasci u turističke smještajne objekte“ kod rezultata za otpad od drva



dolazi do odstupanja u rezultatima istraživanja Kumar i sur., 2011; Mateu-Sbert i sur., 2013 i Arbulú i sur., 2015. Naime, rezultati pokazuju da dolazak u turističke smještajne objekte negativno utječe na otpad od drva.

S obzirom na to da je potvrđeno da turizam pozitivno utječe na stvaranje otpada, bilo bi poželjno u budućnosti poticati i provoditi turizam koji podržava (ili barem ne narušava) okoliš. Primjerice, ekoturizam opisuju aktivnosti koje se provode na održiv način u ruralnim destinacijama. Ekološki prihvatljiv turizam definira se i u smislu turističkih i ugostiteljskih poduzeća koja djeluju na održiv način što uključuje ekološki prihvatljive prakse u hotelima i u drugim smještajnim objektima u kojima se štedi energija i/ili voda, hrana se nabavlja iz malih i lokalnih izvora, vodi se računa o otpadu od hrane, provodi se odvojeno sakupljanje i recikliranje otpada i slično. Nedavne studije pokazuju da su ekološki prihvatljiva praksa hotela i destinacija sve važnije za turiste i stoga se mogu koristiti kao konkurentska prednost. Tako je u 2015. godini jedna trećina europskih građana obratila pozornost da pri odabiru smještaja ili destinacije odaberu onu opciju koja nudi ekološki prihvatljivije mogućnosti. Provođenjem aktivnosti koje turizam čine ekološki prihvatljivim (ili prihvatljivijim) smanjile bi se negativne posljedice koje turizam ima na okoliš. Potrebno je uložiti dodatni napor u edukaciju ljudi kako je važno voditi računa da se prilikom transporta do turističkih destinacija odaberu ekološki prihvatljiviji načini transporta (Falk i Hagsten, 2019).

## **8. Podaci o otpadu**

Varijabla koja označava nastali komunalni otpad pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 4,22 % za miješani komunalni otpad, 4,08 % za otpadni komunalni papir i karton, 3,62 % za otpad od drva i 2,03 % za tekstilni otpad. Varijabla koja označava nastali komunalni otpad po stanovniku pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 2,30 % za miješani komunalni otpad, 3,81 % za otpadni komunalni papir i karton, 1,64 % za otpad od drva i 3,52 % za tekstilni otpad.

Varijabla koja označava nastalu stopu recikliranja komunalnog otpada pozitivno utječe na sve četiri promatrane vrste otpada s relativnim utjecajem od: 0,99 % za miješani komunalni otpad, 4,28 % za otpadni komunalni papir i karton, 0,72 % za otpad od drva i 2,82 % za tekstilni otpad. Varijabla koja označava odlaganje komunalnog otpada ima relativni utjecaj od: 6,58 % za miješani komunalni otpad, 1,10 % za otpadni komunalni papir i karton, -0,04 % za otpad od drva i -1,72 % za tekstilni otpad.

Što se tiče utjecaja pojedinih država na stvaranje otpada, na količinu miješanoga komunalnog otpada najpozitivnije utječe Mađarska (s relativnim utjecajem od 5,98 %), dok najnegativnije utječe Malta (s relativnim utjecajem od -7,65 %). Na količinu papirnog i kartonskog otpada

najpozitivnije utječe ponovno Mađarska (s relativnim utjecajem od 3,57 %), dok najnegativnije ponovno utječe Malta (s relativnim utjecajem od -6,32 %). Na količinu drvnog otpada najpozitivnije utječe Češka (s relativnim utjecajem od 3,00 %), dok najnegativnije i dalje utječe Malta (s relativnim utjecajem od -5,21 %). Na količinu tekstilnog otpada najpozitivnije utječe Irska (s relativnim utjecajem od 5,84 %), dok najnegativniji utjecaj i u ovom slučaju ima Malta (s relativnim utjecajem od -4,59 %).

Iz dobivenih rezultata proizlaze sljedeći zaključci.

- Na količine miješanoga komunalnog otpada, a, povezano s time, na količine biootpada najviše (pozitivno) utječu broj stanovnika i BDP po tržišnim cijenama, količine odloženoga komunalnog otpada i količine nastaloga komunalnog otpada (prikaz u tisućama tona). Gledajući samo primjer Hrvatske, navedeno nije neočekivano s obzirom na to da je odlaganje najčešći način zbrinjavanja miješanoga komunalnog otpada (Ministarstvo gospodarstva i održivog razvoja, 2021).
- Na količine miješanoga komunalnog otpada (povezano s time i na količine biootpada) najnegativnije utječu obrazovanje i ukupne obveze financijskog sektora. S obzirom na to da se u današnje vrijeme posebna pažnja posvećuje obrazovanju i edukaciji, pogotovo mlađih generacija, o važnosti odvojenog sakupljanja i općenito o utjecaju pojedinca na stvaranje otpada, ne čudi da je upravo varijabla „Obrazovanje“ imala najnegativniji utjecaj na stvaranje miješanoga komunalnog otpada.
- Na količine papirnog i kartonskog otpada najviše (pozitivno) utječu BDP po tržišnim cijenama i stope recikliranja komunalnog otpada, zatim količine nastaloga komunalnog otpada i broj stanovnika.
- Na količine papirnog i kartonskog otpada najnegativnije utječe najobrazovaniji dio stanovništva, ukupne obveze financijskog sektora i stopa nezaposlenosti mladih.
- Na količine otpadnog drva najviše (pozitivno) utječu srednji ekvivalent neto prihoda, harmonizirani indeks cijene stambenih objekata i neto vanjski dug.
- Na količine otpadnog drva najnegativnije utječu obrazovne varijable i to najviše najniže obrazovani.
- Na količine tekstilnog otpada najviše (pozitivno) utječe srednji ekvivalent neto prihoda, izvoz nafte i naftnih derivata po zemljama partnerima i noćenja u turističkim smještajnim objektima.
- Na količine tekstilnog otpada najnegativnije utječe životni vijek i varijable obrazovanja (ne računajući najnižu razinu obrazovanja koja pozitivno utječe).

Iz provedenog istraživanja također se može zaključiti da na sve četiri promatrane vrste komunalnog otpada pozitivno utječe:

- broj stanovnika, čime je potvrđena činjenica Kulisza i Kujawske (2020) da je stanovništvo jedan od najvažnijih čimbenika koji utječe na stvaranje otpada.
- BDP po tržišnim cijenama. Navedeno je podudarno s istraživanjem Namlisa i Komilisa (2019) koji su došli do zaključka da je BDP također jedan od najutjecajnijih čimbenika za stvaranje otpada.
- srednji ekvivalent neto prihoda, što je u skladu s istraživanjem Changa i sur., 1993, i Buenrostro i sur., 2001, koji su utvrdili da je prihod još jedan od čimbenika koji također značajno utječe na stvaranje otpada.
- noćenja u turističkim smještajnim objektima. Navedeno je u skladu s istraživanjem Ringér a i sur. (2019) koje pokazuje da se društveno-ekonomski čimbenici, kao što su ukupan broj kućanstava, broj turista i plaće, mogu učinkovito koristiti za predviđanje različitih frakcija otpada (poput papira i kartona, čvrstoga komunalnog otpada i glomaznog otpada).
- stopa recikliranja komunalnog otpada i količine nastalog otpada (kilogram po stanovniku i prikaz u tisućama tona)
- izvoz nafte i naftnih derivata i neto vanjski dug.

Uz navedeno, broj ukupno zaposlenih pokazao se kao utjecajan čimbenik jer pozitivno utječe na tri vrste otpada (na miješani komunalni otpad (povezano s time i na količine biootpada), papir i karton te drveni otpad). Dolasci u turističke smještajne objekte također pozitivno utječu na tri vrste otpada (na miješani komunalni otpad (povezano s time i na količine biootpada), papir i karton te tekstilni otpad). Harmonizirani indeks cijene stambenih objekata također je važan jer ima snažan utjecaj na količine otpada od drva, a uz to pozitivno utječe i na miješani komunalni otpad i papir te karton.

S druge strane, životni vijek, BDP po stanovniku, ukupne obveze financijskog sektora i uvoz roba i usluga negativno utječu na sve četiri vrste komunalnog otpada (miješani komunalni otpad, otpadni papir i karton, drvo i tekstil).

Kada se gleda utjecaj čimbenika na sve četiri promatrane vrste otpada, neki čimbenici (npr. nominalni efektivni tečaj, inozemna izravna ulaganja, godišnji podaci o stopi nezaposlenosti i izvoz roba i usluga) nisu dali jednoznačan odgovor na koji način utječu na stvaranje otpada.

## 5.2. Potvrđivanje postavljenih ciljeva i hipoteza

Stvarna točnost i efikasnost matematičkog modela moći će se utvrditi kada podaci o količinama nastalog otpada u 2020. godini budu dostupni. Do tada se možemo oslanjati na statističke parametre, kao što je koeficijent determinacije čija je vrijednost u ovom modelu za izlazne varijable iznosila: za miješani komunalni otpad 0,999, za papir i karton 0,998, za drvo 0,997 i za tekstil 0,998. S obzirom na to da je vrijednost koeficijenta determinacije bila jako blizu 1, može se reći kako kreiran matematički model pruža jako dobre predikcijske sposobnosti. Time je ujedno ispunjen i prvi cilj ovog istraživanja: izraditi model predviđanja količina komponenti biorazgradivog otpada korištenjem umjetnih neuronskih mreža s ciljem njegove primjene na europskoj i nacionalnoj razini.

Hipoteza koja iz tog cilja proizlazi glasila je kako su umjetne neuronske mreže pouzdan alat kojim se može kreirati matematički model predviđanja količina biorazgradivoga komunalnog otpada na europskoj i nacionalnoj razini. Na temelju vrijednosti koeficijenta determinacije može se zaključiti kako je prva hipoteza potvrđena te da su umjetne neuronske mreže zbilja pouzdan alat kojim se može kreirati matematički model za predviđanje količina miješanoga komunalnog otpada, komunalnog otpadnog papira i kartona, drva i tekstila.

Drugi cilj ovog istraživanja glasilo je: predvidjeti utjecaj sociodemografskih, ekonomskih i industrijskih pokazatelja na količine proizvedenog biorazgradivog otpada primjenom umjetnih neuronskih mreža. Sažeto se može reći da sociodemografski, ekonomski i industrijski pokazatelji kao što su broj stanovnika, BDP po tržišnim cijenama, ukupan broj zaposlenih, srednji ekvivalent neto prihoda, turizam, izvoz nafte i naftnih derivata te neto vanjski dug pozitivno utječu na stvaranje promatranih frakcija biorazgradivog otpada. Životni vijek, realni BDP po stanovniku, ukupne obveze financijskog sektora i uvoz roba i usluga negativno utječu na sve četiri promatrane vrste otpada (miješani komunalni otpad, otpadni papir i karton, drvo i tekstil). S obzirom na to da određeni promatrani parametri (npr. nominalni efektivni tečaj, inozemna izravna ulaganja, godišnja stopa nezaposlenosti, izvoz roba i usluga i odlaganje) nisu pokazali jednoznačan utjecaj na sve četiri promatrane vrste otpada, može se zaključiti kako različiti parametri na drugačiji način utječu na različite vrste otpada. Također, može se reći kako je time druga hipoteza (H2: Točnost predviđanja količina biorazgradivog otpada korištenjem umjetnih neuronskih mreža ovisi o odabiru ulaznih sociodemografskih, ekonomskih i industrijskih pokazatelja) također potvrđena.

Znanstveni doprinos predviđenog istraživanja je kreiranje matematičkog modela kojim će se moći predvidjeti količina nastalog biorazgradivog otpada sa zadovoljavajućom razinom točnosti, a koji će biti lako primjenjiv na razini EU-a i na nacionalnoj razini. Na temelju ranije

spomenutih vrijednosti koeficijenta determinacije može se biti optimističan vezano za ostvarivanje zadanog znanstvenog doprinosa. Matematički model također bi trebao biti primjenjiv i na drugim vrstama otpada.

### **5.3. Ograničenja provedenog istraživanja i prijedlozi za buduća istraživanja**

Iako su obje hipoteze s početka istraživanja potvrđene, provedeno istraživanje ima i svoje nedostatke. Kao što je spomenuto i ranije, upravo je „čekanje“ službenih podataka o otpadu veliko ograničenje ovog istraživanja. Uzevši u obzir da je bila ograničena količina podataka korištena u ovom radu za dobivanje matematičkog modela i da se model pokazao sposobnim postići dovoljno dobre predikcijske rezultate, očekuje se da bi ovaj model mogao biti vrlo koristan u znanstvenoj i stručnoj praksi. Kako bi matematički modeli za predviđanje nastanka otpada bili što kvalitetniji, bilo bi idealno kada bi postojao centralizirani skup podataka o otpadu na što većoj razini, sa što je moguće ranije dostupnim podacima.

Još jedno veliko ograničenje ovog istraživanja je i epidemija uzrokovana koronavirusom (COVID-19) koja će zasigurno utjecati na brojne promjene u socioekonomskim parametrima, pa tako i na području gospodarenja otpadom. To predstavlja problem zato što su podaci za istraživanje sakupljeni od 1995. godine, zaključno s 2019. godinom. Nakon toga napravljen je matematički model koji je na temelju prikupljenih podataka napravio predviđanja za razdoblje od 2020. do 2025. godine, ne uzevši u obzir utjecaj koronakrize na podatke. Zbog toga bi se podaci dobiveni ovim istraživanjima mogli razlikovati od stvarnih podataka za 2020. i 2021. godinu. Stoga bi se buduća istraživanja trebala dodatno poboljšati dodavanjem novih setova podataka tijekom vremena. Dodavanjem novih podataka, unaprijedit i poboljšat će se matematički model te bi razvijen model mogao poboljšati trenutne aktivnosti u sektoru gospodarenja otpadom na europskom i nacionalnom nivou. Također se savjetuju dodatna istraživanja kojima bi se dodatno proučio i razjasnio utjecaj koronakrize na stvaranje otpada.

U ovom istraživanju nije promatran ni utjecaj čimbenika na sastav otpada, iako je i to važno obilježje otpada. Kao i količina, i sastav otpada povezan je s financijskim i s ekonomskim napretkom. Prema dosadašnjim istraživanjima, kako ljudi stječu bogatstvo i kako društvo postaje (tehnološki) razvijenije, odbačeni materijali su složeniji. Iz tih se razloga obilježja otpada uvelike razlikuju među gradovima i regijama (Vergara i Tchobanoglous, 2012). Zbog toga je, kada se analiziraju otpad i gospodarenje otpadom, potrebno, uz količine, voditi računa i o sastavu otpada, iako promatranje sastava otpada zahtijeva drugačiji pristup problemu.

S obzirom na to da je ovo istraživanje definiralo parametre koji pozitivno utječu na stvaranje otpada, kao i one koji negativno utječu na stvaranje promatranih frakcija biorazgradivog otpada, te kako je navedeno u skladu je s istraživanjima drugih autora, predlaže se navedene parametre koristiti za buduća istraživanja. U budućim istraživanjima također se predlaže korištenje parametara kao što su veličina obitelji i prehrambene navike koje bi na temelju do sada provedenih istraživanja trebale imati pozitivnu korelaciju sa stvaranjem otpada (Trang i sur., 2017). Tako su Trang i sur. (2017) u svom istraživanju došli do zaključka da je količina otpada i broj članova kućanstva u pozitivnoj korelaciji (koeficijent = 0,1050312) i da kućanstva s više članova stvaraju više otpada. Rezultati su statistički značajni ( $p < 0,01$ ). Badruddin i sur. (2002) dolaze do zaključka da veličina obitelji, ali i prehrambene navike imaju tendenciju značajno utjecati na količinu nastanka otpada. U njihovom istraživanju rezultati su pokazali da se količina otpada povećava u skladu s veličinom obitelji, ali smanjuje se kako obitelji češće večeraju izvan kuće (objedovanje izvan kuće ima statistički značajan rezultat,  $p = 0,01$ ; Pearsonov koeficijenti korelacije = -0,333). U ovom istraživanju navedeni parametri (veličina obitelji i prehrambene navike) nisu uzeti u obzir.

U budućim istraživanjima predlaže se svakako i dorada matematičkog modela s novijim podacima i s drugim vrstama otpada. Također je uputno buduća istraživanja proširiti na nove, u ovom istraživanju neobuhvaćene države, kao i na druge inovativne ideje koje bi mogle pomoći u rješavanju problema s otpadom. Navedeno svakako moraju pratiti i odgovarajući razvoj infrastrukture i edukacija građana kao ključna točka u prihvaćanju principa održivog gospodarenja otpadom. Edukaciju građana o temi otpada najbolje je započeti još u predškolskom razdoblju i nastaviti kao dio cjeloživotnog obrazovnog sustava. S pravodobnim širenjem informacija i povećavanjem razine edukacije dolazi se do pojedinaca, ali i do cjelokupnog društva koje ima potrebna znanja za donošenje savjesnih i ekološki osviještenih odluka. Na taj način spriječilo bi se neodgovorno postupanje s otpadom te bi se potencijal otpada mogao maksimalno iskoristi, pritom smanjujući negativan utjecaj otpada na prirodu i okoliš.

## 6. ZAKLJUČAK

Iako je otpad prisutan od same pojave čovječanstva, zadnjih godina otpad predstavlja sve važniju temu i sve više zaokuplja znanstvenu i stručnu javnost, donosiocima odluka, medije, političare ali i cijelokupno građanstvo. Tome je tako jer otpad počinje sve više utjecati na naš svakodnevni život, a problemi vezani uz otpad utječu na kvalitetu života. Kako bi se pokrenule pozitivne promjene, ovim radom se želi doprinjeti što boljem razumijevanju ključnih pojmova u sustavu gospodarenja otpadom. Također se želi ponuditi znanstveni doprinos u vidu kreiranja modela za predviđanje količina nastalog otpada koji bi mogao imati praktičnu korist u postizanju učinkovitijeg sustava gospodarenja otpadom. U skladu s navedenim, glavni cilj ovog istraživanja bio je izraditi model predviđanja količina četiriju različitih komponenti biorazgradivoga komunalnog otpada korištenjem umjetnih neuronskih mreža s ciljem njegove primjene na europskoj i nacionalnoj razini. Prema dobivenim rezultatima iz ovog istraživanja, od 2020. do 2025. godine očekuje se da će u 17 država EU-a nastati 411.351.769 tona miješanoga komunalnog otpada, 90.280.031 tonu papira i kartona, 35.926.182 tone otpadnog drva i 3.511.589 tona tekstilnog otpada. S obzirom na to da se radi o milijunima tona otpada koji će nastati u petogodišnjem razdoblju, za navedene vrste otpada (ali i za druge vrste) potrebno je izgraditi i osigurati nužnu infrastrukturu za sakupljanje, obradu, recikliranje i odlaganje. Važno je naglasiti kako će prema kreiranom modelu nastati i oko 81.776.732 tone biootpada koji će biti bačen kao dio miješanoga komunalnog otpada čime se nedovoljno iskorištava veliki potencijal koji biootpad ima. Kako bi se biootpad što bolje iskoristio, potrebno je raditi na tome da se što veće količine biootpada odvoje na mjestu nastanka, a navedene količine iskoriste za proizvodnju komposta ili kao sirovina za anaerobnu digestiju.

Ovim istraživanjem također se želio istražiti utjecaj različitih sociodemografskih, ekonomskih i industrijskih pokazatelja na količine biorazgradivog otpada. Rezultati istraživanja pokazuju da na sve četiri promatrane vrste komunalnog otpada pozitivno utječe broj stanovnika, BDP po tržišnim cijenama, ukupan broj zaposlenih, srednji ekvivalent neto prihoda, turizam, izvoz nafte i naftnih derivata te neto vanjski dug. Time je potvrđena hipoteza da točnost predviđanja količina biorazgradivoga komunalnog otpada ovisi o odabiru ulaznih sociodemografskih, ekonomskih i industrijskih pokazatelja.

Zaključno se može reći da iako je EU heterogena zajednica koju čini 27 različitih država i bez obzira na poteškoće u pronalasku što ažurnijih podataka, kreiran matematički model pokazao je zadovoljavajuća svojstva i mogućnosti u predviđanju količina miješanoga komunalnog otpada (biootpada), otpadnog papira, drva i tekstila. U daljnjem istraživanju teme potrebno je

proširiti istraživanje i nastaviti s inovacijama u sektoru gospodarenja otpadom ako se žele ostvariti ambiciozni ciljevi EU-a da Europa do 2050. postane prvi klimatski neutralan kontinent u svijetu. Kako bi se zadani ciljevi postigli, potrebno je imati jasan koncept te organizirano i dosljedno provoditi zadane ciljeve. Još važnije od ostvarivanja zadanih ciljeva je osigurati generacijama koje dolaze siguran, zdrav i ekološki stabilan život. U skladu sa svime navedenim, razvijen matematički model mogao bi poslužiti kao alat kojim bi se unaprijedilo gospodarenje otpadom tako da organizacija bude točnija, jednostavnija, a, povezano s time, i ekonomičnija te ekološki prihvatljivija. Također bi se ovim modelom osiguralo da se gospodarenje otpadom mijenja paralelno s promjenom društveno-ekonomskih obilježja društva.



## 7. POPIS LITERATURE:

1. Abdi H., Williams L.J. (2010). Principal component analysis. John Wiley & Sons, Inc. 2, 433-459. DOI: 10.1002/wics.101.
2. Agatonovic-Kustrin S., Beresford R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis* 22: 717-727.
3. Ajayi L.B., Oke M.O. (2012). Effect of External Debt on Economic Growth and Development of Nigeria. *International Journal of Business and Social Science* 3 (12), 297-304.
4. Andrijanić I. (2005). *Poslovanje u vanjskoj trgovini*. Mikrorad, Zagreb.
5. Antanasijević D., Pocaajt V., Popović I., Redžić N., Ristić M. (2013). The forecasting of municipal waste generation using artificial neural networks and sustainability indicators. *Sustain Sci* 8: 37-46.
6. Arbulú I., Lozano J., Rey-Maqueira J. (2015). Tourism and solid waste generation in Europe: A panel data assessment of the Environmental Kuznets Curve. *Waste Management* 46: 628-636. <http://dx.doi.org/10.1016/j.wasman.2015.04.014>
7. Argentino de Moraes Vieira V.H., Matheus D.R. (2017). The impact of socioeconomic factors on municipal solid waste generation in São Paulo, Brazil. *Waste Management & Research*, 1–7.
8. Azadi S., Karimi-Jashni A. (2015). Verifying the performance of artificial neural network and multiple linear regression in predicting the mean seasonal municipal solid waste generation rate: A case study of Fars province, Iran. *Waste Management* 48: 14-23.
9. Azarmi.S.L., Oladipo.A.A, Vaziri.R., Alipour.H. (2018). Comparative Modelling and Artificial Neural Network Inspired Prediction of Waste Generation Rates of Hospitality Industry: The Case of North Cyprus. *Sustainability*, 10, 1-18.
10. Badruddin M.Y., Othman F., Hashim N., Cahaya Ali N. (2002). The role of socio-economic and cultural factors in municipal solid waste generation: A case study in Taman Perling, Johor Bahru. *Jurnal Teknologi* 37(F): 55–64.
11. Bakari S., Mabrouki M. (2017). Impact of exports and imports on economic growth: New evidence from Panama. *Journal of smart economic growth* 2(1), 67-79.
12. Bandara N.J.G.J., Hettiaratchi J.P.A., Wirasinghe S.C., Pilapiiya S. (2007). Relation of waste generation and composition to socio-economic factors: a case study. *Environ Monit Assess* 135: 31–39.

13. Barbalace K. (2003). The History of Waste. EnvironmentalChemistry.com. (<https://EnvironmentalChemistry.com/yogj/environmental/wastehistory.html>, 26.4.2021).
14. Barles S. (2014). History of Waste Management and the Social and Cultural Representations of Waste. The Basic Environmental History. Environmental History, vol 4. Springer, Cham. [https://doi.org/10.1007/978-3-319-09180-8\\_7](https://doi.org/10.1007/978-3-319-09180-8_7).
15. Basheer L.A., Hajmeer M. (2000). Artificial neural networks: Fundamentals, computing, design and application. Journal of Microbiological Methods 43: 3-31.
16. Beigl P., Lebersorger S., Salhofer S. (2008). Modelling municipal solid waste generation: A review. Waste Management 28: 200–214.
17. Beigl P., Wassermann G., Schneider F., Salhofer S. (2004). Forecasting Municipal Solid Waste Generation in Major European Cities. In ; Pahl-Wostl.C., Schmidt.S., Jakeman.T. iEMSs 2004 International Congress: Complexity and Integrated Resources Management. Osnabrueck, Germany.
18. Berger F., Gauvin F., Brouwers H.J.H. (2020). The recycling potential of wood waste into wood-wool/cement composite. Construction and Building Materials 260. DOI: <https://doi.org/10.1016/j.conbuildmat.2020.119786>
19. Bide T., Brown T., Evans E., Idoine N., Petavratzi E., Mancini L., Vidal-Legaz B. (2019). Optimizing quality of information in RAw MAterial data collection across Europe. Deliverable 1.3 Report on the datasets available relating to social and environmental dimensions of extraction. [https://www.researchgate.net/figure/The-waste-hierarchy-as-described-in-the-EU-Waste-Framework-Directive-14\\_fig3\\_339796148](https://www.researchgate.net/figure/The-waste-hierarchy-as-described-in-the-EU-Waste-Framework-Directive-14_fig3_339796148), 17.11.2021
20. Bidlingmaier W., Sidaine J-M., Papadimitriou E.K. (2004). Separate collection and biological waste treatment in the European Community. Reviews in Environmental Science & Bio/Technology 3: 307–320.
21. Bilas V., Franc S. (2006). Uloga inozemnih izravnih ulaganja i načini poticaja. EFZG – Serija članaka u nastajanju, Članak broj 06-13. Sveučilište u Zagrebu, Ekonomski fakultet, Zagreb.
22. Blumenthal K. (2011). Generation and treatment of municipal waste. Environment and energy: 1-12. Eurostat Statistics in focus 31/2011 (<https://op.europa.eu/en/publication-detail/-/publication/bd8a43dc-8076-4134-987d-c3081c8311e8> online data code: env\_wasmun, 23.3.2021)
23. Bolf N., Kopčić N., Briški F., Gomzi Z. (2007). Software Sensors for Monitoring of a Solid Waste Composting Process. Chemical Papers 61, 98-102.

24. Bolfek B., Knežević S. (2011). Međunarodna ekonomija, Veleučilište u Slavonskom Brodu, Slavonski Brod.
25. Brunner H.P., Fellner J. (2007). Setting Priorities for Waste Management in Developing Countries. *Waste Management & Research* 25: 234-240.
26. Buenrostro O., Bocco G., Vence J. (2001). Forecasting Generation of Urban Solid Waste in Developing Countries - A Case Study of Mexico. *Journal of Air & Waste Management Association* 51: 86-93.
27. Bunsan S., Chen W-Y., Chen H-W., Chuang Y.H., Gridanurak N. (2013). Modeling the dioxin emission of a municipal solid waste incinerator using neural networks. *Chemosphere* 92: 258-264.
28. Carter Ingram J., Dawson T.P., Whittaker R.J. (2005). Mapping tropical forest structure in southeastern Madagascar using remote sensing and artificial neural networks. *Remote Sensing of Environment* 94, 491 – 507.
29. Castillo-Giménez J., Montañés A., Picazo-Tadeo A.J. (2019). Performance in the treatment of municipal waste: Are European Union member states so different? *Science of the Total Environment* 687: 1305-1314.
30. Chang N-B., Pan Y.C., Huang S. (1993). Time Series Forecasting of Solid Waste Generation. *Journal of Resource Management and Technology* 21(1): 1-10.
31. Changqing D., Baosheng J., Daji L. (2003). Predicting the heating value of MSW with a feed forward neural network. *Waste Management* 23, 103-106.
32. Charambous, C. (1992). Conjugate gradient algorithm for efficient training of artificial neural networks, *IEEE Proceedings*, 139, 301-310.
33. Cho S., Lim B., Jung J., Kim S., Chae H., Park J., Park S., Park J.K. (2014). Factors affecting algal blooms in a man-made lake and prediction using an artificial neural network. *Measurement* 53, 224-233.
34. Commission of the European Communities (2008). Green paper on the management of bio-waste in the European Union, Brussels. <https://op.europa.eu/en/publication-detail/-/publication/b2341160-6612-4d97-a147-93308c9c8f5e/language-en>, 15.11.2021
35. Dalbelo Bašić B., Čupić M., Šnajder J. (2008). Umjetne neuronske mreže. Umjetna inteligencija, Zavod za elektorniku, mikroelektroniku i inteligentne sustave, Fakultet elektrotehnike i računarstva. Zagreb.
36. Davies B., Doble M. (2004). The development and implementation of a landfill tax in the UK, in OECD. Addressing the Economics of Waste, Paris, OECD.

37. Demuth H., Beale M. (1992). Neural Network Toolbox: For use with Matlab, The MathWorks, Inc., Natick, MA, USA.
38. Dev Sharma K., Jain S. (2020). Municipal solid waste generation, composition, and management: the global scenario. Social responsibility journal 16 (6), 917-948.
39. Direktiva 2008/98/EZ Europskog Parlamenta i Vijeća od 19. studenoga 2008. o otpadu i stavljanju izvan snage određenih direktiva (<https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32008L0098&from=HR>, 30.4.2021).
40. Direktiva (EU) 2018/851 Europskog parlamenta i vijeća od 30. svibnja 2018. o izmjeni Direktive 2008/98/EZ o otpadu (<https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32018L0851&from=EN>, 14.4.2021)
41. Direktiva vijeća 1999/31/EZ od 26. travnja 1999. o odlagalištima otpada, <https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:31999L0031&from=HR>
42. Dobilaitė V., Jucienė M., Sacevičienė V. (2017). Study of Textile Waste Generation and Treatment in Lithuania. Fibres&textiles in Eastern Europe 25, 6(126): 8-13. DOI: 10.5604/01.3001.0010.5360
43. Domijan D. (2000). Uvod u neuronske mreže. Metodčki ogleđi 7, 1-2, 101-127.
44. Dong C., Jin B., Li D. (2003). Predicting the heating value of MSW with a feed forward neural network. Waste Management 23, 103-106.
45. Drmić A. (2012.). Načela gospodarenja otpadom i njihovo značenje. Upravljanje okolišnim problemima HKJU – CCPA3, 861–877.
46. Državni zavod za statistiku Republike Hrvatske. Popis '21. Prvi rezultati popisa 2021. <https://popis2021.hr/>, 5.2.2022.
47. Državni zavod za statistiku Republike Hrvatske. Statistički ljetopis 2018, Obrazovanje. Zagreb, prosinac 2018.
48. Dubois M., Sims E., Moerman T., Watson D., Bauer B., Bel J-B., Mehlhart G. (2020). Guidance for separate collection of municipal waste. European Commission, Publications Office. <https://data.europa.eu/doi/10.2779/691513>, 10.1.2022.
49. Dumantić S. (2014). Neuronske mreže. Sveučilište Josipa Jurja Strossmayera U Osijeku, Odjel za fiziku. Diplomski rad.
50. Dyson B., Chang N-B. (2005). Forecasting municipal solid waste generation in a fast-growing urban region with system dynamics modeling. Waste management 25, 669-679.
51. Eder L.V., Provornaya I.V., Filimonova I.V., Kozhevnikov V.D., Komarova A.V. (2012). World energy market in the conditions of low oil prices, the role of renewable energy sources. Energy Procedia 153, 112–117.

52. Energetika-net. (18.09.2013). Koji su vodeći europski proizvođači nafte?. <http://www.energetika-net.com/vijesti/energetsko-gospodarstvo/koji-su-vodeci-europski-proizvodaci-nafte-17513>, 27.9.2021.
53. Esfahani H.S., Mohaddes K., Pesaranc M.H. (2012). Oil exports and the Iranian economy. The Quarterly Review of Economics and Finance, 1-17.
54. European Commission. Textiles and clothing industries. [https://ec.europa.eu/growth/sectors/fashion/textiles-and-clothing-industries\\_en](https://ec.europa.eu/growth/sectors/fashion/textiles-and-clothing-industries_en), 16.2.2022.
55. European Environment Agency. (2020). Bio-waste in Europe – turning challenges into opportunities. EEA Report. Publications Office of the European Union.
56. European Parliament. (2017). Towards a circular economy - Waste management in the EU. Scientific Foresight Unit.
57. Europska središnja banka. (2021). Što je inflacija? <https://www.ecb.europa.eu/ecb/educational/hicp/html/index.hr.html>, 8.12.2021.
58. Eurostat (2010). Guidance on classification of waste according to EWC-Stat categories, Supplement to the Manual for the Implementation of the Regulation (EC) No 2150/2002 on Waste Statistics. Version 2. <https://ec.europa.eu/eurostat/documents/342366/351806/Guidance-on-EWCStat-categories-2010.pdf/0e7cd3fc-c05c-47a7-818f-1c2421e55604>, 15.11.2021.
59. Eurostat. (2013). Glossary:Municipal waste. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Glossary:Municipal\\_waste](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Glossary:Municipal_waste), 16.9.2021.
60. Eurostat. (2020a). 492 kg of municipal waste generated per person in the EU. <https://ec.europa.eu/eurostat/web/products-eurostat-news/-/ddn-20200318-1>, 24.5.2021.
61. Eurostat. (2020b). International Standard Classification of Education (ISCED). Page was last edited on 3 September 2020. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=International\\_Standard\\_Classification\\_of\\_Education\\_\(ISCED\)](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=International_Standard_Classification_of_Education_(ISCED)), 23.9.2021)
62. Eurostat. (2020c). Ageing Europe. Looking at the lives of older people in the EU. Publications Office of the European Union, 2020. 2020 edition. <https://ec.europa.eu/eurostat/documents/3217494/11478057/KS-02-20-655-EN-N.pdf/9b09606c-d4e8-4c33-63d2-3b20d5c19c91>, 21.9.2021.
63. Eurostat (2020d). Tourism in the EU - what a normal spring season looks like - before Covid-19. Page was last edited on 13 May 2020. <https://ec.europa.eu/eurostat/statistics->

- [explained/index.php?title=Tourism in the EU - what a normal spring season looks like - before Covid-19&stable=1#Europeans spend more than 1.5 billion overnights in the EU](#), 2.2.2022.
64. Eurostat. (2021a). Direct investment in the reporting economy. (<https://ec.europa.eu/eurostat/databrowser/view/tipsbp90/default/table?lang=en>, 24.9.2021)
  65. Eurostat. (2021b). House price index, deflated - annual data. <https://ec.europa.eu/eurostat/databrowser/view/tipsho10/default/table?lang=en>, 27.9.2021
  66. Eurostat. (2021c). Half a tonne of municipal waste generated per person in the EU. <https://ec.europa.eu/eurostat/en/web/products-eurostat-news/-/ddn-20210216-1>, 24.5.2021.
  67. Eurostat. (2021d). Municipal waste statistics. [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Municipal\\_waste\\_statistics#Municipal\\_waste\\_generation](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Municipal_waste_statistics#Municipal_waste_generation), 24.5.2021.
  68. Eurostat. (2021e). Net external debt - annual data, % of GDP. <https://ec.europa.eu/eurostat/databrowser/view/tipsii20/default/table?lang=en>, 24.9.2021.
  69. Eurostat. (2021f). Municipal waste by waste management operations. [https://ec.europa.eu/eurostat/databrowser/view/env\\_wasmun/default/table?lang=en](https://ec.europa.eu/eurostat/databrowser/view/env_wasmun/default/table?lang=en), 17.11.2021
  70. Eurostat. (2021g). [Statistički podaci u području turizma](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Archive:Statisti%C4%8Dki_podaci_u_podru%C4%8Dju_turizma&oldid=388857). [https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Archive:Statisti%C4%8Dki\\_podaci\\_u\\_podru%C4%8Dju\\_turizma&oldid=388857](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Archive:Statisti%C4%8Dki_podaci_u_podru%C4%8Dju_turizma&oldid=388857), 2.2.2022.
  71. [Falk M., Hagsten E. \(2019\). Ways of the green tourist in Europe. Journal of Cleaner Production 225, 1033-1043.](#)
  72. Faraca G., Boldrin A., Astrup T. (2019). Resource quality of wood waste: The importance of physical and chemical impurities in wood waste for recycling. Waste Management 87, 135-147.
  73. Foday P.S., Xiangbin Y., Alhaji M.H.C. (2012). A Situational Assessment of Socioeconomic Factors Affecting Solid Waste Generation and Composition in Freetown, Sierra Leone. J Environ Prot 3, 563-568.

74. García A.J., Esteban M.B., Ma´rquez M.C., Ramos P. (2005.). Biodegradable municipal solid waste: Characterization and potential use as animal feedstuffs. *Waste Management* 25, 780–787.
75. Gharfalkar M., Court R., Campbell C., Ali Z., Hillier G. (2015). Analysis of waste hierarchy in the European waste directive 2008/98/EC. *Waste Management* 39, 305-313.
76. Ghazi Zade M.J., Noori R. (2008). Prediction of Municipal Solid Waste Generation by Use of Artificial Neural Network: A Case Study of Mashhad. *International Journal of Environmental Research* 2(1), 13-22.
77. Ghinea C., Drăgoi E.N., Comănită E-D., Gavrilesco M., Câmpean T., Curteanu S., Gavrilesco M. (2016). Forecasting municipal solid waste generation using prognostic tools and regression analysis. *Journal of Environmental management* 182, 80-93.
78. Grdović Gnip A. (2009). Analiza hrvstake robne razmjene. *Economic research - Ekonomska istraživanja* 22 (1), 98-113.
79. Grebeš A. (2017). Odabir varijabli za stvaranje modela obrade krutoga otpada u gradovima i naseljima Hrvatske. *Rudarsko-geološko-naftni zbornik* 32(3), 55-69. <https://doi.org/10.17794/rgn.2017.3.6>
80. Grieu S., Faugeroux O., Traoré A., Claudet B., Bodnar J.L. (2011). Artificial intelligence tools and inverse methods for estimating the thermal diffusivity of building materials. *Energy and Buildings* 43, 543-554.
81. Gui S., Zhao L., Zhang Z (2019). Does municipal solid waste generation in China support the Environmental Kuznets Curve? New evidence from spatial linkage analysis. *Waste Management* 84, 310-319.
82. Haberl H., Fischer-Kowalski M., Krausmann F., Winiwarter V. (2016). *Social Ecology: Society-Nature Relations across Time and Space*. Springer.
83. Hall D., Nguyen T.A.J. (2012). *Waste management in Europe: Companies, structure and employment*. Public Services International Research Unit (PSIRU).
84. Hamed M.M, Khalafallah M.G, Hassanien E.A. (2004). Prediction of wastewater treatment plant performance using artificial neural network. *Environmental Modelling & Software* 19, 919- 928.
85. Hargreaves J.C., Adl M.S., Warman P.R. (2008). A review of use of composted municipal solid waste in agriculture. *Agriculture, Ecosystems and Environment* 123, 1-14.
86. Haug T.R. (1993.). *The Practical Handbook of Compost Engineering*. Lewis Publishers, United States of America. DOI: <https://doi.org/10.1201/9780203736234>.

87. Heidari E., Sobati M.A., Movahedira S. (2016). Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN). *Chemometrics and Intelligent Laboratory System*. doi:10.1016/j.chemolab.2016.03.03.
88. Helmer J. (2021). Can Dynamic Pricing Reduce Food Waste in Supermarkets? *Food Print*. <https://foodprint.org/blog/food-waste-management/>, 30.11.2021.
89. HNB. (2016). Inozemna izravna ulaganja. <https://www.hnb.hr/statistika/statisticki-podaci/sektor-inozemstva/inozemna-izravna-ulaganja>, 9.2.2022.
90. Hosseinia S.M.P., Tang C.F. (2014). The effects of oil and non-oil exports on economic growth: a case study of the Iranian economy. *Economic Research - Ekonomska Istraživanja* 27 (1) , 427–441.
91. Hrnjak-Murgić Z. (2016). *Gospodarenje polimernim otpadom*. Sveučilište u Zagrebu, Fakultet kemijskog inženjstva 8-117.
92. Hrvatska agencija za okoliš i prirodu. (2018). *Unaprjeđenje sustava za prikupljanje podataka o biootpadu i otpadu od hrane*. Zagreb
93. Hultman J., Corvellec H. (2012.). The European Waste Hierarchy: from the sociomateriality of waste to a politics of consumption. *Environment and Planning* 44, 2413-2427.
94. Ivić K., Jurković Z., Marinković R. (2012). Izrada modela neuronskih mreža za učestalost korištenja fakultetske knjižnice. *Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues* XXV (1), 106-116.
95. Jahandideh S., Jahandideh S., Barzegari Asadabadi E., Askarian M., Movahedi M.M., Hosseini S., Jahandideh M. (2009). The use of artificial neural networks and multiple linear regression to predict rate of medical waste generation. *Waste Management* 29, 2874-2879.
96. Jurišić M., Babić D., Škobić H. (2019.). Ekološka sijest u gospodarenju otpadom na području grada Mostara. *Zdravstveni glasnik*, 5 (1), 67-77.
97. Kalambura S, Krička T., Kalambura D. (2011.). *Gospodarenje otpadom*. Velika Gorica, Veleučilište Velika Gorica.
98. Kalawapudi K., Dube O., Sharma R. (2020), Use of neural networks and spatial interpolation to predict groundwater quality. *Environment, Development and Sustainability* 22, 2801–2816.
99. Karaca F., Özkaya B. (2006). NN-LEAP: A neural network-based model for controlling leachate flow-rate in municipal solid waste landfill site. *Environmental Modelling & Software*, 21, 1190-1197.



100. Karak T., Bhagat R.M., Bhattacharyya P. (2012). Municipal Solid Waste Generation, Composition, and Management: The World Scenario. *Critical Reviews in Environmental Science and Technology* 42,1509–1630. DOI: 10.1080/10643389.2011.569871
101. Karlović S., Bosiljkov T., Brnčić M., Ježek D., Tripalo B., Dujmić F., Džineva I., Skupnjak A. (2013). Comparison of Artificial Neural Network and Mathematical Models for Drying of Apple Slices Pretreated with High Intensity Ultrasound. *Bulgarian Journal of Agricultural Science* 19, 1372-1377.
102. Kerner A. (2014). What We Talk About When We Talk About Foreign Direct Investment. *International Studies Quarterly* 58, 804–815.
103. Keser S., Duzgun S., Aksoy A. (2012). Application of spatial and non-spatial data analysis in determination of the factor that impact municipal solid waste generation rates in Turkey. *Waste Management* 32, 359-371.
104. Kim C.K, Kwak I.S, Cha E.Y, Chon T.S. (2006). Implementation of wavelets and artificial networks to detection of toxic response behavior of chironomids (Chironomidae: Diptera) for water quality monitoring. *Ecological Modelling* 195, 61-67.
105. Kollo T., von Rosen D. (2005). *Advanced Multivariate Statistics with Matrices*. Springer, Dordrecht.
106. Koški D. (2009). Utjecaj promjene deviznog tečaja na bilancu roba Republike Hrvatske: ekonometrijska analiza. *Ekonomski pregled* 60(3-4), 152-167.
107. Kovačević M., Ivanišević N., Dašić T., Marković Lj. (2018). Primjena neuronskih mreža za hidrološko modeliranje u krškom području. *Građevinar* 70(1), 1-10.
108. Kulisz M., Kujawska J. (2020). Predicting of Municipal Waste Generation in Poland Using Neural Network Modeling. *Sustainability* 12, 1-16.
109. Kumar J.S., Venkata Subbaiah K., Prasada Rao.P.V.V. (2011). Prediction of Municipal Solid Waste with RBF NetWork- A Case Study of Eluru, A.P, India. *International Journal of Innovation, Management and Technology* 2 (3), 238-243.
110. Kusch S., Hills C.D. (2017). The Link between e-Waste and GDP—New Insights from Data from the Pan-European Region. *Resources* 6 (2), 15. DOI:10.3390/resources6020015.
111. Le Page M. (2021). “Make or break” is hardly hyperbole for the climate negotiations due to reach their climax in November in Glasgow, UK. At the COP26 meeting, nations will have a last chance to really rev up the stuttering motor of climate action and come good on commitments made in Paris in 2015 to limit global warming to a “safe” level of 1.5°C. *New Scientist* 250 (3331), 34-37, 42-45.

112. Levine R. Finance and Growth: Theory and Evidence. U. Aghion P., Durlauf S. (2005). Handbook of Economic Growth vol 1. North Holland, Amsterdam, 866-910.
113. Lioudis N. (2021). What Is the Relationship Between Oil Prices and Inflation? Investopedia. <https://www.investopedia.com/ask/answers/06/oilpricesinflation.asp>, 8.12.20201.
114. Marković Z. (2007). Jedan pristup normalizaciji matrice podataka u višekriterijumskoj analizi. XXV Simpozijum o novim tehnologijama u poštanskom i telekomunikacionom saobraćaju - PosTel 2007, Beograd, 11. i 12. decembar 2007.
115. Mateu-Sbert J., Ricci-Cabello I., Villalonga-Olives E., Cabeza-Irigoyen E. (2013). The impact of tourism on municipal solid waste generation: The case of Menorca Island (Spain). Waste Management 33, 2589-2593.
116. Mazzanti M., Montini A., Nicolli F. (2012). Waste dynamics in economic and policy transitions: decoupling, convergence and spatial effects. J. Environ. Plann. Manage 55, 563-581.
117. McCulloch W.S., Pitts W. (1943). A local calculus of the ideas imminent in nervous activity. Bull. Math. Biophy 5, 115-133.
118. Medina M. (1997). Effect of income on municipal solid waste generation rates for countries of varying levels of economic development: a model J. Solid Waste Technol. Manage 24, 149-155.
119. Melesse A.M., Ahmad S., McClain M.E., Wang X., Lim Y.H. (2011). Suspended sediment load prediction of river systems: An artificial neural network approach. Agricultural Water Management 98, 855-866.
120. Ministarstvo gospodarstva i održivog razvoja (2020). Izvešće o komunalnom otpadu za 2019. godinu. Zagreb.
121. Ministarstvo gospodarstva i održivog razvoja (2021). Izvešće o komunalnom otpadu za 2020. godinu. Zagreb.
122. Minsky M.L., Papert S.A. (1969). Perceptions, An Introduction to Computational Geometry. M.I.T. Press, Cambridge.
123. Monavari S.M., Ali Omrani G., Karbassi A., Fakheri Raof F. (2012). The effects of socioeconomic parameters on household solid-waste generation and composition in developing countries (a case study: Ahvaz, Iran). Environ Monit Assess 184:1841–1846. DOI 10.1007/s10661-011-2082-y
124. Montaño J.J., Palmer A. (2003). Numeric sensitivity analysis applied to feedforward neural networks. Neural Computing & Applications 12, 119-125.

125. Moustris K.P., Ziomas I.C., Paliatsos A.G. (2010). 3-Day-Ahead Forecasting of Regional Pollution Indeks for the Pollutants NO<sub>2</sub>, CO, SO<sub>2</sub>, and O<sub>3</sub> Using Artificial Neural Networks in Athens, Greece. *Water, Air & Soil Pollution* 209, 29-43.
126. Namlis K-G., Komilis D. (2019). Influence of four socioeconomic indices and the impact of economic. *Waste Management* 89, 190-200.
127. Noori R., Abdoli M.A., Jalili Ghazizade M., Samiefard R. (2009). Comparasion of Neural Network and Principal Component Regression Analysis to Predict the Solid Waste Generation in Tehran. *Iranian Journal of Public Health* 38(1), 74-84.
128. Noori R., Karbassi A., Sabahi M.S. (2010). Evaluation of PCA and Gamma test techniques on ANN operation for weekly solid waste prediction. *J Environ Manage* 91:767–771.
129. Ogwueleka T.C. (2013). Survey of household waste composition and quantities in Abuja, Nigeria. *Resour conserve recy* 77, 52–60.
130. Omanović A., Išerić H., Jonuz-Silajdžić Z., Hodžić L. (2020). Determinante očekivanog životnog vijeka u zemljama Europske unije. *Western Balkans Youth Conference: Regional Cooperation and Integration*, 93-117.
131. Omerdić N. (2020). Anaerobnom digestijom do visokovrijednog organskog gnojiva. *Hrvatske vode* 28 (111), 43-50.
132. Passarini F., Vassura I., Monti F., Morselli L., Villani B. (2011). Indicators of waste management efficiency related to different territorial conditions. *Waste Management* 31, 785-792.
133. Peixeiro M. (2019). Step-by-step Guide to Building Your Own Neural Network From Scratch. <https://towardsdatascience.com/step-by-step-guide-to-building-your-own-neural-network-from-scratch-df64b1c5ab6e>, 18.11.2021.
134. Peters T., Iberg R. (1978). Mineralogical changes during firing of calcium-rich brick clays, *Ceramic Bulletin* 57, 503-509.
135. Petrić D., Vusić D., Geček R. (2012). Kartoni: od proizvodnje do konačne primjene. *Tehnički glasnik* 6(2), 219-227.
136. Petrović M. (2011). Osnovi veštačkih neuronskih mreža i značaj njihove primene, *Zbornik radova* 20, 47-55.
137. Pezo L., Ćurčić B.Lj., Filipović V.S., Nićetin M.R., Koprivica G.B., Mišljenović N.M., Lević Lj.B. (2013). Artificial neural network model of pork meat cubes osmotic dehydration. *Hemijaska industrija* 67 (3), 465-475.

138. Pires A., Martinho G. (2019). Waste hierarchy index for circular economy in waste management. *Waste Management* 95, 298-305.
139. Pravilnik o katalogu otpada, NN 90/2015 ([https://narodne-novine.nn.hr/clanci/sluzbeni/2015\\_08\\_90\\_1757.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2015_08_90_1757.html), 14.4.2021.)
140. Prvonožec S. (2020). Utjecaj plaća na tržište rada u Republici Hrvatskoj. *Oeconomica Jadertina*, 115-126.
141. Puntarić D., Capak K. (2012). *Gospodarenje otpadom i zdravlje u: Puntarić D., Miškulin M., Bošnjir J. i sur. Zdravstvena ekologija. Medicinska naklada, Zagreb.*
142. Purcell M., Magette W.L. (2009). Prediction of household and commercial BMW generation according to socio-economic and other factors for the Dublin region. *Waste Management* 29, 1237-1250.
143. Purcell M., Magette W.L. (2011). Targeted intervention strategies to optimise diversion of BMW in the Dublin, Ireland region 31, 2180-2189.
144. Rahman R., Shahriar S., Kea S. (2019). Determinants of Exports: A Gravity Model Analysis of the Bangladeshi Textile and Clothing Industries. *FIIB Business Review* 8 (3), 229-244.
145. Ralašić M. Javni ili državni dug. *Financijska praksa* 17 (4), 381-383. [http://www.ijf.hr/pojmovnik/javni\\_dug.htm](http://www.ijf.hr/pojmovnik/javni_dug.htm), 30.11.2021.
146. Ribić B., Pezo L., Sinčić D., Lončar B., Voća N. (2019). Predictive model for municipal waste generation using artificial neural networks – Case study City of Zagreb, Croatia. *International journal of energy research* 43, 5701-5713.
147. Ringér M. (2008). What is principal component analysis? *Nature biotechnology* 26 (3), 303-304.
148. Rumelhart D.E., McClelland J.L. (1986). *Parallel Distributed Processing, volume 1: Explorations in the Microstructures of Cognition.* MIT Press, Cambridge.
149. Rumelhart D.E, Hinton G.E., Williams R.J. (1985). *Learning Internal Representations by Error Propagation.* Institute for cognitive science, University of California, San Diego. ICS Report 8506
150. Sabarinah M. (1997). *The Effect of Socio-economy on Municipal Solid Waste Generation: State of Johor. A Master Thesis.* Universiti Teknologi Malaysia.
151. Shamsiry E., Bin Mokhtar M., Abdulai A-M. (2014). Comparison of Artificial Neural Network (ANN) and Multiple Regression Analysis for Predicting the Amount of Solid Waste Generation in a Tourist and Tropical Area – Langkawi Island. *International*

- Conferece on Biological, Civil and Environmental Engineering (BCEE-2014) March 17-18, 2014 Dubai
152. Sofilić T. (2015). Priručnik za polaznike - "Izobrazbe o gospodarenju otpadom". Zagreb Metroalfa edukacija.
  153. Sokka L., Antikainen R., Kauppi P.E. (2007). Municipal solid waste production and composition in Finland—Changes in the period 1960–2002 and prospects until 2020. *Resources, Conservation and Recycling* 50, 475–488.
  154. Sujaudhin M., Huda S.M.S., Rafiqul Hoque A.T.M. (2008). Household solid waste characteristics and management in Chittagong, Bangladesh. *Waste management* 28 (9), 1688-95.
  155. Ujević Andrijić Ž. (2019). Umjetne neuronske mreže. *Osvježimo znanje* 68 (5-6), 2019-220.
  156. Uredba komisije (EU) br. 1357/2014 od 18. prosinca 2014. o zamjeni Priloga III. Direktivi 2008/98/EZ Europskog parlamenta i Vijeća o otpadu i stavljaju izvan snage određenih direktiva. <https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32014R1357&from=HR>, 15.4.2021
  157. Uredba (EZ) br. 2150/2002 Europskog Parlamenta i Vijeća od 25. studenog 2002. o statističkim podacima o otpadu. <https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32002R2150&from=HR>, 17.11.2021.
  158. Taylor B.J. (2006). *Methods and Procedures for the Verification and Validation of Artificial Neural Networks*, Springer Science, Business Media, Inc., USA
  159. Themelis N.J. (2021). Divert Biodegradable Waste From Landfills to Cut Climate-Warming Methane Emissions. *Columbia News*. <https://news.columbia.edu/news/divert-biodegradable-waste-methane>, 10.2.2022.
  160. Trang P.T.T., Dong H.Q., Toan D.Q., Hanh N.T.X., Thu N.T. (2017). The effects of socio-economic factors on household solid waste generation and composition A case study in Thu Dau Mot, Vietnam. *Energy Procedia* 107, 253–258.
  161. Trelea I.C., Raoult-Wack A.L., Trzstram G. (1997). Application of neural network modeling for the control of dewatering and impregnation soaking process (osmotic dehydration), *Food Science and Technology International* 3, 459-465.
  162. Tschegg C., Ntaflos T. Hein I. (2009). Thermally triggered two-stage reaction of carbonats and clay during ceramic firing- A case study on Bronye Age Cypriot ceramics, *Applied Clay Science* 43, 69-78.

163. Tun M.M., Juchelková D., Raclavská H., Sassmanová V. (2018). Utilization of Biodegradable Wastes as a Clean Energy Source in the Developing Countries: A Case Study in Myanmar. *Energies* 11, 3183. DOI:10.3390/en11113183
164. Vergara S.E., Tchobanoglous G. (2012.). Municipal Solid Waste and the Environment: A Global Perspective. *Annu. Rev. Environ. Resour* 37, 277–309.
165. Villanueva A., Wenzel H. (2007). Paper waste – Recycling, incineration or landfilling? A review of existing life cycle assessments. *Waste Management* 27, 29–46.
166. Vlada Republike Hrvatske, Odluka o donošenju Plana gospodarenja otpadom Republike Hrvatske za razdoblje 2017. - 2022. godine, NN 3/17 ([https://narodne-novine.nn.hr/clanci/sluzbeni/2017\\_01\\_3\\_120.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2017_01_3_120.html), 7.11.2021)
167. Voća N., Krička T., Ćosić T., Rupiće V., Jukić Ž., Kalambura S. (2004). Kakvoća digestiranog ostatka nakon anaerobne digestije pilećeg gnoja. *Krmiva* 47(2), 65-72.
168. Wei Y., Li J., Shi D., Liua G., Zhao Y., Shimaoka T. (2017). Environmental challenges impeding the composting of biodegradable municipal solid waste: A critical review. *Resources, Conservation and Recycling* 122, 51-65.
169. Werbos P. (1974). Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. dissertation, Committee on Appl. Math., Harvard Univ., Cambridge, MA.
170. Wiedmann T.O., Schandl H., Lenzen M., Moran D., Suh S., West J., Kanemoto K. (2013). The material footprint of nations. *PNAS Early Edition*, 1-6. <https://doi.org/10.1073/pnas.1220362110>
171. Wilson D.G. (1976). A brief history of solid-waste management. *International Journal of Environmental Studies* 9, 123-129.
172. Winkler A. (2009). Southeastern Europe Financial Deepening, Foreign Banks and Sudden Stops in Capital Flows. *Focus on European Economic Integration* 1, 84-97.
173. Wu F., Niu D., Dai S., Wu B. (2020). New insights into regional differences of the predictions of municipal solid waste generation rates using artificial neural networks. *Waste Management* 107, 182-190.
174. Yusoff.S.H., Abdullah Din.U.N.K., Mansor.H., Midi. N.S., Syasya.A.Z. (2018). Neural Network Prediction for Efficient Waste Management in Malaysia. *Indonesian Journal of Engineering and Computer Science*, 12(2), 738-747
175. Zakon o gospodarenju otpadom NN 84/21. [https://narodne-novine.nn.hr/clanci/sluzbeni/2021\\_07\\_84\\_1554.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2021_07_84_1554.html), 25.8.2021.

176. Zupan J. (1994). Introduction to Artificial Neural Network (ANN) Methods: What They Are and How to Use Them. *Acta Chimica Slovenica* 41/3, 327-352.
177. Žalac N. (1997). Neuronske mreže i poslovna prognostika. *Poslovna analiza i upravljanje* 1 (11-12), 39-45.

## 178. ŽIVOTOPIS

Eda Puntarić rođena je 26. studenoga 1990. godine u Zagrebu. Živi u Graberju Ivaničkom, nedaleko Ivanić-Grada gdje je završila osnovnu školu. Srednju školu završila je u Ivanić-Gradu, nakon čega 2009. godine upisuje Prirodoslovno-matematički fakultet Sveučilišta u Zagrebu, Biološki odsjek, smjer Znanosti o okolišu. Preddiplomski studij završava 2012. godine i nastavlja školovanje na diplomskom studiju istog smjera. Zvanje magistre struke Znanosti o okolišu stječe 2014. godine. Četiri godine kasnije, tj. 2018. godine, nastavlja školovanje na poslijediplomskom studiju Poljoprivredne znanosti na Agronomskom fakultetu Sveučilišta u Zagrebu.

Radno iskustvo započinje u lipnju 2015. godine stručnim osposobljavanjem u Odjelu za otpad i tokove materijala u Agenciji za zaštitu okoliša (od rujna 2015. godine Hrvatska agencija za okoliš i prirodu). Trenutno, sa sedam godina radnog iskustva, radi kao viša stručna suradnica u Ministarstvu gospodarstva i održivog razvoja. Bavi se temama komunalnog otpada, biootpada, vodi podatke o kompostanama i bioplinskim postrojenjima, reciklažnim dvorištima i drugo. Aktivno je sudjelovala na uspostavi nacionalnog sustava e-ONTO (elektromnički očevidnik o nastanku i tijeku otpada). Aktivno je sudjelovala i na statističkom istraživanju otpada od hrane u Republici Hrvatskoj provedenom u 2021. godini. Povezano s radnim zadacima, područje interesa su gospodarenje biorazgradivim otpadom, zaštite okoliša i razvoj matematičkih modela. Sudjelovala je na brojnim konferencijama iz područja gospodarenja otpadom. Govori engleski i njemački.

Popis radova:

Voća, N.; Puntarić, E.; Šurić, J.; Kunjko, D. (2020): Vegan vs meat: Categorization of plate waste in restaurants; *Fresenius Environmental Bulletin*, Vol.29; No.4A; 3048-3055.

Puntarić, D.; Venus, M.; Gvozdić, V.; Vidosavljević, D.; Puntarić, A.; Puntarić, E.; Miletić-Medved, M. (2019): Koncentracija urana u tlu, vodi, povrću i biološkim uzorcima stanovnika područja pogođenih ratom u istočnoj Hrvatskoj; 4. Hrvatski epidemiološki kongres s međunarodnim sudjelovanjem, *Knjiga sažetaka / Tešić, V.; Jurčev-Savičević, A. (ur.)*.

Venus, M.; Puntarić, D.; Gvozdić, V.; Vidosavljević, D.; Bijelić, L.; Puntarić, A.; Puntarić, E.; Špehar, M.; Venus, T.; Vidosavljević, M. (2019): Koncentracija urana u tlu, vodi, povrću i biološkim uzorcima stanovnika pogođenih ratom u istočnoj Hrvatskoj; *Medica Jadertina*, Vol.49; No.1; 15-24.

Venus, M.; Puntarić, D.; Gvozdić, V.; Vidosavljević, D.; Bijelić, L.; Puntarić, A.; Puntarić, E.; Vidosavljević, M.; Jergović, M.; Šabarić, J. (2019): Determination of uranium concentrations in soil, water, vegetables and biological samples from inhabitants of war affected areas in eastern Croatia (ICP-MS method); *Journal of environmental radioactivity*, Vol.203; 147-153.



Požgaj Đ, Gumhalter Malić L, Puntarić E, Pavlinec B, Gudelj I. (2018): Aktualnosti u informacijskom sustavu gospodarenja otpadom – pregled aktivnosti Hrvatske agencije za okoliš i prirodu. Međunarodna konferencija o zaštiti okoliša, Energija, ekologija i ekonomija kružnog gospodarenja otpadom, Poreč, 6. – 8. lipnja 2018.

Puntarić D, Vidosavljević D, Gvozdić, V, Puntarić A, Puntarić E. (2018): Elementi rijetkih zemalja (REE) u urinu i serumu stanovnika istočne Hrvatske; 82. Stručno znanstveni sastanak Hrvatskog epidemiološkog društva Hrvatskog liječničkog zbora.

## 179. PRILOZI

### Prilog 1: Popis ključnih brojeva koji spadaju u komunalni otpad

Tablica 26. Popis ključnih brojeva koji spadaju u komunalni otpad (izvor: Ministarstvo gospodarstva i održivog razvoja, 2020)

Ključni broj	Opisni naziv otpada
15 01 01	Papirna i kartonska ambalaža
15 01 02	Plastična ambalaža
15 01 03	Drvena ambalaža
15 01 04	Metalna ambalaža
15 01 05	Višeslojna (kompozitna) ambalaža
15 01 06	Miješana ambalaža
15 01 07	Staklena ambalaža
15 01 09	Tekstilna ambalaža
15 01 10*	Ambalaža koja sadrži ostatke opasnih tvari ili ambalaža koja je onečišćena opasnim tvarima
15 01 11*	Metalna ambalaža koja sadrži opasne krute porozne materijale (npr. azbest), uključujući prazne spremnike pod tlakom
20 01 01	Papir i karton
20 01 02	Staklo
20 01 08	Biorazgradivi otpad iz kuhinja i kantina
20 01 10	Odjeća
20 01 11	Tekstil
20 01 13*	Otapala
20 01 14*	Kiseline
20 01 15*	Lužine
20 01 17*	Fotografske kemikalije
20 01 19*	Pesticidi
20 01 21*	Fluorescentne cijevi i ostali otpad koji sadrži živu
20 01 23*	Odbačena oprema koja sadrži klorofluorouglikide
20 01 25	Jestiva ulja i masti
20 01 26*	Ulja i masti koje nisu navedene pod 20 01 25*
20 01 27*	Boje, tinte, ljepila i smole koji sadrže opasne tvari

Ključni broj	Opisni naziv otpada
20 01 28	Boje, tinte, ljepila i smole koje nisu navedene pod 20 01 27*
20 01 29*	Deterdženti koji sadrže opasne tvari
20 01 30	Deterdženti koji nisu navedeni pod 20 01 29*
20 01 31*	Citotoksici i citostatici
20 01 32	Lijekovi koji nisu navedeni pod 20 01 31*
20 01 33*	Baterije i akumulatori obuhvaćeni pod 16 06 01*, 16 06 02* ili 16 06 03* i nesortirane baterije i akumulatori koji sadrže te baterije
20 01 34	Baterije i akumulatori koji nisu navedeni pod 20 01 33*
20 01 35*	Odbačena električna i elektronička oprema koja nije navedena pod 20 01 21* i 20 01 23*, koja sadrži opasne komponente
20 01 36	Odbačena električna i elektronička oprema koja nije navedena pod 20 01 21*, 20 01 23* i 20 01 35*
20 01 37*	Drvo koje sadrži opasne tvari
20 01 38	Drvo koje nije navedeno pod 20 01 37*
20 01 39	Plastika
20 01 40	Metali
20 01 41	Otpad od čišćenja dimnjaka
20 01 99	Ostali sastojci komunalnog otpada koji nisu specificirani na drugi način
20 02 01	Biorazgradivi otpad
20 02 03	Ostali otpad koji nije biorazgradiv
20 03 01	Miješani komunalni otpad
20 03 02	Otpad s tržnica
20 03 03	Ostaci od čišćenja ulica
20 03 07	Glomazni otpad
20 03 99	Komunalni otpad koji nije specificiran na drugi način

## Prilog 2: Podaci korišteni za razvoj mreže

Tablica 27. Podaci o broju stanovnika korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	10.130.574	4.658.893	10.333.161	5.215.718	1.448.075	59.315.139	10.336.700	3.597.617	56.844.408	2.500.580	3.642.991	405.650	376.433	15.424.122	1.989.477	39.639.726	8.816.381
1996	10.143.047	4.581.167	10.321.344	5.251.027	1.425.192	59.522.297	10.321.229	3.620.065	56.844.197	2.469.531	3.615.212	411.600	378.404	15.493.889	1.990.266	39.808.374	8.837.496
1997	10.170.226	4.533.028	10.309.137	5.275.121	1.405.996	59.726.386	10.301.247	3.654.955	56.876.364	2.444.912	3.588.013	416.850	381.405	15.567.107	1.986.989	39.971.329	8.844.499
1998	10.192.264	4.536.812	10.299.125	5.294.860	1.393.074	59.934.884	10.279.724	3.693.386	56.904.379	2.420.789	3.562.261	422.050	384.176	15.654.192	1.984.923	40.143.449	8.847.625
1999	10.213.752	4.527.460	10.289.621	5.313.577	1.379.237	60.158.533	10.253.416	3.732.006	56.909.109	2.399.248	3.536.401	427.350	386.397	15.760.225	1.978.334	40.303.568	8.854.322
2000	10.239.085	4.497.735	10.278.098	5.330.020	1.401.250	60.545.022	10.221.644	3.777.565	56.923.524	2.381.715	3.512.074	433.600	388.759	15.863.950	1.987.755	40.470.182	8.861.426
2001	10.263.414	4.295.406	10.232.027	5.349.212	1.392.720	60.979.315	10.200.298	3.832.783	56.960.692	2.353.384	3.486.998	439.000	391.415	15.987.075	1.990.094	40.665.545	8.882.792
2002	10.309.725	4.305.494	10.201.182	5.368.354	1.383.510	61.424.036	10.174.853	3.899.702	56.987.507	2.320.956	3.454.637	444.050	394.641	16.105.285	1.994.026	41.035.278	8.909.128
2003	10.355.844	4.305.384	10.192.649	5.383.507	1.375.190	61.864.088	10.142.362	3.964.191	57.130.506	2.299.390	3.431.497	448.300	397.296	16.192.572	1.995.033	41.827.838	8.940.788
2004	10.396.421	4.305.725	10.195.347	5.397.640	1.366.250	62.292.241	10.116.742	4.028.851	57.495.900	2.276.520	3.398.929	454.960	399.867	16.258.032	1.996.433	42.547.451	8.975.670
2005	10.445.852	4.310.861	10.198.855	5.411.405	1.358.850	62.772.870	10.097.549	4.111.672	57.874.753	2.249.724	3.355.220	461.230	402.668	16.305.526	1.997.590	43.296.338	9.011.392
2006	10.511.382	4.312.487	10.223.577	5.427.459	1.350.700	63.229.635	10.076.581	4.208.156	58.064.214	2.227.874	3.289.835	469.086	404.999	16.334.210	2.003.358	44.009.971	9.047.752
2007	10.584.534	4.313.530	10.254.233	5.447.084	1.342.920	63.645.065	10.066.158	4.340.118	58.223.744	2.208.840	3.249.983	476.187	405.616	16.357.992	2.010.377	44.784.666	9.113.257
2008	10.666.866	4.311.967	10.343.422	5.475.791	1.338.440	64.007.193	10.045.401	4.457.765	58.652.875	2.191.810	3.212.605	483.799	407.832	16.405.399	2.010.269	45.668.939	9.182.927
2009	10.753.080	4.309.796	10.425.783	5.511.451	1.335.740	64.350.226	10.030.975	4.521.322	59.000.586	2.162.834	3.183.856	493.500	410.926	16.485.787	2.032.362	46.239.273	9.256.347
2010	10.839.905	4.302.847	10.462.088	5.534.738	1.333.290	64.658.856	10.014.324	4.549.428	59.190.143	2.120.504	3.141.976	502.066	414.027	16.574.989	2.046.976	46.486.619	9.340.682
2011	11.000.638	4.289.857	10.486.731	5.560.628	1.329.660	64.978.721	9.985.722	4.570.881	59.364.690	2.074.605	3.052.588	511.840	414.989	16.655.799	2.050.189	46.667.174	9.415.570
2012	11.075.889	4.275.984	10.505.445	5.580.516	1.325.217	65.276.983	9.931.925	4.589.287	59.394.207	2.044.813	3.003.641	524.853	417.546	16.730.348	2.055.496	46.818.219	9.482.855
2013	11.137.974	4.262.140	10.516.125	5.602.628	1.320.174	65.600.350	9.908.798	4.609.779	59.685.227	2.023.825	2.971.905	537.039	422.509	16.779.575	2.058.821	46.727.890	9.555.893
2014	11.180.840	4.246.809	10.512.419	5.627.235	1.315.819	66.165.980	9.877.365	4.637.852	60.782.668	2.001.468	2.943.472	549.680	429.424	16.829.289	2.061.085	46.512.199	9.644.864
2015	11.237.274	4.225.316	10.538.275	5.659.715	1.314.870	66.458.153	9.855.571	4.677.627	60.795.612	1.986.096	2.921.262	562.958	439.691	16.900.726	2.062.874	46.449.565	9.747.355
2016	11.311.117	4.190.669	10.553.843	5.707.251	1.315.944	66.638.391	9.830.485	4.726.286	60.665.551	1.968.957	2.888.558	576.249	450.415	16.979.120	2.064.188	46.440.099	9.851.017
2017	11.351.727	4.154.213	10.578.820	5.748.769	1.315.635	66.809.816	9.797.561	4.784.383	60.589.445	1.950.116	2.847.904	590.667	460.297	17.081.507	2.065.895	46.528.024	9.995.153
2018	11.398.589	4.105.493	10.610.055	5.781.190	1.319.133	66.918.941	9.778.371	4.830.392	60.483.973	1.934.379	2.808.901	602.005	475.701	17.181.084	2.066.880	46.658.447	10.120.242
2019	11.455.519	4.076.246	10.649.800	5.806.081	1.324.820	67.012.883	9.772.756	4.904.240	60.359.546	1.919.968	2.794.184	613.894	493.559	17.282.163	2.080.908	46.937.060	10.230.185

Tablica 28. Podaci o životnom vijeku (god.) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irsk	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	77,0	72,1	73,3	75,3	67,7	78,1	70,0	75,5	78,3		69,1	76,8	77,4	77,6	74,7	78,1	79,0
1996	77,3	72,4	74,0	75,7	69,9	78,2	70,6	75,8	78,7		70,3	76,8	77,5	77,6	75,2	78,3	79,2
1997	77,5	72,5	74,1	76,1	70,1	78,6	71,1	76,0	79,0		71,1	77,1	77,8	78,0	75,2	78,8	79,4
1998	77,6	72,3	74,7	76,5	69,7	78,7	71,0	76,2	79,1		71,4	77,3	77,7	78,1	75,3	78,8	79,5
1999	77,7	72,6	74,9	76,6	70,6	78,9	71,1	76,1	79,6		71,8	78,0	77,6	78,0	75,7	78,8	79,6
2000	77,9	72,8	75,1	76,9	71,1	79,2	71,9	76,6	79,9		72,1	78,0	78,5	78,2	76,2	79,3	79,8
2001	78,1	74,6	75,3	77,0	70,9	79,3	72,5	77,2	80,3		71,6	78,0	78,9	78,4	76,4	79,8	79,9
2002	78,2	74,7	75,4	77,1	71,4	79,4	72,6	77,7	80,4	70,2	71,8	78,1	78,8	78,5	76,6	79,8	80,0
2003	78,3	74,6	75,3	77,4	71,9	79,3	72,6	78,2	80,1	70,6	72,0	77,9	78,7	78,7	76,4	79,7	80,3
2004	79,0	75,4	75,9	77,8	72,4	80,3	73,0	78,6	80,9	70,9	72,0	79,2	79,4	79,3	77,2	80,4	80,7
2005	79,1	75,3	76,1	78,3	73,0	80,3	73,0	79,0	80,9	70,6	71,2	79,6	79,4	79,6	77,5	80,3	80,7
2006	79,5	75,9	76,7	78,4	73,2	80,9	73,5	79,3	81,4	70,6	71,0	79,4	79,5	80,0	78,3	81,1	81,0
2007	79,9	75,8	77,0	78,4	73,2	81,3	73,6	79,7	81,6	70,8	70,7	79,5	79,9	80,4	78,4	81,1	81,1
2008	79,8	76,0	77,3	78,8	74,4	81,4	74,2	80,2	81,7	72,1	71,7	80,7	79,7	80,5	79,1	81,5	81,3
2009	80,2	76,3	77,4	79,0	75,3	81,5	74,4	80,2	81,8	72,8	72,9	80,8	80,4	80,9	79,4	81,9	81,5
2010	80,3	76,7	77,7	79,3	76,0	81,8	74,7	80,8	82,2	73,1	73,3	80,8	81,5	81,0	79,8	82,4	81,6
2011	80,7	77,2	78,0	79,9	76,6	82,3	75,1	80,9	82,4	73,9	73,7	81,1	80,9	81,3	80,1	82,6	81,9
2012	80,5	77,3	78,1	80,2	76,7	82,1	75,3	80,9	82,4	74,1	74,1	81,5	80,9	81,2	80,3	82,5	81,8
2013	80,7	77,8	78,3	80,4	77,5	82,4	75,8	81,0	82,9	74,3	74,1	81,9	81,9	81,4	80,5	83,2	82,0
2014	81,4	77,9	78,9	80,7	77,4	82,9	76,0	81,4	83,2	74,5	74,7	82,3	82,1	81,8	81,2	83,3	82,3
2015	81,1	77,5	78,7	80,8	78,0	82,4	75,7	81,5	82,7	74,8	74,6	82,4	82,0	81,6	80,9	83,0	82,2
2016	81,5	78,2	79,1	80,9	78,0	82,7	76,2	81,7	83,4	74,9	74,9	82,7	82,6	81,7	81,2	83,5	82,4
2017	81,6	78,0	79,1	81,1	78,4	82,7	76,0	82,2	83,1	74,9	75,8	82,1	82,4	81,8	81,2	83,4	82,5
2018	81,7	78,2	79,1	81,0	78,5	82,9	76,2	82,3	83,4	75,1	76,0	82,3	82,5	81,9	81,5	83,5	82,6
2019	81,6	78,4	79,4	81,3	78,6	82,6		82,2	83,4					82,2	81,2		

Tablica 29. Podaci o BDP-u po tržišnim cijenama (milijun eura) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	220.252	17.350	46.008	141.441	2.985	1.224.717	35.469	52.890	898.299	4.124	5.124	16.508	2.847	346.001	16.340	470.156	204.329
1996	219.965	18.939	53.088	147.843	3.765	1.265.105	36.758	59.698	1.033.760	4.685	6.604	17.156	3.011	354.929	16.946	506.363	229.771
1997	223.033	21.123	54.857	153.152	4.548	1.282.410	41.741	73.087	1.096.302	5.734	8.924	17.415	3.347	367.862	18.321	520.831	236.646
1998	231.016	22.696	59.825	158.146	5.060	1.343.327	43.409	80.496	1.134.535	6.384	10.026	18.059	3.582	391.461	19.785	553.338	241.468
1999	242.308	21.968	61.083	166.972	5.412	1.400.999	46.040	92.669	1.175.150	7.032	10.294	20.871	3.861	419.459	21.228	595.723	257.110
2000	256.376	23.468	67.033	178.018	6.180	1.478.585	51.239	108.400	1.241.513	8.606	12.491	23.079	4.412	452.007	21.867	647.851	285.150
2001	264.335	25.843	75.705	184.046	6.992	1.538.200	60.013	122.010	1.304.137	9.343	13.681	23.772	4.566	481.881	23.249	700.993	270.525
2002	273.256	28.475	87.358	189.795	7.827	1.587.829	71.756	135.956	1.350.259	10.140	15.173	25.095	4.741	501.137	24.972	749.552	283.627
2003	281.200	30.728	88.660	193.353	8.748	1.630.666	75.443	145.534	1.394.693	10.464	16.669	26.188	4.824	512.810	26.248	802.266	296.306
2004	296.820	33.481	96.554	202.422	9.776	1.704.019	83.754	156.189	1.452.319	11.659	18.237	27.936	4.910	529.286	27.692	859.437	310.182
2005	310.038	36.485	110.322	212.832	11.337	1.765.905	90.905	170.231	1.493.635	13.716	21.002	30.031	5.152	550.883	29.122	927.357	315.775
2006	325.152	40.199	124.581	225.531	13.561	1.848.151	92.017	184.914	1.552.687	17.256	24.079	33.808	5.403	584.546	31.476	1.003.823	337.317
2007	343.619	43.991	139.002	233.383	16.399	1.941.360	102.253	197.130	1.614.840	22.677	29.041	37.179	5.790	619.170	35.074	1.075.539	358.945
2008	351.743	47.998	162.065	241.614	16.638	1.992.380	108.216	187.620	1.637.699	24.397	32.696	38.129	6.206	647.198	37.926	1.109.541	354.881
2009	346.473	45.064	149.587	231.278	14.212	1.936.422	94.383	169.786	1.577.256	18.807	26.935	36.977	6.260	624.842	36.255	1.069.323	314.638
2010	363.140	45.112	157.921	243.165	14.861	1.995.289	98.987	167.674	1.611.279	17.818	27.955	40.178	6.816	639.187	36.364	1.072.709	374.695
2011	375.968	44.793	165.202	247.880	16.827	2.058.369	101.553	170.951	1.648.756	20.219	31.234	43.165	6.925	650.359	37.059	1.063.763	412.845
2012	386.175	43.941	162.588	254.578	18.051	2.088.804	99.734	175.104	1.624.359	22.098	33.332	44.112	7.365	652.966	36.253	1.031.099	430.037
2013	392.880	43.703	159.462	258.743	19.033	2.117.189	102.032	179.616	1.612.751	22.845	34.985	46.500	7.944	660.463	36.454	1.020.348	441.851
2014	403.003	43.401	157.821	265.757	20.180	2.149.765	105.906	195.148	1.627.406	23.654	36.545	49.825	8.751	671.560	37.634	1.032.158	438.834
2015	416.701	44.616	169.558	273.018	20.782	2.198.432	112.210	262.853	1.655.355	24.426	37.322	52.066	9.997	690.008	38.853	1.077.590	455.495
2016	430.231	46.616	177.439	283.110	21.932	2.234.129	115.259	270.810	1.695.787	25.073	38.893	54.867	10.538	708.337	40.367	1.113.840	466.267
2017	445.957	49.094	194.133	292.408	23.858	2.297.242	125.603	300.387	1.736.593	26.798	42.269	56.814	11.638	738.146	42.987	1.161.867	480.026
2018	459.532	51.625	210.893	301.341	25.938	2.360.687	133.782	326.986	1.766.168	29.056	45.264	60.053	12.491	773.987	45.755	1.204.241	470.673
2019	473.085	53.937	223.945	310.002	28.112	2.425.708	143.826	356.051	1.787.664	30.476	48.433	63.516	13.390	810.247	48.007	1.244.772	474.194

Tablica 30. Podaci o BDP-u po stanovniku (euro po stanovniku) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	25.810	7.046	5.698	29.093	2.588	28.012	7.398	15.927	27.142					31.922	12.506		
1996	26.128	7.560	6.540	29.735	2.792	28.440	7.487	17.322	27.554					32.659	12.776		
1997	27.038	8.111	7.054	30.556	3.678	28.867	7.665	18.719	27.965					34.134	13.585		
1998	27.500	8.156	7.725	31.109	3.379	29.792	7.860	20.147	28.464					35.507	13.693		
1999	28.408	8.246	8.080	31.801	3.427	30.654	8.251	21.825	28.922					37.047	13.800		
2000	29.890	8.200	11.230	42.190	3.370	31.639	8.506	33.290	27.430	5.210	5.230	70.460	13.750	38.326	13.980	21.460	33.960
2001	30.110	8.460	11.620	42.390	3.728	29.290	9.016	34.520	27.950	5.610	5.620	71.440	13.480	38.471	14.410	22.190	34.360
2002	30.490	8.890	11.830	42.430	4.419	29.410	8.660	35.920	27.960	6.080	6.050	73.380	13.730	38.760	14.900	22.430	35.000
2003	30.680	9.400	12.260	42.490	7.206	29.440	9.040	36.400	27.850	6.660	6.740	73.650	14.200	38.929	15.330	22.680	35.680
2004	31.640	9.780	12.840	43.520	7.369	30.050	9.490	38.190	28.030	7.290	7.260	75.270	14.120	39.267	15.990	23.020	37.080
2005	32.200	10.190	13.650	44.400	8.604	30.320	9.910	39.480	28.090	8.170	7.950	76.460	14.510	39.943	16.570	23.420	37.990
2006	32.800	10.700	14.530	45.990	10.443	30.850	10.330	40.390	28.480	9.220	8.670	79.190	14.820	41.296	17.460	24.000	39.540
2007	33.760	11.260	15.250	46.210	13.842	31.400	10.370	41.280	28.730	10.220	9.750	84.420	15.470	42.761	18.570	24.380	40.590
2008	33.640	11.470	15.500	45.700	15.070	31.310	10.500	38.600	28.230	9.990	10.110	81.880	15.960	39.810	19.190	24.200	40.100
2009	32.700	10.630	14.690	43.220	12.232	30.250	9.810	36.300	26.590	8.710	8.710	76.900	15.660	42.053	17.570	23.100	38.030
2010	33.330	10.500	15.020	43.840	12.229	30.690	9.900	36.770	26.930	8.500	9.030	79.160	16.440	42.204	17.750	23.040	39.950
2011	33.460	10.500	15.310	44.240	14.569	31.210	10.110	36.840	27.020	9.200	9.790	79.310	16.450	42.506	17.870	22.770	40.920
2012	33.490	10.300	15.170	44.170	14.497	31.160	10.010	36.740	26.090	9.700	10.300	77.240	16.970	38.340	17.360	22.080	40.380
2013	33.490	10.280	15.160	44.410	15.853	31.170	10.230	37.010	25.480	10.030	10.780	78.030	17.650	41.735	17.160	21.840	40.510
2014	33.870	10.310	15.480	44.890	16.839	31.320	10.690	39.920	25.420	10.310	11.250	79.490	18.610	42.094	17.620	22.210	41.180
2015	34.360	10.630	16.290	45.630	14.487	31.540	11.130	49.510	25.640	10.740	11.590	81.300	19.920	42.813	17.990	23.080	42.580
2016	34.690	11.100	16.670	46.720	15.078	31.770	11.410	49.930	26.020	11.030	12.040	82.880	20.230	43.383	18.540	23.760	42.920
2017	35.210	11.560	17.490	47.360	16.856	32.380	11.930	53.890	26.490	11.560	12.720	82.550	21.250	44.522	19.430	24.430	43.430
2018	35.580	11.990	17.980	48.260	19.229	32.860	12.560	57.780	26.740	12.140	13.310	83.470	21.580	45.003	20.170	24.910	43.760
2019	35.900	12.410	18.330	49.180	19.561	33.270	13.180	60.170	26.860	12.490	13.880	83.640	21.770	45.965	20.490	25.200	43.870

Tablica 31. Podaci o ukupim obvezama financijskog sektora (kao postotak BDP-a) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	364,9	91,6	153,1	343,4	57,4	315,3	161,4	883,1	166,5	46,6	40,0		237,2	630,0	79,3	211,6	238,7
1996	392,9	98,3	148,4	368,5	74,3	327,0	144,3	883,1	172,2	56,0	34,6		263,2	664,9	84,8	221,9	249,9
1997	407,7	105,4	161,5	417,0	108,2	348,1	134,7	883,1	194,2	67,0	35,8		290,7	704,2	92,8	238,9	273,6
1998	453,1	106,0	156,5	465,8	93,5	351,7	132,0	883,1	222,7	61,8	41,2		358,1	754,1	95,8	250,0	295,7
1999	469,7	107,2	156,5	493,4	107,5	389,4	149,7	883,1	245,6	67,4	42,8	8.579,3	416,5	792,9	99,1	261,5	312,6
2000	454,3	106,6	154,0	506,7	133,3	393,5	174,5	883,1	260,5	81,8	45,4	9.042,9	414,9	800,4	107,1	260,0	337,0
2001	473,5	108,0	142,8	496,3	133,3	396,3	187,2	883,1	240,9	90,6	50,4	9.845,6	401,4	795,2	121,4	258,5	330,2
2002	451,3	120,7	150,8	482,6	148,0	388,8	170,7	875,4	241,1	100,3	54,6	9.727,6	439,4	797,4	135,3	255,0	322,7
2003	487,1	131,0	149,3	510,6	150,2	404,5	174,6	1.001,8	261,7	109,6	64,9	11.005,3	479,5	822,4	139,9	278,3	336,4
2004	522,7	139,0	145,1	525,2	171,9	425,2	171,5	1.121,3	269,5	127,8	74,4	11.855,6	947,2	854,1	144,6	302,1	359,2
2005	582,0	146,1	151,7	625,8	177,5	471,8	216,5	1.390,2	293,5	145,3	96,0	14.298,6	1.482,4	947,5	161,3	349,8	407,1
2006	617,4	169,2	146,1	660,3	179,9	519,8	236,7	1.556,1	313,4	170,4	111,3	14.736,5	1.894,4	996,5	169,6	389,0	418,6
2007	668,9	190,7	154,5	703,9	189,4	558,4	276,8	1.600,4	302,8	176,3	123,8	15.304,8	2.569,7	1.076,8	195,5	425,2	431,0
2008	624,4	163,2	155,6	679,1	192,7	555,4	329,5	1.790,3	293,7	177,9	114,7	13.896,1	2.663,1	1.075,7	192,7	432,8	470,0
2009	637,1	178,0	162,6	749,8	215,3	567,4	344,3	2.044,8	320,1	208,8	133,1	15.297,3	2.796,0	1.194,2	216,6	461,5	499,3
2010	600,3	186,4	166,3	782,3	188,2	570,2	333,3	2.201,7	326,7	220,5	128,1	15.922,4	2.972,4	1.230,6	208,6	450,5	480,4
2011	610,9	187,6	171,2	779,5	165,8	591,1	340,2	2.110,2	334,9	182,9	116,9	16.440,0	3.170,1	1.333,5	202,2	469,7	469,0
2012	564,2	190,9	178,7	779,1	171,4	590,9	315,0	2.023,2	363,9	179,0	108,7	18.518,6	3.279,9	1.407,4	205,2	487,7	493,2
2013	561,2	195,7	194,1	778,8	179,3	585,8	296,3	2.010,8	358,1	182,0	102,4	19.380,9	3.076,1	1.369,6	183,4	442,0	530,3
2014	560,8	196,8	194,6	814,1	191,2	609,0	298,3	2.212,6	358,2	195,5	114,4	24.930,2	2.928,1	1.455,4	177,4	437,0	571,8
2015	557,0	195,7	197,3	785,1	201,7	608,4	281,6	1.800,9	357,0	214,4	120,1	28.042,3	2.673,4	1.473,3	165,4	410,2	545,6
2016	552,3	195,9	222,2	800,4	207,2	626,4	326,0	1.774,5	359,9	218,7	133,5	27.995,6	2.592,9	1.541,2	164,6	406,6	574,4
2017	540,3	195,1	267,5	807,9	214,3	637,9	278,3	1.667,8	357,9	217,4	139,9	27.157,9	2.528,9	1.487,1	162,8	402,1	586,2
2018	510,8	195,2	261,4	759,3	210,2	632,2	229,8	1.601,9	350,9	193,9	141,3	25.171,9	2.373,3	1.376,8	159,2	379,7	546,4
2019	517,8		259,6		218,2		231,4	1.698,7	360,5					1.395,4	166,7	370,0	581,4



Tablica 32. Podaci o neto vanjskom dugu (kao postotak BDP-a) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Irska	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995													-6,2		40,7
1996													-2,4		38,9
1997													-4,7		42,6
1998													-3,2		41,5
1999		14,0			24,9								1,6		35,8
2000		20,0			24,1			10,4					3,8		37,3
2001		10,1			19,8			14,8					-6,2		51,3
2002		18,7			22,1		-202,0	16,9		-2.274,4			-10,4	28,7	48,0
2003		27,7			25,5		-206,8	21,1		-2.261,3		44,0	-6,7	32,4	51,1
2004		32,1	-14,3		30,9		-192,9	27,5	14,3	-2.318,2	-57,7	53,4	-3,3	39,2	49,8
2005	-43,6	35,8	-16,4	20,9	32,7		-200,9	33,9	16,9	-2.433,0	-163,2	48,9	3,1	48,5	54,7
2006	-49,3	37,4	-12,1	31,9	42,8		-194,4	40,9	19,9	-2.511,9	-323,6	42,8	10,7	60,4	44,3
2007	-45,5	39,8	-7,4	32,3	48,0		-203,9	46,1	29,6	-2.587,1	-385,9	45,9	24,2	71,1	44,8
2008	-77,1	50,2	-4,7	29,8	53,9	22,7	-153,2	53,8	35,7	-2.139,8	-428,8	59,0	34,5	77,8	65,7
2009	-100,5	60,3	-2,4	28,6	51,7	25,4	-202,4	58,8	38,0	-2.686,1	-334,8	63,0	39,0	88,8	70,8
2010	-110,1	63,0	-1,3	21,9	34,3	28,1	-277,4	56,1	36,1	-2.972,4	-490,7	71,1	41,5	91,9	60,9
2011	-112,5	63,5	-0,2	14,3	5,7	28,3	-313,3	47,7	32,2	-2.345,3	-495,7	66,9	37,7	95,8	61,3
2012	-92,2	60,7	-1,1	10,9	-1,1	33,8	-349,4	39,9	34,1	-2.319,1	-479,0	51,7	42,2	93,8	58,5
2013	-81,8	60,5	-5,1	8,2	-4,9	32,4	-342,6	37,0	29,7	-2.147,9	-376,2	51,6	37,6	92,7	55,5
2014	-70,7	58,4	-6,3	0,2	-10,4	35,8	-400,5	35,2	28,6	-1.806,7	-299,5	53,0	36,7	95,8	55,7
2015	-52,8	52,5	-9,7	0,1	-10,2	35,3	-284,9	30,4	26,8	-1.794,0	-236,4	53,6	30,4	92,0	48,0
2016	-28,0	42,1	-13,4	-6,3	-10,3	34,6	-360,6	29,5	25,1	-1.737,9	-204,1	36,3	24,3	87,7	46,3
2017	-15,9	32,7	-11,6	-8,4	-14,3	38,2	-380,8	24,1	20,3	-1.882,3	-207,3	21,3	17,6	85,4	38,4
2018	-2,8	26,0	-12,7	-7,0	-17,4	40,0	-354,3	22,2	14,1	-1.960,3	-179,2	8,7	9,0	80,4	37,5
2019	8,2	18,4	-14,1	-17,2	-21,9	43,3	-384,2	19,7	9,2	-2.386,5	-165,1	-11,7	2,5	74,6	30,3

Tablica 33. Podaci o nominalnom efektivnom tečaju (kao postotna promjena) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	6,7	15,6	6,2	7,6	28,3	6,4	-16,8	1,9	-5,5	28,9	23,3	6,4	3,0	6,6	6,6	2,8	2,7
1996	-1,4	0,2	3,1	0,0	0,3	1,0	-13,1	3,0	11,0	1,6	7,8	-1,4	-0,9	-1,2	-9,1	1,7	10,7
1997	-3,8	0,5	-2,6	-2,6	-2,7	-3,1	-6,2	2,3	1,7	6,1	14,6	-3,6	1,8	-3,6	-3,6	-3,9	-3,3
1998	2,0	5,2	3,8	3,3	13,5	3,4	-7,6	-2,8	3,3	13,3	21,2	1,4	3,0	2,0	2,2	2,0	0,9
1999	0,4	1,6	2,0	1,1	14,2	0,2	-1,3	-1,8	1,6	18,1	26,9	0,4	-0,1	0,8	0,3	1,0	1,8
2000	-3,6	-2,3	1,5	-4,7	-3,8	-4,5	-4,9	-5,8	-4,2	7,3	11,9	-2,5	-1,9	-3,1	-7,4	-3,4	-0,5
2001	1,4	3,7	5,2	1,9	1,8	1,7	2,6	1,4	2,1	1,0	4,5	0,8	1,1	1,3	-4,3	2,1	-7,5
2002	1,6	2,8	12,0	1,8	2,0	2,2	7,2	2,3	2,6	-1,8	6,7	1,1	1,6	1,4	-2,1	2,0	3,0
2003	5,2	2,1	0,4	5,4	5,2	6,1	-0,5	7,7	6,7	-4,6	7,3	3,3	4,1	4,5	0,4	5,2	7,2
2004	1,4	2,3	0,6	1,6	1,5	1,8	1,7	2,5	2,1	-2,8	1,6	0,7	2,3	1,1	-1,2	1,4	2,5
2005	-0,6	0,4	6,0	-0,9	-0,4	-0,8	0,4	-0,4	-1,1	-5,3	-0,8	-0,5	-1,1	-0,6	-1,3	-0,8	-2,9
2006	0,0	0,8	4,8	-0,1	-0,3	0,0	-6,4	0,3	0,0	-0,5	-0,5	-0,1	0,5	0,0	-0,3	0,0	0,3
2007	1,4	0,8	2,4	1,5	1,4	1,7	5,7	2,6	1,7	0,4	1,2	0,7	3,0	1,1	0,5	1,3	1,8
2008	2,1	3,1	12,6	2,5	2,0	2,5	1,0	4,2	2,3	1,6	1,8	1,8	2,8	2,3	0,8	2,3	-1,7
2009	1,5	1,0	-2,9	2,9	4,7	1,4	-7,4	1,0	1,8	4,9	5,8	1,9	-0,4	1,9	3,4	1,7	-7,6
2010	-2,9	-2,2	2,1	-4,5	-4,2	-3,7	-0,8	-3,8	-3,9	-4,3	-4,0	-2,4	-4,7	-2,8	-2,5	-3,0	7,0
2011	0,5	-1,4	3,2	-0,2	-0,2	0,4	-0,9	1,0	0,6	0,7	0,7	0,2	0,6	0,4	0,6	0,5	6,0
2012	-2,3	-2,8	-3,6	-2,9	-2,2	-2,8	-4,6	-3,9	-2,6	-0,7	-2,1	-1,8	-2,3	-2,1	-1,1	-2,1	0,8
2013	2,3	1,3	-1,6	2,4	2,1	2,7	-1,0	2,9	2,7	1,9	2,7	1,7	2,6	1,9	1,6	2,3	3,4
2014	1,2	2,1	-4,3	1,9	4,5	1,2	-2,2	0,3	1,7	4,7	5,6	1,0	1,2	0,9	2,3	1,2	-3,3
2015	-2,9	0,7	0,1	-2,5	2,6	-3,7	-1,2	-6,4	-3,3	3,6	5,4	-1,9	-5,0	-2,7	0,2	-2,8	-4,9
2016	2,1	3,0	2,7	2,2	2,2	2,1	1,2	2,1	2,1	3,0	3,2	1,5	1,5	2,1	1,7	2,2	0,9
2017	1,2	1,3	3,2	1,3	-0,1	1,3	1,3	1,8	1,3	-0,6	-1,0	0,7	1,6	1,1	0,1	1,3	-0,8
2018	2,3	3,4	4,7	2,7	3,4	2,8	-1,1	2,9	3,1	3,6	3,9	1,7	2,8	2,1	2,1	2,6	-3,9
2019	-0,6	-0,3	-0,3	-0,6	0,0	-0,8	-2,1	-1,9	-0,8	-0,2	-0,5	-0,4	-2,0	-0,5	-0,2	-0,5	-3,6

Tablica 34. Podaci o inozemnim izravnim ulaganjima (kao postotak BDP-a) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995			4,3				11,0				1,7				0,7	1,3	5,0
1996			2,1				7,1				2,8				0,8	1,5	1,3
1997			2,1				8,8				5,1				1,6	1,6	3,6
1998			5,6				6,7				11,7				1,0	2,5	8,8
1999			9,8			3,1	6,9		0,6		6,2				0,5	3,1	23,3
2000		4,6	8,1		7,4	3,1	5,8		1,2	4,1	4,0				0,7	6,9	9,3
2001		4,5	8,4		9,4	3,7	7,5		1,3	2,1	4,2				1,8	4,6	7,3
2002		3,7	10,4		4,6	3,4	5,4	31,7	1,3	1,6	5,7	488,3			7,5	5,5	6,7
2003	10,5	5,2	2,1		10,6	2,3	4,8	33,7	1,2	2,7	1,5	306,5			1,7	3,4	1,8
2004	11,8	3,2	5,4		8,9	1,7	4,3	19,7	1,1	4,1	3,8	226,7	123,4	21,2	1,8	2,4	4,4
2005	8,9	4,0	10,1	4,9	21,2	3,9	7,6	22,4	2,0	4,7	4,9	308,9	340,6	30,8	2,8	2,4	5,4
2006	14,4	6,6	4,5	0,9	10,3	3,4	16,2	9,8	2,9	7,9	7,4	304,0	371,6	51,2	1,9	2,6	5,1
2007	19,9	7,8	7,0	3,7	13,4	3,2	49,6	22,9	3,0	8,8	6,5	372,8	451,2	85,1	2,3	4,5	9,3
2008	38,7	7,7	3,7	0,5	7,9	2,3	47,6	7,9	-0,5	3,7	3,6	182,4	164,7	17,5	2,0	4,5	8,3
2009	15,1	4,8	2,5	1,2	9,1	0,7	-2,4	22,8	0,9	-0,6	-1,0	410,6	16,8	10,9	-0,7	0,7	2,1
2010	26,0	2,5	4,9	-3,6	13,0	1,5	-15,9	16,8	0,4	2,0	2,9	423,7	106,3	14,5	0,6	2,5	0,2
2011	31,5	2,0	1,9	3,8	4,9	1,5	10,0	15,3	1,5	5,4	4,3	679,9	82,0	37,1	1,7	1,9	1,1
2012	2,4	2,3	4,5	-4,9	7,7	1,2	8,2	25,9	0,0	3,8	1,6	971,6	36,1	29,4	0,1	1,6	0,8
2013	-5,6	1,7	3,5	0,2	4,4	1,1	-2,7	29,6	0,9	3,3	1,6	1.024,1	5,6	37,5	0,2	3,5	0,2
2014	-2,7	5,3	3,9	2,0	6,6	0,2	9,5	38,4	0,8	3,3	0,8	276,6	2,8	13,0	2,0	2,3	-1,7
2015	-4,3	0,1	0,9	0,6	-3,1	1,8	-4,3	82,0	0,7	3,0	2,5	1.295,6	34,0	42,2	4,0	1,9	2,0
2016	12,2	0,8	5,6	2,5	3,8	1,3	55,7	34,5	1,4	1,2	3,1	192,6	27,5	30,5	3,2	3,6	2,9
2017	-6,9	0,9	5,2	0,9	6,4	1,4	-8,3	19,2	0,6	3,7	2,8	126,4	31,0	27,5	2,5	2,0	4,8
2018	-10,3	1,9	3,4	0,3	3,8	2,6	-43,8	16,8	1,9	1,3	2,7	-899,5	32,4	-41,0	2,8	3,4	-0,2
2019	-5,3	1,9	3,8	-2,2	9,2	1,9	18,7	20,1	1,5	2,6	2,5	-517,5	30,1	3,9	2,6	0,8	4,6

Tablica 35. Podaci o harmoniziranim indeksima cijene stambenih objekata (kao prosječna godišnja stopa promjene) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
2001	2,4	-2,7	5,8	3,4		5,7		10,3	3,2	-2,0	10,0	12,1	6,7	6,1		6,0	5,7
2002	5,3	3,2	11,1	1,7		7,8		-0,6	8,7	38,9	6,0	7,0	10,6	2,8		12,4	4,7
2003	5,4	1,0	10,1	2,0		10,0		10,0	3,0	16,5	11,5	8,8	15,1	0,1		13,5	4,5
2004	6,0	8,7	-2,6	7,7		12,7		9,2	3,6	-4,0	8,3	11,4	13,3	2,6	6,5	13,1	8,9
2005	9,5	7,8	0,4	15,6		13,3		8,0	5,5	13,0	22,7	7,8	4,6	2,8	12,0	9,9	9,0
2006	6,8	13,7	5,8	21,4	41,7	9,7		12,1	3,0	41,0	22,6	8,4	17,0	1,5	14,1	9,5	11,5
2007	5,0	8,9	16,0	0,9	11,9	3,6		4,3	2,7	22,0	19,3	4,6	19,5	2,8	18,8	6,2	11,0
2008	1,2	-2,4	7,7	-7,8	-16,3	-1,9	-3,2	-8,4	-0,6	-10,8	-1,7	0,2	7,1	0,1	1,3	-4,8	-1,7
2009	0,3	-7,9	-4,7	-13,1	-36,3	-4,8	-9,1	-13,6	0,1	-34,9	-32,8	-0,6	-6,2	-3,0	-10,2	-5,7	1,1
2010	1,2	-7,6	-2,2	0,3	1,7	3,7	-6,0	-11,6	-0,8	-8,7	-8,6	4,2	-1,0	-3,3	-1,3	-3,7	6,6
2011	1,1	-2,0	-1,6	-4,0	3,1	3,9	-7,0	-17,9	-1,5	4,1	2,1	0,6	-3,4	-4,0	0,9	-9,8	1,2
2012	0,2	-4,6	-3,6	-4,9	3,1	-1,9	-9,4	-14,6	-5,0	-0,3	-3,3	2,1	0,4	-7,9	-8,5	-16,5	0,7
2013	0,1	-5,7	-0,8	3,1	7,3	-2,6	-4,5	-0,1	-7,5	6,8	0,3	3,3	-1,4	-7,9	-7,2	-10,0	4,5
2014	-1,3	-1,3	1,9	3,1	12,9	-1,7	3,1	15,4	-4,9	4,3	6,4	3,9	2,1	-0,1	-6,2	0,2	8,3
2015	0,8	-2,6	3,9	6,6	7,3	-1,7	13,2	10,8	-4,0	-2,4	4,7	5,3	4,1	3,4	1,4	3,7	12,0
2016	1,2	2,0	6,6	5,1	4,0	0,8	13,1	7,2	0,2	7,4	4,4	5,7	4,8	4,4	3,9	4,5	7,3
2017	1,7	2,9	9,1	3,2	1,8	2,3	9,3	9,7	-2,1	5,6	5,2	3,7	4,2	6,1	6,2	4,5	4,8
2018	1,0	4,6	6,2	3,5	2,1	1,3	10,9	8,3	-1,5	6,6	4,6	4,8	5,0	7,1	7,3	5,2	-3,3
2019	2,5	8,1	6,0	1,5	4,4	2,3	11,2	0,1	-0,6	5,9	4,9	8,0	4,6	4,8	5,0	3,9	0,5

Tablica 36. Podaci o ukupnom broju zaposlenih ljudi u dobi od 15 do 64 godine (broj zaposlenih u tisućama) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	3.106	1.196	4.251	2.342	590	18.879		977	14.085			143		5.904	722	9.302	3.526
1996	3.104	1.195	4.251	2.366	570	19.073	2.926	1.028	14.178			149		6.063	722	9.573	3.478
1997	3.172	1.187	4.251	2.406	543	19.082	2.942	1.081	14.291			153		6.279	723	10.087	3.442
1998	3.183	1.272	4.133	2.402	543	19.445	3.047	1.183	14.448	803	1.179	154		6.519	728	10.632	3.476
1999	3.293	1.263	3.982	2.447	514	19.740	3.178	1.274	14.708	788	1.169	160		6.716	723	11.439	3.572
2000	3.453	1.258	3.929	2.455	525	20.453	3.212	1.343	14.967	787	1.125	164	126	6.936	749	12.280	3.639
2001	3.419	1.272	3.925	2.454	524	21.064	3.285	1.396	15.341	778	1.080	172	129	7.102	756	12.815	3.847
2002	3.422	1.152	3.940	2.471	533	21.285	3.321	1.435	15.703	804	1.112	173	127	7.187	771	13.547	3.853
2003	3.434	1.160	3.847	2.432	528	21.754	3.383	1.465	15.951	810	1.148	172	128	7.166	769	14.210	3.868
2004	3.530	1.200	3.851	2.477	525	21.834	3.317	1.496	16.095	807	1.145	173	125	7.083	796	14.702	3.826
2005	3.582	1.179	3.963	2.481	547	22.223	3.353	1.607	16.366	839	1.173	178	128	6.721	802	15.676	3.852
2006	3.614	1.219	4.008	2.524	575	22.249	3.413	1.697	16.684	882	1.169	180	130	6.804	802	16.338	3.919
2007	3.723	1.371	4.081	2.525	575	22.714	3.398	1.844	16.846	910	1.219	188	133	6.974	826	16.910	4.019
2008	3.804	1.399	4.152	2.515	583	23.119	3.362	1.814	17.136	909	1.235	189	136	7.113	853	16.801	4.065
2009	3.760	1.386	4.059	2.415	526	22.796	3.256	1.648	16.958	779	1.138	198	136	7.065	819	15.815	3.963
2010	3.830	1.318	3.974	2.375	503	22.705	3.252	1.578	16.763	736	1.094	202	138	6.969	796	15.522	3.964
2011	3.852	1.267	3.947	2.368	532	22.667	3.282	1.553	16.866	747	1.099	204	143	6.972	776	15.325	4.073
2012	3.863	1.253	3.941	2.347	539	22.726	3.360	1.547	16.861	758	1.109	214	149	6.984	772	14.503	4.089
2013	3.833	1.243	4.001	2.345	542	22.742	3.439	1.590	16.588	769	1.118	216	155	6.866	750	14.010	4.122
2014	3.866	1.315	4.024	2.369	545	23.163	3.622	1.636	16.684	762	1.136	222	163	6.774	744	14.230	4.175
2015	3.846	1.331	4.102	2.407	556	23.222	3.732	1.696	16.878	761	1.145	231	169	6.828	764	14.711	4.238
2016	3.895	1.363	4.180	2.451	554	23.278	3.862	1.763	17.183	753	1.160	233	177	6.910	782	15.161	4.319
2017	3.960	1.416	4.248	2.491	562	23.509	3.940	1.830	17.499	754	1.154	243	185	7.052	815	15.636	4.412
2018	4.071	1.447	4.300	2.535	564	23.693	3.972	1.889	17.679	773	1.171	255	202	7.198	827	16.149	4.483
2019	4.124	1.460	4.316	2.567	566	23.643	3.980	1.951	17.796	769	1.172	262	212	7.321	844	16.572	4.502

Tablica 37. Podaci o stopi nezaposlenosti (%) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	9,5	7,0	3,0	7,3	7,7	9,8		12,1	11,4			2,9		7,1	7,2	22,9	
1996	9,5	7,6	3,1	6,8	9,8	9,8		11,6	11,7			2,9		6,4	6,9	22,1	9,6
1997	9,3	8,0	4,3	5,7	10,2	10,6	9,1	9,9	11,7	14,4	13,1	2,5	6,3	5,5	6,9	20,6	10,1
1998	9,3	8,3	6,5	5,4	10,0	10,6	8,5	7,8	11,9	14,0	13,4	2,6	6,4	4,4	7,4	18,6	8,8
1999	8,6	9,3	8,8	5,6	12,4	10,2	7,0	5,9	11,4	14,0	14,4	2,4	6,4	3,6	7,4	15,7	7,3
2000	7,0	15,6	8,8	4,6	14,6	9,2	6,4	4,5	10,6	14,3	16,4	2,4	6,6	2,9	6,8	13,9	5,5
2001	6,6	16,0	8,2	4,6	13,0	8,0	5,7	4,2	9,6	13,7	17,3	2,3	6,9	2,3	6,2	10,6	4,9
2002	7,5	15,0	7,3	4,6	11,2	7,9	5,8	4,7	9,0	12,5	13,7	2,9	6,9	2,8	6,3	11,5	5,1
2003	8,2	14,2	7,8	5,4	10,3	8,5	5,9	4,8	8,7	11,6	12,5	3,7	7,6	3,7	6,7	11,5	5,7
2004	8,4	13,7	8,3	5,5	10,1	8,9	6,1	4,7	8,0	11,7	10,9	5,1	7,2	4,6	6,3	11,0	6,5
2005	8,5	12,7	7,9	4,8	8,0	8,9	7,2	4,6	7,7	10,0	8,3	4,5	6,9	5,9	6,5	9,2	7,5
2006	8,3	11,3	7,2	3,9	5,9	8,8	7,5	4,8	6,8	7,0	5,8	4,7	6,8	5,0	6,0	8,5	7,1
2007	7,5	9,9	5,3	3,8	4,6	8,0	7,4	5,0	6,1	6,1	4,3	4,1	6,5	4,2	4,9	8,2	6,2
2008	7,0	8,6	4,4	3,7	5,5	7,4	7,8	6,8	6,7	7,7	5,8	5,1	6,0	3,7	4,4	11,3	6,2
2009	7,9	9,2	6,7	6,4	13,5	9,1	10,0	12,6	7,8	17,5	13,8	5,1	6,9	4,4	5,9	17,9	8,4
2010	8,3	11,7	7,3	7,7	16,7	9,3	11,2	14,6	8,4	19,5	17,8	4,4	6,9	5,0	7,3	19,9	8,6
2011	7,2	13,7	6,7	7,8	12,3	9,2	11,0	15,4	8,4	16,2	15,4	4,9	6,4	5,0	8,2	21,4	7,8
2012	7,6	16,0	7,0	7,8	10,0	9,8	11,0	15,5	10,7	15,0	13,4	5,1	6,2	5,8	8,9	24,8	8,0
2013	8,4	17,3	7,0	7,4	8,6	10,3	10,2	13,8	12,2	11,9	11,8	5,9	6,1	7,3	10,1	26,1	8,1
2014	8,5	17,3	6,1	6,9	7,4	10,3	7,7	11,9	12,7	10,8	10,7	5,9	5,7	7,4	9,7	24,5	8,0
2015	8,5	16,2	5,1	6,3	6,2	10,4	6,8	10,0	11,9	9,9	9,1	6,7	5,4	6,9	9,0	22,1	7,4
2016	7,8	13,1	4,0	6,0	6,8	10,0	5,1	8,4	11,7	9,6	7,9	6,3	4,7	6,0	8,0	19,6	7,0
2017	7,1	11,2	2,9	5,8	5,8	9,4	4,2	6,7	11,2	8,7	7,1	5,5	4,0	4,9	6,6	17,2	6,7
2018	6,0	8,5	2,2	5,1	5,4	9,0	3,7	5,8	10,6	7,4	6,2	5,6	3,7	3,8	5,1	15,3	6,4
2019	5,4	6,6	2,0	5,0	4,4	8,5	3,4	5,0	10,0	6,3	6,3	5,6	3,4	3,4	4,5	14,1	6,8

Tablica 38. Podaci o stopi nezaposlenosti mladih (%) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	-0,3		4,2	-3,4				-6,4	4,5						-2,7		
1996	0,9		3,7	-3,4				-6,4	4,5			2,6		0,8	-1,9	-0,5	
1997	-0,7		4,2	-2,4				-6,9	2,3			-0,6		-1,7	-0,3	-5,4	
1998	-0,5		5,7	-2,1				-7,9	0,5			-0,8		-3,3	1,1	-7,1	
1999	0,1		7,9	-0,6				-9,2	-1,5			-0,9		-4,3	0,8	-12,5	-5,7
2000	-3,6		9,3	-1,6	6,3		-4,6	-8,5	-3,0	-5,2	4,7	0,6	1,5	-4,0	-0,4	-12,9	-9,6
2001	-4,0		4,6	0,3	6,2		-3,8	-4,0	-5,6	-2,9	7,6	1,1	3,3	-4,1	0,3	-14,1	-5,6
2002	-3,3		-1,1	-2,1	-3,2		-0,1	-0,2	-5,7	-3,6	-3,3	1,1	1,8	-2,0	-1,1	-7,2	-2,7
2003	4,3	-2,7	0,5	2,5	-3,0		0,9	2,0	-4,0	-2,6	-4,6	2,8	3,1	0,5	1,0	-3,3	2,5
2004	4,2	-5,5	3,4	-0,2	1,7		4,2	1,5	-4,7	-2,9	-9,6	8,2	1,3	3,4	-1,7	0,9	5,3
2005	3,8	-4,4	2,3	1,2	-2,8		6,7	0,2	-3,1	-5,2	-7,2	4,7	2,0	6,8	-0,6	-2,6	9,1
2006	-1,3	-6,3	-1,1	-1,5	-8,8	3,1	5,7	-0,1	-5,3	-6,0	-15,1	5,3	-0,9	3,7	-3,4	-4,8	7,8
2007	-2,4	-7,6	-10,3	-0,7	-13,8	-1,0	2,5	0,4	-3,1	-9,4	-13,4	-1,7	-3,1	1,4	-6,0	-3,9	2,3
2008	-3,5	-8,0	-9,3	0,9	-3,1	-1,9	0,1	4,8	-2,9	-1,5	-2,5	4,2	-4,4	-3,2	-5,5	4,9	-1,7
2009	1,4	-3,5	-0,9	5,8	15,3	1,6	7,3	15,7	3,5	19,7	19,6	1,0	-1,0	0,2	-0,3	19,8	3,5
2010	3,6	7,2	7,6	8,1	22,8	3,9	8,4	18,9	7,5	25,6	27,3	-1,0	-0,3	1,7	4,6	23,4	5,5
2011	0,7	13,0	8,2	6,9	10,4	3,7	6,5	16,1	8,0	17,4	19,3	-1,1	1,6	1,4	5,3	21,7	2,6
2012	-2,1	16,9	2,9	2,3	-6,5	0,8	1,8	6,3	10,0	-4,8	-2,9	1,6	-0,7	1,5	7,0	15,2	-1,4
2013	1,3	17,6	0,7	-0,8	-14,2	1,6	0,2	-1,4	12,1	-13,0	-13,8	1,3	-0,5	2,1	6,9	14,0	-1,3
2014	4,5	8,8	-2,2	-2,2	-7,4	1,5	-5,6	-6,2	13,5	-11,4	-13,3	5,8	-1,6	2,7	4,5	7,0	0,1
2015	2,3	0,2	-6,9	-3,6	-7,8	0,3	-10,9	-10,6	5,0	-12,2	-10,4	-1,5	-2,2	-0,4	-4,3	-4,6	-3,2
2016	-3,6	-18,7	-8,5	-2,6	-5,3	-0,4	-13,7	-9,9	-2,2	-5,9	-7,4	3,4	-2,0	-2,4	-6,4	-11,1	-4,6
2017	-3,9	-18,1	-8,0	-1,8	-2,9	-2,1	-9,7	-9,0	-8,0	-2,6	-6,0	-7,2	-1,1	-3,8	-9,0	-14,6	-5,0
2018	-6,3	-18,6	-5,9	-1,7	-1,3	-3,9	-7,1	-6,4	-8,1	-4,1	-5,2	-3,1	-2,5	-4,1	-7,5	-14,0	-3,0
2019	-5,9	-14,7	-4,9	-2,1	-2,3	-4,9	-1,5	-4,3	-8,6	-4,9	-2,6	-1,9	-1,5	-4,1	-7,1	-11,9	1,2

Tablica 39. Podaci o srednjem ekvivalentu neto prihoda (euro) korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	13.405					12.653		7.955	7.702			18.679		11.351		6.173	
1996	14.111					13.191		8.244	7.355			20.164		11.855		6.247	
1997	14.089					13.353		9.173	8.295			20.585		12.393		6.619	
1998	14.027					13.557		10.802	8.860			20.808		12.249		6.796	
1999	14.200					13.814		11.095	9.340			21.270		12.782		7.485	
2000	14.778					14.104		12.127	9.968			22.121		13.326		8.236	
2001	15.492					14.889		14.271	10.399			23.114		13.820		9.034	
2003	15.522			20.923				17.079				25.780					
2004	15.674			21.225	2.564	15.242		18.075	13.631			26.941		17.000		10.327	17.329
2005	16.581		4.233	22.124	2.980	15.946	3.447	18.798	14.307	2.080	2.058	28.396	8.591	17.263	8.797	10.453	17.498
2006	17.213		4.802	22.663	3.639	16.209	3.849	19.757	14.560	2.530	2.534	29.480	9.030	18.244	9.317	11.138	17.991
2007	17.566		5.423	23.341	4.448	16.441	3.936	22.065	15.106	3.365	3.276	29.892	9.304	19.522	9.907	11.645	18.845
2008	17.985		6.068	24.161	5.547	18.899	4.400	22.995	15.640	4.740	4.111	30.917	10.009	20.156	10.893	13.966	20.217
2009	19.313		7.295	25.029	6.209	19.644	4.739	22.445	15.605	5.355	4.715	31.764	10.503	20.292	11.864	14.795	20.477
2010	19.464	5.810	7.058	25.668	5.727	19.960	4.241	20.512	15.964	4.488	4.030	32.333	10.435	20.310	11.736	14.605	18.897
2011	20.008	5.579	7.451	26.944	5.598	19.995	4.493	19.726	15.971	4.195	3.857	32.538	10.862	20.562	11.999	13.929	21.584
2012	20.280	5.377	7.791	27.184	5.987	20.603	4.696	19.648	15.979	4.450	4.337	32.779	11.449	20.839	12.122	13.868	23.852
2013	21.483	5.078	7.694	27.444	6.579	20.924	4.449	19.856	15.733	4.666	4.698	33.301	12.043	20.891	11.852	13.524	25.401
2014	21.705	5.225	7.622	27.861	7.217	21.199	4.512	20.171	15.759	5.203	4.823	34.320	12.808	21.292	11.909	13.269	25.838
2015	21.654	5.453	7.423	28.364	7.889	21.415	4.556	21.629	15.846	5.828	5.180	35.270	13.551	22.733	12.332	13.352	25.306
2016	22.295	5.726	7.838	28.665	8.645	21.713	4.768	22.544	16.247	6.365	5.645	32.841	13.617	23.561	12.327	13.681	25.164
2017	22.733	6.210	8.282	29.383	9.384	21.960	4.988	22.879	16.542	6.607	6.134	36.315	14.522	24.016	12.713	14.203	25.376
2018	23.686	6.659	9.088	30.104	10.524	22.220	5.424	24.920	16.844	7.333	6.895	34.472	14.781	24.612	13.244	14.785	25.540
2019	24.608	7.306	9.995	30.717	11.461	22.562	5.852	25.528	17.165	8.187	7.586	36.354	15.354	25.674	14.067	15.015	24.474



Tablica 40. Podaci o uvozu roba i usluga (u milijunima eura) u 17 država EU-a od 1995. do 2019. korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	123.923	6.219	19.911	45.124	2.187	257.475	13.903	33.095	188.751	1.626	2.448	13.560	3.755	175.068	7.791	107.893	64.315
1996	127.625	7.047	22.809	46.429	2.703	269.134	15.221	38.186	198.213	2.325	3.383	14.396	3.730	182.237	8.029	117.541	70.102
1997	135.832	9.329	24.351	51.161	3.673	288.674	19.595	47.633	224.070	2.803	4.912	16.498	3.886	198.575	8.922	132.794	77.801
1998	139.845	8.222	25.344	53.948	4.216	314.074	23.658	59.174	238.590	3.286	5.066	19.271	4.153	208.303	9.732	146.964	82.870
1999	146.855	8.016	26.412	55.683	4.015	331.818	26.879	68.118	251.718	3.160	4.364	22.621	4.498	228.592	10.282	168.500	89.441
2000	178.650	9.336	33.486	67.890	4.003	403.155	36.148	87.409	307.620	3.863	5.587	28.495	5.664	268.893	11.767	204.196	108.982
2001	179.655	10.969	37.971	70.699	4.556	410.599	39.709	97.203	318.024	4.534	6.773	29.455	5.152	273.421	12.273	211.248	101.900
2002	178.310	13.020	40.474	73.740	5.113	405.547	43.185	99.646	319.342	4.745	8.044	29.330	5.239	267.151	12.818	213.961	102.025
2003	179.066	14.244	42.774	71.625	5.738	402.544	45.472	95.631	318.641	5.099	8.660	30.169	5.324	269.922	13.471	223.309	103.470
2004	195.937	15.235	54.487	77.486	6.737	433.778	53.279	103.307	340.140	6.357	10.172	35.806	5.378	290.760	15.647	250.201	111.357
2005	217.790	16.606	65.625	89.278	7.997	475.870	59.043	116.912	368.927	7.898	13.082	40.871	5.875	314.965	17.605	276.195	122.319
2006	236.588	18.674	77.431	105.180	9.956	520.594	69.011	131.267	419.143	10.485	16.187	48.803	7.047	348.337	20.434	310.541	137.315
2007	254.851	20.342	88.514	113.390	11.709	554.598	79.149	142.994	447.317	13.062	18.784	55.626	7.705	381.919	24.281	341.622	149.148
2008	282.126	22.385	98.520	122.383	11.682	583.323	85.404	141.785	452.498	12.737	22.610	59.652	9.329	396.514	25.948	336.850	154.293
2009	230.654	17.250	81.453	98.591	7.900	496.245	66.416	135.676	363.078	8.363	14.403	48.773	9.260	341.492	20.251	255.923	119.735
2010	269.260	17.081	98.678	105.964	10.117	560.267	75.679	144.925	433.952	9.928	18.487	56.907	10.284	394.496	22.988	289.380	148.265
2011	303.768	18.182	110.753	117.559	13.473	625.111	81.718	145.143	466.154	12.923	23.665	62.787	11.018	435.537	25.582	311.238	167.284
2012	310.259	18.085	115.246	123.752	15.149	637.065	79.336	152.399	443.052	14.758	25.932	68.558	11.751	455.542	25.193	303.041	173.110
2013	308.515	18.555	112.204	124.769	15.485	643.611	80.190	152.456	423.095	14.760	27.057	73.755	11.786	460.137	25.350	296.245	169.180
2014	318.301	18.955	119.346	126.635	15.713	662.388	85.860	179.164	426.597	15.139	25.772	89.782	12.062	466.572	26.117	313.601	174.074
2015	318.307	20.595	126.519	132.769	15.164	685.011	89.759	244.886	442.016	15.229	26.058	97.449	14.480	518.594	26.866	329.593	182.002
2016	336.479	21.676	126.832	132.334	15.963	689.287	90.368	285.882	441.578	15.034	26.004	97.459	14.734	491.044	27.930	332.955	184.778
2017	365.579	24.260	138.816	141.219	17.102	735.421	100.479	294.028	483.996	16.790	30.134	103.662	15.558	536.163	31.892	366.489	197.771
2018	383.301	26.519	149.800	152.436	18.555	773.362	108.051	307.110	513.236	18.129	33.388	105.420	15.863	573.832	34.996	390.484	204.499
2019	386.775	28.318	153.101	159.411	19.369	794.444	115.490	405.076	509.227	18.572	35.252	109.733	17.380	590.651	36.432	396.875	206.321

Tablica 41. Podaci o izvozu roba i usluga (u milijunima eura) u 17 država EU-a od 1995. do 2019. korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	132.403	4.784	18.500	51.785	1.969	277.067	13.900	38.878	221.633	1.430	1.903	16.917	3.606	197.985	7.425	102.621	75.855
1996	134.602	5.812	20.244	54.802	2.310	291.677	15.395	44.721	245.050	1.901	2.770	18.276	3.435	203.688	7.817	116.627	82.784
1997	144.495	6.606	22.080	57.835	3.205	327.312	19.996	56.393	264.755	2.283	4.013	20.175	3.687	222.041	8.714	133.696	92.604
1998	148.253	6.683	25.157	58.809	3.732	350.964	22.976	67.936	273.003	2.512	3.923	22.786	3.919	232.294	9.397	144.432	96.638
1999	156.441	6.687	26.119	65.701	3.778	365.332	25.618	80.227	272.643	2.468	3.337	27.305	4.312	251.277	9.363	156.982	103.130
2000	185.994	8.272	32.237	79.836	3.803	422.801	34.257	102.408	318.172	3.175	4.815	34.270	5.306	298.475	10.963	185.048	123.352
2001	189.295	9.623	36.987	83.841	4.280	434.786	38.935	116.259	334.498	3.562	6.026	35.049	4.960	305.023	12.031	195.308	116.111
2002	193.551	10.311	39.315	86.745	4.534	437.146	41.717	123.009	329.564	3.716	7.183	35.626	5.376	301.426	13.066	199.036	116.988
2003	194.131	11.028	41.429	84.763	4.999	425.799	42.499	117.685	324.994	3.785	7.696	36.375	5.186	304.015	13.387	205.612	119.487
2004	210.464	12.354	55.092	88.921	5.972	451.034	49.963	125.751	348.699	4.562	8.886	42.751	5.064	331.726	15.246	218.400	132.419
2005	230.305	13.400	68.193	100.994	7.423	477.378	56.945	135.441	367.451	5.926	11.566	48.553	5.337	361.556	17.418	231.647	142.148
2006	249.733	15.242	80.823	114.412	8.585	516.282	67.972	146.148	406.392	6.901	13.719	59.586	6.667	398.550	20.419	253.378	160.183
2007	269.060	16.641	91.882	120.152	10.267	540.732	79.699	159.305	441.837	8.720	14.982	67.996	7.484	425.837	23.815	279.476	170.895
2008	284.492	17.472	102.022	130.896	11.033	560.245	85.789	157.942	439.932	9.631	18.819	71.343	9.216	451.703	25.150	284.308	174.200
2009	238.491	14.720	87.277	108.992	8.601	480.921	70.220	158.596	353.292	7.988	13.930	60.667	9.203	388.883	20.761	246.604	136.723
2010	275.442	16.319	103.506	122.854	11.063	534.504	80.922	172.797	404.013	9.553	17.926	70.120	10.288	446.176	23.373	278.386	167.410
2011	303.396	17.411	116.999	133.409	14.443	585.016	87.930	177.303	443.061	11.756	22.824	76.829	11.120	491.041	26.033	314.182	186.900
2012	310.502	17.372	122.991	139.077	15.446	609.994	86.092	183.013	460.981	13.578	26.136	82.245	12.013	519.130	26.426	324.335	193.635
2013	311.650	17.668	121.284	141.866	15.993	621.707	87.324	186.244	461.783	13.765	27.565	88.642	12.391	527.581	27.055	336.333	187.905
2014	321.601	18.789	129.341	145.138	16.413	637.764	92.581	214.350	473.719	14.444	26.438	105.930	13.110	541.129	28.659	345.593	189.867
2015	324.216	20.690	136.594	151.301	15.976	672.558	98.722	320.565	491.905	14.805	25.686	115.168	15.457	570.353	29.974	362.356	199.355
2016	341.615	22.202	140.366	151.254	16.748	675.769	100.450	328.235	497.339	15.118	26.285	116.887	15.921	563.377	31.383	377.370	199.056
2017	370.203	24.560	153.418	162.373	18.046	710.965	109.139	359.655	533.720	16.616	31.113	123.640	17.553	615.553	35.752	408.390	209.938
2018	382.087	26.080	162.328	170.211	19.225	748.790	114.036	399.897	555.572	17.898	34.230	127.048	17.840	655.439	38.890	423.256	215.018
2019	389.709	28.183	166.595	182.398	20.496	770.689	120.046	448.866	563.839	18.317	37.794	132.592	19.290	675.153	40.526	434.336	223.644

Tablica 42. Podaci o izvozu nafte i naftnih derivata (u milijunima tona) u 17 država EU-a od 1995. do 2019. korišteni za razvoj umjetne neuronske mreže

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	17.868	2.256	986	9.096	158	15.498	2.081	1.023	17.059	47	1.698	4		55.123	85	8.585	9.739
1996	20.339	1.663	1.261	9.963	194	18.193	1.875	878	18.784	132	2.415	6		55.384	53	8.123	9.782
1997	20.331	1.758	1.216	11.292	221	19.559	1.866	1.391	20.962	64	3.323	11		58.320	70	7.899	10.131
1998	20.824	1.810	1.402	11.510	102	21.053	1.819	1.384	22.866	126	4.261	19		57.174	167	8.879	9.229
1999	21.926	1.947	1.305	15.048	70	19.338	1.889	1.185	20.354	183	2.583	27		56.562	306	6.926	9.720
2000	23.110	1.738	1.084	17.999	138	22.460	1.755	1.399	21.571	110	3.101	20		60.687	229	7.367	10.946
2001	21.628	1.641	1.275	15.836	128	19.686	2.260	1.463	22.421	1	4.921	31		62.775	158	6.223	9.985
2002	22.704	1.626	1.383	17.503	160	19.172	2.541	1.582	21.461	1	4.596	23		62.729	117	5.926	9.302
2003	23.248	1.726	1.244	17.355	165	22.539	2.470	1.636	23.826	16	5.299	18		62.436	91	6.802	10.005
2004	25.136	2.052	954	19.080	220	23.958	2.769	1.324	25.561	336	6.761	17		69.958	118	7.970	10.944
2005	25.699	1.873	1.261	17.809	238	27.327	3.143	1.458	29.392	507	6.844	15		76.028	212	8.258	10.450
2006	24.218	1.853	1.176	16.148	271	27.575	3.386	1.315	27.875	261	6.359	14		80.401	408	9.840	11.145
2007	24.890	2.021	1.020	14.074	373	26.049	3.310	1.251	31.339	142	3.875	10		76.678	428	10.714	10.532
2008	24.305	1.736	1.357	13.915	303	30.655	3.339	1.259	29.233	125	7.175	15		80.754	548	10.231	12.255
2009	23.689	1.866	1.157	13.512	396	25.246	2.327	976	26.751	260	6.786	15	9	90.282	478	11.089	11.923
2010	24.010	1.926	1.634	13.079	391	22.875	2.826	1.471	29.674	257	7.400	7	16	100.526	672	11.579	12.663
2011	24.267	1.572	1.592	13.179	432	21.367	2.985	1.629	27.068	457	7.827	6	3	99.112	710	13.054	11.507
2012	26.767	1.554	1.706	12.553	1.336	19.787	2.887	1.772	29.862	517	7.681	9	8	102.351	812	19.539	13.408
2013	27.328	1.536	1.784	13.362	746	19.028	2.982	1.241	24.452	676	8.305	8	151	101.752	935	22.278	9.916
2014	29.542	1.544	2.039	12.530	1.148	19.187	3.259	1.287	20.896	818	6.970	6	206	101.254	1.393	21.666	12.565
2015	29.223	1.854	2.493	13.478	1.101	21.203	2.877	1.772	27.924	949	8.340	7	532	111.755	1.717	23.243	15.061
2016	29.369	2.076	2.253	12.882	1.115	20.595	3.003	1.634	29.505	807	8.536	11	273	113.886	2.045	25.130	16.839
2017	33.809	2.484	2.454	10.844	1.353	20.333	3.263	1.863	31.744	750	8.258	25	152	112.385	2.081	27.578	17.884
2018	32.560	2.426	2.287	9.379	1.758	20.011	3.948	1.693	29.520	869	7.577	3	355	110.396	2.112	25.500	17.096

Tablica 43. Postotak stanovništva sa završenim osnovnoškolskim i nižim srednjoškolskim obrazovanjem u 17 država EU-a od 1995. do 2019.

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	46,0	29,7	33,5	25,7	22,2	42,2		52,8	63,5					40,5	34,4		
1996	44,0	29,8	33,5	29,3	22,2	42,6		50,1	62,0					40,5	34,4		
1997	43,2	30,0	33,5	28,4	22,2	41,7	40,5	50,5	60,4					39,0	33,5		
1998	44,4	29,8	19,6	28,0	22,2	42,4	35,3	50,5	58,5					38,9	31,5		
1999	44,4	29,5	19,0	26,6	22,2	41,1	30,0	45,9	57,0					38,8	30,6		
2000	42,3	29,1	19,7	27,8	20,7	40,1	33,1	43,7	54,9	16,8	15,8	39,1	81,9	37,3	28,5	61,4	22,8
2001	41,6	29,0	19,9	22,7	20,1	39,1	33,1	41,8	57,1	20,8	15,8	40,8	80,7	36,4	27,8	59,6	19,5
2002	40,5	29,6	18,5	22,7	21,2	38,3	32,0	40,3	56,0	17,9	15,1	38,4	81,6	35,7	26,5	57,8	18,6
2003	39,6	30,0	18,0	25,8	20,6	37,0	30,1	38,9	53,7	17,0	13,9	40,9	80,2	34,8	25,5	56,3	17,9
2004	37,8	28,8	17,6	25,3	20,3	36,3	29,3	38,3	51,8	15,7	13,4	36,8	76,4	33,3	24,4	54,6	17,1
2005	36,3	27,2	16,8	25,7	19,9	35,5	28,5	36,5	50,6	15,6	12,5	34,1	74,8	34,5	24,0	51,2	16,4
2006	35,7	25,9	16,4	25,4	20,6	35,0	27,3	34,9	49,5	15,9	12,2	34,5	73,5	33,7	22,8	50,3	21,1
2007	34,8	24,3	16,2	32,3	20,0	34,0	26,3	32,9	48,7	15,4	11,5	34,3	73,4	32,8	22,2	49,4	20,6
2008	33,6	23,3	15,8	33,2	20,4	33,0	25,8	31,4	47,9	14,1	9,6	32,1	72,2	32,8	21,9	48,9	20,0
2009	32,4	22,5	15,2	32,4	19,2	32,4	25,0	30,7	47,1	13,2	8,8	22,7	69,2	32,6	20,8	48,4	19,3
2010	32,6	22,7	14,4	32,1	18,2	31,9	24,4	29,9	46,3	11,4	8,1	22,3	67,0	31,8	20,9	47,1	18,8
2011	31,9	21,8	13,9	30,9	17,7	31,2	24,3	29,1	45,5	12,1	7,1	22,7	64,5	31,6	19,7	46,0	18,4
2012	31,4	19,5	13,4	30,1	16,8	30,4	23,5	28,2	44,2	10,9	6,7	21,7	61,9	30,8	19,0	45,3	17,6
2013	30,4	18,7	12,9	29,9	15,8	28,0	22,8	26,6	43,4	10,6	6,6	19,5	58,8	29,0	18,5	44,5	16,8
2014	29,5	17,3	12,4	28,7	17,7	26,5	22,0	24,0	42,3	10,5	6,7	18,0	55,9	28,8	18,4	43,4	16,3
2015	28,7	16,9	12,4	27,9	17,3	25,9	21,9	23,5	41,9	9,9	6,5	24,0	54,0	28,4	17,4	42,6	15,7
2016	28,2	17,3	12,4	27,3	16,7	25,4	21,8	23,0	41,6	9,3	5,4	21,6	51,6	27,9	17,2	41,7	15,0
2017	27,2	16,2	12,1	26,7	16,8	25,2	21,1	21,8	40,9	9,6	5,2	23,6	48,9	26,6	16,7	40,9	14,7
2018	26,3	14,9	12,1	26,6	16,8	24,4	20,2	21,5	40,3	9,3	5,2	21,4	46,0	26,0	16,4	39,9	14,4
2019	25,9	14,2	12,3	26,1	15,8	23,4	20,0	21,0	39,8	8,8	5,0	20,7	44,8	25,5	15,8	38,7	13,9

Tablica 44. Postotak stanovništva sa završenim srednjoškolskim ili višim obrazovanjem u 17 država EU-a od 1995. do 2019.

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	54,0	17,2	65,5	74,3	77,8	57,8		47,2	36,5					59,5	65,6		
1996	56,0	24,8	65,5	70,7	77,8	57,4		49,9	38,0					59,5	65,6		
1997	56,8	32,4	65,5	71,6	77,8	58,3	59,5	49,5	39,6					61,0	66,5		
1998	55,6	40,0	65,5	72,0	77,8	57,6	64,7	49,5	41,5					61,1	68,5		
1999	55,6	47,6	65,5	73,4	77,8	58,9	70,0	54,1	43,0					61,2	69,4		
2000	57,7	55,2	86,1	72,2	79,3	59,9	66,9	56,3	45,1	83,2	84,2	60,9	18,1	62,7	71,5	38,6	77,2
2001	58,4	62,8	86,3	77,3	79,9	60,9	66,9	58,2	42,9	79,2	84,2	59,2	19,3	63,6	72,2	40,4	80,5
2002	59,5	70,4	87,9	77,3	78,8	61,7	68,0	59,7	44,0	82,1	84,9	61,6	18,4	64,3	73,5	42,2	81,4
2003	60,4	70,0	88,5	74,2	79,4	63,0	69,9	61,1	46,3	83,0	86,1	59,1	19,8	65,2	74,5	43,7	82,1
2004	62,2	71,2	89,1	74,7	79,7	63,7	70,7	61,7	48,2	84,3	86,6	63,2	23,6	66,7	75,6	45,4	82,9
2005	63,7	72,8	89,9	74,3	80,1	64,5	71,5	63,5	49,4	84,4	87,5	65,9	25,2	65,5	76,0	48,8	83,6
2006	64,3	74,1	90,3	74,6	79,4	65,0	72,7	65,1	50,5	84,1	87,8	65,5	26,5	66,3	77,2	49,7	78,9
2007	65,2	75,7	90,5	67,7	80,0	66,0	73,7	67,1	51,3	84,6	88,5	65,7	26,6	67,2	77,8	50,6	79,4
2008	66,4	76,7	90,9	66,8	79,6	67,0	74,2	68,6	52,1	85,9	90,4	67,9	27,8	67,2	78,1	51,1	80,0
2009	67,6	77,5	91,4	67,6	80,8	67,6	75,0	69,3	52,9	86,8	91,2	77,3	30,8	67,4	79,2	51,6	80,7
2010	67,4	77,3	91,9	67,9	81,8	68,1	75,6	70,1	53,7	88,6	91,9	77,7	33,0	68,2	79,1	52,9	81,2
2011	68,1	78,2	92,3	69,1	82,3	68,8	75,7	70,9	54,5	87,9	92,9	77,3	35,5	68,4	80,3	54,0	81,6
2012	68,6	80,5	92,5	69,9	83,2	69,6	76,5	71,8	55,8	89,1	93,3	78,3	38,1	69,2	81,0	54,7	82,4
2013	69,6	81,3	92,8	70,1	84,2	72,0	77,2	73,4	56,6	89,4	93,4	80,5	41,2	71,0	81,5	55,5	83,2
2014	70,5	82,7	93,2	71,3	82,3	73,5	78,0	76,0	57,7	89,5	93,3	82,0	44,1	71,2	81,6	56,6	83,7
2015	71,3	83,1	93,2	72,1	82,7	74,1	78,1	76,5	58,1	90,1	93,5	76,0	46,0	71,6	82,6	57,4	84,3
2016	71,8	82,7	93,4	72,7	83,3	74,6	78,2	77,0	58,4	90,7	94,6	78,4	48,4	72,1	82,8	58,3	85,0
2017	72,8	83,8	93,8	73,3	83,2	74,8	78,9	78,2	59,1	90,4	94,8	76,4	51,1	73,4	83,3	59,1	85,3
2018	73,7	85,1	93,9	73,4	83,2	75,6	79,8	78,5	59,7	90,7	94,8	78,6	54,0	74,0	83,6	60,1	85,6
2019	74,1	85,8	93,8	73,9	84,2	76,6	80,0	79,0	60,2	91,2	95,0	79,3	55,2	74,5	84,2	61,3	86,1

Tablica 45. Postotak stanovništva koji imaju završeno srednjoškolsko obrazovanje ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje u 17 država EU-a od 1995. do 2019.

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	33,4	12,2	58,3	52,0	52,5	41,0		29,6	30,5					40,3	54,5		
1996	34,3	18,2	58,3	47,6	52,5	41,6		29,8	31,6					40,3	54,5		
1997	34,3	24,3	58,3	50,5	52,5	41,8	49,8	29,6	33,0					40,6	55,8		
1998	33,3	30,3	58,3	50,9	52,5	39,2	54,1	29,6	34,2					42,4	56,8		
1999	32,4	36,4	58,3	51,1	53,1	39,6	58,1	36,4	35,0					41,8	57,0		
2000	33,8	42,4	74,5	50,2	55,1	40,1	55,2	37,2	37,0	65,0	41,8	42,6	12,8	42,1	58,7	15,9	47,5
2001	34,0	48,5	74,7	53,2	55,0	40,2	55,2	37,3	34,7	61,4	62,0	41,0	9,8	42,8	60,6	16,6	55,0
2002	34,6	54,5	76,0	52,2	54,4	40,2	55,9	37,6	35,4	63,2	63,0	43,0	9,5	42,7	61,2	17,3	55,0
2003	34,8	54,1	76,5	47,0	54,5	40,8	56,8	37,6	37,2	65,0	62,8	44,8	10,6	41,4	60,1	18,0	54,9
2004	35,4	55,4	76,8	46,7	54,0	41,0	56,5	36,8	38,1	64,5	61,1	39,6	12,4	41,1	59,9	18,6	54,7
2005	36,5	56,8	76,9	45,8	52,4	41,1	56,9	37,4	38,6	64,1	61,0	39,3	13,8	41,0	59,4	20,2	53,9
2006	36,4	57,9	76,8	45,3	52,0	41,1	57,7	36,9	39,1	63,2	61,7	41,5	14,6	41,5	59,4	20,9	48,4
2007	37,1	59,9	76,8	41,7	52,5	41,6	58,3	36,7	39,3	62,5	60,2	39,2	14,2	41,7	59,3	21,4	48,0
2008	38,0	60,5	76,4	40,7	51,3	42,3	57,8	36,9	39,5	61,0	60,2	40,3	14,6	40,9	59,2	21,6	47,9
2009	38,1	60,3	75,9	41,0	50,6	41,8	58,1	36,7	40,1	60,9	60,4	42,5	16,9	40,6	59,6	21,6	47,6
2010	36,7	58,7	75,2	40,5	51,8	41,9	58,5	36,2	40,7	61,7	59,5	42,2	18,1	40,5	58,9	21,9	47,3
2011	37,7	60,3	74,1	41,3	51,0	42,0	57,7	36,5	41,4	60,2	59,4	40,2	19,3	40,4	58,8	22,1	46,8
2012	37,4	62,0	73,2	41,4	51,1	41,9	57,5	36,1	41,9	59,9	59,3	39,2	20,3	40,6	58,0	22,0	46,7
2013	38,1	61,5	72,4	41,2	51,9	43,1	57,8	36,1	42,2	58,3	58,2	39,8	21,7	41,6	57,1	21,7	46,2
2014	37,8	61,3	71,7	41,9	49,7	43,7	57,7	38,1	42,7	59,3	56,6	36,0	22,9	41,4	56,5	21,9	45,0
2015	38,7	60,4	71,0	41,9	49,5	43,6	57,2	37,5	42,7	58,5	54,8	34,9	24,3	41,1	55,9	22,4	44,5
2016	38,6	59,7	70,5	41,7	49,3	43,6	57,6	37,6	42,7	57,4	54,9	35,8	26,2	41,1	55,6	22,6	43,9
2017	37,1	60,1	69,9	41,2	48,4	43,4	58,0	37,8	42,6	56,5	54,5	36,4	27,2	41,3	54,6	22,7	43,4
2018	37,7	59,7	69,6	41,0	47,3	42,8	58,1	38,0	42,6	56,7	53,1	34,5	27,2	40,9	54,9	22,9	42,4
2019	38,1	60,5	69,5	40,8	47,7	42,9	57,6	38,3	42,8	55,4	51,8	32,3	26,7	39,7	54,9	22,7	42,1

Tablica 46. Postotak stanovništva koji ima visoko obrazovanje u 17 država EU-a od 1995. do 2019.

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	20,5	5,0	7,2	22,3	25,3	16,7		17,7	6,0					19,3	11,0		
1996	21,7	6,6	7,2	23,1	25,3	15,8		20,1	6,4					19,3	11,0		
1997	22,5	8,2	7,2	21,1	25,3	16,5	9,6	19,8	6,7					20,5	10,7		
1998	22,3	9,7	7,2	21,2	25,3	18,5	10,6	19,8	7,3					18,7	11,7		
1999	23,1	11,3	7,2	22,3	24,7	19,2	11,8	17,6	7,9					19,4	12,5		
2000	23,8	12,8	11,5	22,0	24,1	19,8	11,7	19,2	8,1	18,2	42,4	18,3	5,4	20,6	12,9	22,7	29,7
2001	24,4	14,4	11,7	24,1	24,8	20,7	11,7	20,9	8,3	17,8	22,2	18,1	9,5	20,8	11,6	23,7	25,5
2002	24,9	15,9	11,9	25,1	24,4	21,5	12,1	22,0	8,6	18,9	21,9	18,6	8,8	21,6	12,3	24,9	26,4
2003	25,6	15,9	12,0	27,2	24,8	22,2	13,1	23,5	9,1	17,9	23,2	14,3	9,2	23,8	14,4	25,6	27,2
2004	26,8	15,8	12,3	27,9	25,6	22,7	14,2	24,9	10,0	19,8	25,6	23,7	11,2	25,7	15,7	26,7	28,1
2005	27,2	16,0	13,1	28,5	27,7	23,4	14,5	26,1	10,8	20,3	26,5	26,5	11,5	24,5	16,7	28,5	29,6
2006	27,9	16,2	13,5	29,3	27,4	24,0	15,0	28,1	11,4	20,9	26,1	24,0	11,9	24,8	17,8	28,8	30,5
2007	28,1	15,8	13,7	26,0	27,5	24,4	15,4	30,3	12,0	22,2	28,2	26,5	12,4	25,5	18,5	29,3	31,3
2008	28,4	16,2	14,5	26,0	28,3	24,8	16,4	31,7	12,7	24,8	30,2	27,7	13,3	26,3	19,0	29,5	32,0
2009	29,4	17,2	15,5	26,6	30,2	25,9	16,9	32,6	12,8	25,8	30,8	34,8	13,9	26,8	19,6	30,0	33,1
2010	30,7	18,6	16,8	27,3	30,0	26,2	17,1	33,9	13,0	26,9	32,4	35,5	14,9	27,7	20,2	31,0	33,9
2011	30,4	18,0	18,2	27,8	31,3	26,7	18,0	34,4	13,2	27,7	33,5	37,0	16,2	28,0	21,6	31,9	34,8
2012	31,3	18,5	19,3	28,5	32,1	27,7	19,0	35,7	13,9	29,2	34,1	39,1	17,8	28,6	23,0	32,6	35,7
2013	31,5	19,8	20,5	28,9	32,3	28,9	19,5	37,3	14,4	31,0	35,2	40,7	19,6	29,3	24,4	33,7	37,0
2014	32,6	21,3	21,5	29,4	32,6	29,8	20,2	38,0	15,0	30,2	36,7	45,9	21,2	29,7	25,1	34,7	38,7
2015	32,7	22,7	22,2	30,2	33,3	30,5	20,9	39,0	15,5	31,6	38,7	41,1	21,6	30,5	26,6	35,1	39,8
2016	33,2	23,0	23,0	30,9	34,1	31,0	20,6	39,5	15,7	33,4	39,7	42,6	22,1	31,0	27,2	35,7	41,1
2017	35,6	23,7	23,9	32,1	34,7	31,4	20,9	40,4	16,5	33,9	40,3	39,9	23,9	32,1	28,7	36,4	41,9
2018	36,0	25,4	24,3	32,4	35,9	32,8	21,7	40,5	17,1	33,9	41,7	44,1	26,8	33,0	28,7	37,3	43,2
2019	36,0	25,3	24,2	33,1	36,5	33,7	22,5	40,7	17,4	35,7	43,1	47,0	28,6	34,8	29,3	38,6	44,0

Tablica 47. Dolasci u turističke smještajne objekte u Belgiji, Hrvatskoj, Češkoj, Danskoj, Estoniji, Francuskoj, Mađarskoj, Irskoj, Italiji i Latviji od 1995. do 2019. godine

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija
1995	9.349.104	2.502.884	6.885.245	5.024.542		97.416.521	5.143.427	4.818.000	67.168.685	340.550
1996	9.702.705	3.801.541	9.964.895	5.024.542		98.567.720	5.311.470	5.289.000	69.410.988	366.205
1997	9.981.982	4.796.858	11.220.662	5.077.550		99.718.920	5.349.780	5.587.000	70.635.012	453.095
1998	10.079.663	5.007.940	11.622.985	5.031.979		100.870.119	6.220.697	6.724.000	72.313.561	468.285
1999	10.415.531	4.440.849	11.447.197	5.050.492		104.875.565	6.337.586	7.164.000	74.320.938	462.926
2000	10.723.864	5.921.998	10.863.772	5.126.675		114.110.689	6.731.870	6.646.000	80.031.637	513.567
2001	10.806.622	6.464.933	11.283.185	5.119.424		117.985.948	6.072.820	6.353.000	81.773.368	584.969
2002	11.067.758	6.772.646	10.415.255	5.231.383	1.401.627	118.062.974	6.175.880	6.476.000	82.030.312	666.218
2003	11.072.093	7.180.065	11.346.482	5.239.262	1.561.501	116.021.323	6.315.494	6.764.000	82.724.652	759.476
2004	11.157.880	7.620.847	12.219.689	5.356.366	1.922.126	120.304.154	6.616.443	6.953.000	85.956.568	901.420
2005	11.319.300	7.975.696	12.361.793	5.525.101	2.072.586	125.301.325	7.064.007	7.333.000	88.268.463	1.154.657
2006	11.800.373	8.163.542	12.724.926	5.790.165	2.259.087	124.401.921	7.182.550	8.001.000	93.044.399	1.329.890
2007	12.112.478	8.620.730	12.960.921	6.083.055	2.343.044	127.005.145	7.474.329	8.332.000	96.150.083	1.487.379
2008	12.429.534	8.673.601	12.835.886	6.040.169	2.377.671	126.255.594	7.651.250	8.026.000	95.546.086	1.555.936
2009	12.243.246	8.329.470	11.985.909	5.587.055	2.147.133	124.039.307	7.150.612	7.189.000	95.499.801	1.113.898
2010	12.988.051	7.919.729	12.211.878	5.839.785	2.401.763	125.864.400	7.304.010	7.134.000	98.813.845	1.311.538
2011	13.618.136	8.520.950	12.898.712	6.164.984	2.725.937	148.791.996	7.586.727	7.630.000	103.723.869	1.584.996
2012	13.872.644	11.543.653	15.098.817	6.281.712	2.839.895	148.855.084	8.808.152	7.550.000	103.733.157	1.644.758
2013	14.152.360	12.205.708	15.407.671	6.437.015	2.980.865	153.694.338	9.317.445	8.260.000	103.862.530	1.839.241
2014	14.641.070	12.882.822	15.587.076	6.708.461	3.087.070	152.958.605	10.132.916	8.813.000	106.552.352	2.098.381
2015	15.846.926	14.157.026	17.195.550	7.164.604	3.112.143	157.492.941	10.913.250	9.528.000	113.392.137	2.139.393
2016	15.210.781	15.446.591	18.388.853	7.518.778	3.324.914	157.263.479	11.648.144	10.100.000	116.944.243	2.303.643
2017	16.319.257	17.409.937	20.000.561	7.673.208	3.544.932	166.830.634	12.459.373	10.338.000	123.195.556	2.577.338
2018	17.559.915	18.648.937	21.247.150	7.966.674	3.591.495	171.475.894	13.116.056	11.040.984	128.100.932	2.808.808
2019	18.057.611	19.553.495	21.998.366	8.279.387	3.789.955	174.628.055	13.454.090	11.206.599	131.381.653	2.853.333



Tablica 48. Dolasci u turističke smještajne objekte u Litvi, Luksemburgu, Malti, Nizozemskoj, Sloveniji, Španjolskoj i Švedskoj od 1995. do 2019.

Godina	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	523.859	792.685		17.282.000	1.535.236	41.549.956	
1996	515.765	751.430		17.662.000	1.616.368	42.977.619	16.581.521
1997	566.464	807.422		19.784.000	1.778.064	45.521.415	16.474.527
1998	601.039	821.489		23.745.000	1.751.660	50.149.544	13.740.099
1999	556.222	903.564		25.570.000	1.706.259	63.787.789	14.215.330
2000	517.810	890.267		25.875.000	1.884.327	74.408.937	18.013.505
2001	571.942	878.666		25.186.000	2.020.158	74.941.665	18.652.461
2002	635.330	934.642		25.164.300	2.089.519	76.128.824	19.222.349
2003	716.418	918.551		24.942.300	2.168.735	79.897.616	19.661.566
2004	956.858	932.795	1.159.227	25.672.800	2.267.272	83.734.765	20.806.061
2005	1.152.505	974.104	1.135.771	26.193.900	2.327.394	87.559.070	22.565.030
2006	1.340.927	967.881	1.148.012	28.503.200	2.410.575	99.890.611	21.613.354
2007	1.550.636	979.214	1.193.033	30.260.200	2.604.752	101.781.393	23.089.281
2008	1.591.128	936.646	1.221.378	29.102.000	2.941.948	100.147.418	22.456.293
2009	1.247.951	907.531	1.116.457	28.959.700	2.835.169	93.674.522	22.804.713
2010	1.361.422	854.717	1.276.983	30.008.300	2.851.020	98.800.631	23.431.900
2011	1.576.910	934.995	1.342.460	30.666.800	3.045.139	103.083.343	23.824.238
2012	2.238.245	1.021.673	1.350.986	31.150.585	3.255.882	100.409.178	23.874.536
2013	2.460.250	1.044.336	1.460.645	34.050.183	3.340.320	101.673.090	24.607.973
2014	2.673.531	1.142.892	1.554.679	35.856.074	3.474.852	107.545.009	25.852.368
2015	2.805.808	1.196.117	1.586.068	37.318.438	3.878.223	114.448.411	28.056.573
2016	3.064.514	1.161.784	1.619.532	38.883.066	4.263.811	123.541.778	29.074.804
2017	3.253.204	1.155.958	1.829.467	42.235.134	4.891.986	129.392.382	29.873.967
2018	3.620.390	1.139.037	1.982.579	43.912.615	5.900.000	130.803.657	30.736.850
2019	4.037.749		2.022.912	45.916.002	6.221.841	135.008.823	31.897.702

Tablica 49. Noćenja u turističkim smještajnim objektima u Belgiji, Hrvatskoj, Češkoj, Danskoj, Estoniji, Francuskoj, Mađarskoj, Irskoj, Italiji i Latviji od 1995. do 2019. godine

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija
1995	13.882.027	8.202.576	10.274.976	9.651.070		87.548.126	10.568.798	14.368.000	113.000.571	667.787
1996	14.440.943	14.640.480	13.640.529	10.810.187		89.230.742	11.354.970	17.065.000	118.023.647	697.163
1997	14.762.402	20.293.549	14.932.493	10.918.596		90.913.357	10.941.388	17.420.000	118.359.759	762.962
1998	14.838.367	21.337.500	16.218.000	10.287.564		92.595.973	10.871.690	17.051.000	121.242.294	732.879
1999	15.365.791	17.901.802	16.125.000	9.965.684		99.343.032	10.608.761	18.041.000	126.668.423	723.967
2000	15.526.188	26.633.622	15.597.087	10.005.887		108.838.468	11.210.445	20.776.000	140.356.985	697.010
2001	15.373.338	29.757.532	17.254.881	9.745.743		110.261.514	10.894.493	21.255.000	146.672.273	846.555
2002	15.903.329	30.285.645	15.569.156	9.578.670	1.997.588	113.241.419	10.360.969	19.956.900	145.559.930	871.430
2003	15.929.415	30.982.541	16.510.618	9.843.468	2.267.873	103.744.880	10.040.338	20.534.000	139.653.425	982.542
2004	15.544.514	31.751.027	18.980.462	9.565.867	2.746.806	104.177.904	10.508.109	20.236.000	141.169.236	1.200.569
2005	15.553.279	33.120.436	19.595.035	9.355.831	2.982.459	107.951.866	10.778.899	19.427.000	148.290.126	1.612.671
2006	16.039.090	32.858.014	20.090.348	9.453.026	3.020.367	105.865.432	10.045.891	21.652.000	156.861.341	1.872.393
2007	16.271.311	33.701.925	20.610.186	9.327.579	2.915.456	108.567.043	10.170.808	22.258.000	163.465.680	1.935.984
2008	16.360.702	33.902.735	19.987.022	8.918.197	2.932.662	106.993.811	10.009.531	21.535.000	161.797.434	2.115.618
2009	15.451.017	33.357.844	17.746.893	8.299.403	2.740.696	98.705.212	9.220.148	17.844.544	159.493.866	1.699.562
2010	16.169.676	33.234.882	18.365.947	8.981.992	3.203.721	120.390.105	9.358.373	17.496.163	165.202.498	1.912.336
2011	16.723.867	35.389.002	19.424.839	9.491.137	3.748.865	123.227.704	9.920.339	19.032.942	176.474.062	2.257.021
2012	16.432.646	57.079.967	21.793.985	9.608.124	3.823.039	125.038.453	11.392.183	11.839.245	180.594.988	2.429.093
2013	16.511.721	59.378.896	22.144.896	9.914.273	3.909.326	132.251.136	11.982.883	10.871.806	184.793.382	2.639.434
2014	17.068.872	61.072.661	22.110.112	10.608.119	3.919.299	130.908.700	12.351.330	11.276.424	186.792.507	2.875.934
2015	18.852.087	65.683.010	23.286.515	11.171.416	3.770.207	130.464.997	12.962.395	13.462.348	192.625.026	2.873.885
2016	17.063.194	72.064.582	24.268.149	11.630.004	4.014.581	123.913.410	13.802.045	16.190.381	199.421.814	3.044.532
2017	18.656.843	80.176.804	26.257.013	11.914.787	4.150.419		14.941.781	18.000.000	210.658.786	3.406.527
2018	20.564.683	83.139.873	26.760.021	12.594.611	4.174.552		15.340.449	16.600.000	216.510.546	3.742.966
2019	21.204.838	84.124.151	27.180.563	12.976.570	4.375.637		15.752.573	16.800.000	220.662.684	3.851.303

Tablica 50. Noćenja u turističkim smještajnim objektima u Litvi, Luksemburgu, Malti, Nizozemskoj, Sloveniji, Španjolskoj i Švedskoj od 1995. do 2019.

Godina	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	503.519	2.326.939		19.736.400	2.321.541	107.604.922	7.860.659
1996	576.027	2.148.071		19.043.000	2.436.595	106.442.110	7.716.620
1997	616.375	2.296.827		21.423.000	2.945.115	113.202.480	7.658.900
1998	712.641	2.295.856		24.573.000	2.933.811	120.996.632	8.029.087
1999	667.940	2.471.853		27.475.000	2.626.796	160.424.403	8.600.785
2000	635.634	2.379.021		25.955.000	3.276.819	233.900.964	8.654.086
2001	734.592	2.396.522		25.502.000	3.639.540	231.442.166	9.133.450
2002	799.069	2.445.897		26.367.800	3.832.704	220.699.515	9.767.708
2003	835.562	2.516.803	7.391.578	25.341.600	3.995.310	217.851.459	9.714.883
2004	1.197.331	2.493.349	7.458.466	25.386.300	4.188.385	209.081.382	9.723.676
2005	1.401.033	2.451.764	7.320.428	25.210.000	4.249.817	209.518.387	10.077.858
2006	1.514.197	2.399.913	7.094.031	26.886.500	4.332.049	224.518.083	10.942.968
2007	1.609.998	2.328.688	7.749.831	27.952.200	4.707.220	225.450.241	11.200.359
2008	1.626.829	2.249.545	7.581.137	25.267.600	5.085.308	223.756.216	10.920.106
2009	1.395.899	2.075.831	6.550.794	25.013.700	4.656.825	200.551.728	11.317.502
2010	1.571.325	1.717.130	7.208.295	26.799.800	4.680.456	213.349.649	11.184.995
2011	1.883.003	2.057.883	7.361.449	27.739.000	5.106.452	239.369.167	11.344.435
2012	2.680.048	2.298.068	7.498.421	27.845.942	5.702.306	243.389.006	11.299.455
2013	2.906.201	2.313.124	8.172.407	31.770.508	5.887.862	252.447.766	11.442.690
2014	3.033.826	2.513.585	8.428.215	34.423.552	6.004.623	259.635.794	12.260.712
2015	3.010.727	2.655.733	8.542.055	37.297.588	6.529.086	269.418.103	13.612.924
2016	3.273.420	2.637.701	8.622.438	39.623.541	7.252.070	294.556.428	13.997.265
2017	3.431.233	2.573.589	9.184.162	44.169.041	8.478.019	305.907.462	14.638.702
2018	3.736.850	2.574.556	9.685.156	47.001.546	11.200.000	301.022.634	15.685.681
2019	4.142.526		9.436.332	51.750.379	11.370.766	299.091.409	15.980.234

Tablica 51. Godišnje količine nastaloga komunalnog otpada (prikaz u tisućama tona) u 17 promatranih država EU-a od 1995. do 2019.

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	4.613	979	3.120	2.725	533	28.253	4.752	1.848	25.780	657	1.546	240	146	8.337	1.186	20.076	3.405
1996	4.567	1.100	3.200	3.253	565	28.950	4.834	1.898	25.960	650	1.445	242	156	8.565	1.175	21.125	3.458
1997	4.650	1.015	3.280	3.104	593	29.677	5.016	2.000	26.605	621	1.510	253	167	8.986	1.170	22.174	3.678
1998	4.603	1.205	3.017	3.141	557	30.449	4.976	2.057	26.846	597	1.578	266	177	9.069	1.159	22.423	3.839
1999	4.702	1.253	3.365	3.329	569	30.612	4.943	2.168	28.364	613	1.236	278	181	9.205	1.090	24.470	3.774
2000	4.831	1.173	3.434	3.546	633	31.232	4.552	2.279	28.959	642	1.276	285	208	9.529	1.020	26.505	3.773
2001	4.802	1.259	2.798	3.519	509	32.198	4.603	2.704	29.409	713	1.313	285	212	9.550	953	26.616	3.907
2002	4.981	1.346	2.845	3.568	553	32.684	4.646	2.720	29.864	793	1.395	291	214	9.684	812	26.404	4.149
2003	4.824	1.434	2.857	3.618	567	31.400	4.700	2.918	30.035	695	1.328	306	231	9.504	834	27.270	4.159
2004	5.059	1.311	2.841	3.757	606	32.444	4.592	3.001	31.150	720	1.260	311	250	9.746	969	25.746	4.143
2005	5.052	1.449	2.954	3.990	587	33.347	4.646	3.041	31.668	716	1.287	313	252	9.769	989	25.683	4.321
2006	5.115	1.654	3.039	4.021	536	33.962	4.711	3.385	32.516	760	1.326	323	253	9.761	1.036	26.209	4.461
2007	5.243	1.719	3.025	4.313	602	34.577	4.594	3.398	32.536	861	1.354	333	266	9.922	1.060	26.154	4.460
2008	5.141	1.788	3.176	4.560	524	34.501	4.553	3.224	32.461	752	1.369	341	276	9.868	1.095	25.317	4.476
2009	5.042	1.743	3.310	4.206	452	34.426	4.312	2.953	32.107	753	1.206	338	268	9.738	1.069	25.108	4.390
2010	4.972	1.630	3.334	4.494	406	34.609	4.033	2.846	32.440	680	1.253	344	249	9.484	1.004	23.774	4.140
2011	5.023	1.645	3.358	4.803	399	34.790	3.809	2.823	31.386	721	1.339	345	245	9.479	852	22.672	4.278
2012	4.944	1.670	3.233	4.508	371	34.484	3.988	2.693	29.994	658	1.330	346	248	9.203	744	21.896	4.324
2013	4.867	1.721	3.228	4.564	386	34.176	3.738	2.350	29.573	704	1.280	335	247	8.840	853	21.184	4.371
2014	4.762	1.637	3.261	4.558	470	34.260	3.795	2.619	29.652	726	1.270	348	257	8.894	892	20.836	4.295
2015	4.643	1.654	3.337	4.671	473	34.344	3.712		29.524	798	1.300	346	270	8.866	926	21.158	4.422
2016	4.746	1.680	3.580	4.757	494	34.766	3.721	2.763	30.112	802	1.272	355	270	8.859	943	21.542	4.439
2017	4.672	1.716	3.643	4.728	514	35.188	3.768	2.768	29.572	798	1.286	367	295	8.792	974	22.018	4.551
2018	4.698	1.768	3.732	4.715	535	35.272	3.729	2.900	30.165	785	1.301	371	310	8.806	1.009	22.222	4.416
2019		1.812			543										1.075		

Tablica 52. Količina komunalnog otpada (kg) po stanovniku u 17 država EU-a od 1995. do 2019. godine

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	455	210	302	521	371	475	460	512	454	264	426	587	387	539	596	505	386
1996	450	240	310	618	399	486	469	522	457	265	401	585	412	551	591	530	391
1997	457	224	318	587	424	496	487	544	468	255	422	604	436	576	589	554	416
1998	451	266	293	592	402	507	485	554	472	248	445	625	459	577	585	557	434
1999	460	277	327	626	409	507	483	577	498	256	351	646	466	582	550	606	426
2000	471	262	335	664	453	514	446	599	509	271	365	654	533	598	513	653	425
2001	467	293	274	657	366	526	452	699	516	305	378	646	540	595	478	652	439
2002	482	313	279	664	401	530	457	692	523	343	405	653	541	600	407	637	465
2003	465	333	280	671	414	506	464	730	524	304	389	678	580	586	418	646	464
2004	485	304	279	695	445	519	454	737	540	318	373	679	623	599	485	600	461
2005	482	336	289	736	433	529	461	731	546	320	387	672	623	599	494	588	479
2006	485	384	297	740	398	535	468	792	559	343	405	683	624	597	516	590	491
2007	493	399	294	790	449	542	457	772	557	391	419	695	654	606	525	578	488
2008	480	415	306	830	392	538	454	718	552	345	428	697	674	600	542	551	485
2009	467	405	317	762	339	534	430	651	543	352	381	679	649	589	524	542	472
2010	456	379	318	812	305	534	403	624	547	324	404	679	601	571	490	510	441
2011	455	384	320	862	301	534	382	616	529	350	442	666	589	568	415	485	453
2012	445	391	308	806	280	527	402	585	504	323	445	652	590	549	362	468	454
2013	436	404	307	813	293	520	378	510	491	350	433	616	579	526	414	454	455
2014	425	387	310	808	357	517	385	562	488	364	433	626	591	527	432	448	443
2015	412	393	316	822	359	516	377		486	404	448	607	606	523	449	456	451
2016	419	403	339	830	376	521	379	581	497	410	444	609	593	520	457	463	447
2017	411	416	344	820	390	526	385	576	488	411	455	615	631	513	471	473	452
2018	411	432	351	814	405	527	381	600	499	407	464	610	640	511	486	475	434
2019		444													514		

Tablica 53. Stopa recikliranja komunalnog otpada u 17 promatranih država EU-a od 1995. do 2019. godine

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	19,1	0,0	0,0	25,2	0,6	17,7	1,6		4,8	0,0	0,0	20,0	13,7	39,7	2,0	7,0	26,3
1996	25,2	0,0	0,0	37,0	0,2	18,7	1,6		6,4	0,0	0,0	20,2	12,2	41,5	5,3	7,8	30,4
1997	34,4	0,0	0,0	35,4	0,2	20,0	1,6		9,3	0,0	0,0	26,9	10,8	43,6	6,0	8,4	32,6
1998	41,9	0,0	0,6	36,0	0,2	21,8	1,6	8,1	11,0	0,0	0,0	30,8	9,6	43,9	9,6	9,2	35,3
1999	46,1	0,0	0,9	38,9	0,0	22,9	1,6		12,1	0,0	0,0	30,6	7,2	43,8	6,3	14,2	37,5
2000	49,7	0,0	0,9	37,1	2,4	24,5	1,6	11,9	14,2	0,0	0,0	36,1	10,1	44,1	6,0	18,4	38,5
2001	50,4	0,0	0,9	36,1	5,1	26,1	1,6	11,3	17,8	0,4	0,0	37,2	9,0	43,7	2,7	21,4	39,0
2002	51,5	0,0	0,9	37,6	2,7	27,3	2,5	18,3	14,8	0,4	0,0	38,1	5,1	45,3	9,0	29,3	39,7
2003	52,9	0,0	0,9	40,9	15,0	28,0	3,5	23,6	16,3	2,3	0,0	42,5	6,5	45,6	12,6	28,7	41,3
2004	53,5	0,0	5,5	41,0	24,8	29,0	11,8	29,5	17,6	4,6	1,9	41,5	6,4	46,9	20,4	30,9	43,9
2005	55,6	0,0	6,2	41,0	22,5	29,0	9,6	31,1	18,5	3,8	1,9	43,5	8,7	46,7	18,6	31,4	44,6
2006	56,2		7,4	41,8	17,4	30,7	10,4	33,1	19,2	4,5	1,9	43,7	13,4	46,8	15,4	31,2	47,7
2007	56,8	3,1	10,1	44,2	23,1	32,3	12,1	34,1	25,0	5,0	7,5	45,0	4,1	48,3	21,9	30,6	46,7
2008	52,7	2,8	10,4	47,9	20,2	33,8	15,2	33,6	23,8	6,4	8,5	46,0	3,6	48,4	18,9	39,7	45,6
2009	53,9	2,3	12,4	48,8	21,0	35,3	15,4	33,5	29,7	7,7	8,5	46,2	3,7	49,1	19,6	33,2	49,2
2010	54,8	4,0	15,8	46,7	18,2	36,0	19,6	35,7	31,0	9,4	4,9	46,5	5,2	49,2	22,4	29,2	47,8
2011	54,4	8,3	17,0	42,4	23,3	36,8	22,0	36,1	35,5	9,7	19,9	46,4	9,0	49,1	35,6	26,7	47,0
2012	53,4	14,7	23,2	42,5	19,1	37,7	25,5	36,6	38,4	14,7	23,5	47,4	9,7	49,4	41,9	29,8	46,9
2013	52,8	14,9	24,2	43,3	17,9	38,7	26,4		39,4	25,9	27,8	46,6	8,5	49,8	34,8	32,5	48,2
2014	53,8	16,5	25,4	45,4	31,3	39,7	30,5	39,8	41,6	27,0	30,5	47,7	7,4	50,9	36,0	30,8	49,3
2015	53,5	18,0	29,7	47,4	28,3	40,7	32,2		44,3	28,7	33,1	47,4	6,7	51,8	54,1	30,0	47,5
2016	53,5	21,0	33,6	48,3	28,1	41,9	34,7	40,7	45,9	25,2	48,0	48,2	7,0	53,5	55,6	33,9	48,4
2017	53,9	23,6	34,1	47,6	28,4	43,0	35,0	40,4	47,8	24,8	48,1	50,4	7,1	54,6	57,8	36,1	46,8
2018	54,6	25,3	34,5	49,9	28,0	44,0	37,4	38,0	49,8	25,2	52,5	50,1	6,5	55,9	58,9	36,0	45,8
2019		30,2															

Tablica 54. Ukupna količina odloženoga komunalnog otpada (u tisućama tona) u 17 država EU-a od 1995. do 2019. godine

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	2.004	0	3.120	503	529	12.668	3.481	1.426	24.000	457	1.546	65	126	2.425	908	12.134	1.200
1996	1.718	0	3.200	432	564	13.408	3.693	1.518	21.623	476	1.445	67	137	1.778	925	11.758	1.110
1997	1.249	0	3.280	344	592	13.588	3.928	1.604	21.275	506	1.510	60	148	1.080	975	12.606	1.150
1998	1.028	0	2.800	357	556	13.786	3.936	1.767	20.768	537	1.578	62	159	838	1.017	12.577	1.020
1999	934	0	2.850	361	569	13.462	4.024	1.930	21.745	567	1.236	60	167	616	900	13.157	920
2000	936	0	2.900	355	601	13.320	3.736	2.093	21.917	597	1.209	60	188	900	800	13.559	865
2001	760	0	2.200	251	403	13.117	3.696	2.071	19.912	628	1.169	58	193	783	712	14.726	880
2002	575	0	2.097	218	419	12.651	3.841	1.967	18.745	657	1.119	57	204	800	713	14.723	825
2003	536	0	2.049	184	371	11.944	3.968	1.904	17.883	579	1.136	57	216	252	694	15.174	575
2004	590	0	1.838	169	383	11.767	3.857	1.819	17.641	601	1.153	52	234	159	625	13.068	380
2005	583	0	1.934	207	369	12.133	3.859	1.833	17.117	561	1.174	58	229	168	659	12.584	210
2006	492	1.221	2.043	203	373	12.003	3.792	1.981	17.462	670	1.211	56	219	232	725	15.657	226
2007	499	1.649	2.121	204	390	11.872	3.429	2.015	16.912	735	1.245	56	255	199	688	15.569	186
2008	204	1.731	2.057	175	333	11.148	3.341	1.939	16.069	705	1.237	53	266	154	685	13.091	140
2009	157	1.691	2.114	130	287	10.424	3.212	1.724	15.538	694	1.093	51	257	152	628	14.540	58
2010	81	1.537	2.162	128	267	10.078	2.838	1.496	15.015	617	1.079	55	226	145	571	14.789	38
2011	41	1.496	2.167	124	239	9.731	2.563	1.344	13.206	531	1.034	50	207	151	481	14.276	33
2012	32	1.380	1.828	98	129	9.281	2.609	1.028	11.720	516	971	50	208	138	316	13.263	27
2013	42	1.413	1.815	78	53	8.830	2.415		10.914	521	798	48	209	131	224	11.801	28
2014	46	1.310	1.827	66	30	8.490	2.181	537	9.332	515	748	50	218	128	208	12.023	27
2015	40	1.319	1.755	61	35	8.151	1.991		7.819	494	702	26	300	125	210	12.129	35
2016	38	1.288	1.789	56	51	7.936	1.888	711	7.432	516	379	22	218	127	78	11.658	28
2017	41	1.243	1.765	48	98	7.721	1.825	623	6.927	518	421	24	244	124	99	11.263	20
2018	46	1.171	1.828	53	115	7.382	1.851		6.486	462	320	23	266	125	97	11.325	30
2019		1.073															

Tablica 55. Količine nastalog miješanoga komunalnog otpada (u tisućama tona) u 17 država EU-a od 1995. do 2019. godine

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
1995	3.783,00	890,47	468,00	845,00	373,00	16.386,74	3.611,52	1.325,00	20.882,00	486,18	1.267,72	191,82	103,66	3.432,00	866,00	14.655,48	
1996	3.745,00	1.001,00	480,00	1.008,00	396,00	16.791,00	3.673,84	1.101,00	21.028,00	481,00	1.184,90	193,24	110,76	3.478,00	858,00	15.421,25	
1997	3.813,00	923,65	492,00	962,00	415,00	17.212,66	3.812,16	1.160,00	21.550,00	459,54	1.238,20	185,14	118,57	3.557,00	854,00	16.187,02	
1998	3.774,00	1.096,55	453,00	974,00	390,00	17.660,42	3.781,76	1.221,00	21.745,00	441,78	1.293,96	183,40	125,67	3.650,00	846,00	16.368,79	
1999	3.856,00	1.140,23	505,00	1.032,00	398,00	17.775,50	3.756,68	1.257,00	22.975,00	453,62	1.013,52	192,83	128,51	3.810,00	796,00	17.863,10	
2000	3.961,00	1.067,01	515,00	1.099,00	443,00	18.114,56	3.459,52	1.322,00	23.457,00	475,08	1.046,32	183,11	147,68	3.935,00	745,00	19.348,65	
2001	3.938,00	1.145,46	420,00	1.091,00	356,00	18.674,84	3.498,28	1.469,00	23.831,00	527,62	1.076,66	178,61	150,52	3.958,00	696,00	19.429,68	
2002	4.084,00	1.225,09	427,00	1.106,00	387,00	18.956,72	3.530,96	1.679,00	23.499,51	586,82	1.143,90	179,58	151,94	3.938,00	1.100,00	19.274,92	
2003	3.956,00	1.304,71	429,00	1.122,00	397,00	18.212,00	3.572,00	1.705,00	23.069,00	603,11	1.088,96	177,16	164,01	3.900,00	612,00	19.907,10	
2004	6.468,00	1.192,69	426,00	1.165,00	464,00	18.817,52	3.489,92	1.737,00	23.514,00	592,69	1.031,48	182,18	177,50	3.933,00	634,00	18.794,58	1.422,54
2005	4.143,00	1.318,94	443,00	1.237,00	457,00	19.341,26	3.530,96	1.746,00	23.429,00	543,54	1.047,96	176,48	178,92	3.958,00	618,00	19.657,83	1.447,54
2006	5.020,00	1.515,41	456,00	1.246,00	378,00	19.697,96	3.580,36	1.979,00	23.473,00	884,69	1.076,39	181,32	179,63	3.961,00	646,00	20.431,26	1.466,64
2007	4.299,00	1.439,42	454,00	1.337,00	390,00	20.100,00	3.491,44	1.761,00	22.973,00	745,79	1.128,75	183,19	188,86	3.964,00	642,00	19.993,46	1.494,10
2008	3.608,00	1.517,79	476,00	1.414,00	355,00	18.285,53	3.860,32	1.677,00	21.977,00	670,45	1.156,53	184,21	195,96	3.947,00	625,00	19.858,35	1.532,79
2009	4.134,00	1.491,13	549,00	1.304,00	302,00	19.100,00	3.035,60	1.627,00	20.910,00	533,87	1.038,02	181,57	190,28	3.878,00	586,00	19.333,50	1.470,65
2010	3.836,00	1.401,96	482,00	1.393,00	281,00	18.342,77	3.205,98	1.686,00	20.513,00	512,99	1.033,33	184,32	176,79	3.751,00	544,00	18.808,67	1.358,91
2011	4.119,00	1.377,24	485,00	1.470,00	280,00	18.800,00	2.880,71	1.683,00	19.086,00	412,16	970,00	185,49	173,95	3.734,00	436,00	18.291,85	1.411,74
2012	3.817,00	1.287,93	453,00	1.387,00	267,00	18.276,52	2.972,43	1.577,00	17.617,00	499,51	979,02	181,63	174,99	3.663,00	363,00	17.911,47	1.447,11
2013	3.991,00	1.299,58	438,00	1.415,00	289,00	17.700,00	2.737,42	1.398,00	16.682,00	510,24	923,73	179,66	168,45	3.523,00	320,00	17.320,70	1.267,59
2014	4.112,00	1.240,78	407,00	1.428,00	297,00	17.472,60	2.961,50	1.438,00	15.892,00	448,19	889,39	181,69	174,06	3.469,00	321,00	16.886,94	1.055,88
2015	3.807,00	1.262,84	369,00	1.387,00	308,00	17.400,00	2.902,08		15.165,00	560,77	857,33	181,63	182,67	3.383,00	297,00	17.106,18	1.105,50
2016	3.890,00	1.251,30	376,00	1.344,00	316,00	17.383,00	2.874,98	1.520,00	14.169,00	550,36	780,65	182,95	174,76	3.221,00	310,00	17.141,37	1.111,95
2017	3.831,00	1.228,23	406,00	1.305,00	316,00	16.970,00	2.649,25	1.495,00	13.015,00	571,44	765,47	182,29	184,95	3.057,00	301,00	17.457,71	1.160,51
2018	4.212,00	1.214,62	400,00	1.206,00	329,00		2.579,96	1.595,00	12.481,00	529,13	767,94	184,50	179,85	2.944,00	299,00	17.777,60	1.160,46
2019		1.140,85			334,00		2.610,31				750,93		158,47	2.846,00	290,00		



Tablica 56. Količine nastalog papira i kartona (prikaz u tisućama tona) u 17 država EU-a

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
2004	1.966,60	7,62	191,59	417,58	272,32	5.213,15	610,49	821,90	2.483,51	0,06	13,71	47,84	4,48	1.903,16	60,61	2.903,59	693,46
2005	2.030,90	181,10	206,78	424,94	340,46	5.335,52	464,60	881,89	2.533,44	9,31	38,61	46,95	4,04	1.856,11	69,23	2.825,13	691,36
2006	2.128,92	354,57	214,78	420,53	384,52	5.285,45	301,70	1.063,84	2.681,68	19,91	65,36	47,47	3,67	1.778,73	79,53	3.004,28	718,89
2007	1.861,27	190,30	211,75	431,30	270,90	5.186,55	321,58	815,52	2.928,24	12,05	67,70	56,61	2,66	1.934,79	84,80	2.876,94	713,60
2008	1.510,41	25,98	225,16	434,64	93,61	4.757,12	343,90	542,40	3.301,99	0,87	78,89	63,72	3,99	2.048,02	91,05	3.146,61	715,25
2009	1.702,68	58,90	264,80	328,07	45,20	4.647,51	388,08	472,48	3.210,70	22,59	60,30	60,84	7,24	1.986,55	96,21	3.012,96	702,40
2010	1.897,36	75,35	293,88	274,11	12,11	4.524,08	385,56	20,97	3.360,54	39,99	54,74	61,77	9,65	1.896,38	97,04	2.760,45	616,49
2011	1.908,74	91,80	302,22	432,27	23,94	4.522,70	380,90	451,68	3.295,53	72,10	60,26	62,10	9,80	1.801,01	93,72	2.607,28	598,92
2012	1.896,30	124,64	303,13	534,90	32,33	4.592,48	401,62	219,36	3.294,33	97,49	62,68	62,71	10,48	1.700,12	89,26	2.374,65	557,70
2013	1.800,79	124,60	290,52	547,68	33,58	4.442,88	373,80	376,00	3.400,90	96,45	76,80	56,95	12,35	1.591,20	110,89	2.118,40	699,36
2014	1.693,35	124,91	306,08	548,59	40,61	4.399,52	364,25	253,20	3.429,32	91,07	93,29	52,91	16,54	1.573,41	124,82	1.938,38	822,59
2015	1.583,26	145,80	300,33	546,96	43,52	4.293,00	352,64		3.542,88	103,74	91,00	50,17	17,55	1.595,88	125,01	2.115,80	707,52
2016	1.549,66	166,77	330,54	591,64	47,85	4.094,10	346,61	483,92	3.489,34	106,48	91,65	48,86	18,89	1.585,90	120,64	2.317,35	765,04
2017	1.511,86	144,00	327,87	567,36	51,40	4.046,62	339,12	442,88	3.548,64	87,78	90,02	51,38	17,70	1.521,02	141,23	2.421,98	728,16
2018	1.506,82	121,19	343,45	548,85	55,81	4.043,32	333,62	531,93	3.706,26	69,14	92,71	50,83	14,41	1.470,52	164,79	2.397,16	714,55

Tablica 57. Količine nastalog otpadnog drva (prikaz u tisućama tona) u 17 država EU-a

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
2004	387,12	0,24	14,76	255,80	256,47	705,00	99,11	175,33	657,70	59,90	10,06	7,38	0,52	422,72	15,81	950,40	1,82
2005	420,83	2,20	29,54	299,25	305,24	666,94	92,92	182,46	633,36	78,76	51,48	6,26	0,60	390,76	19,78	770,49	1,73
2006	461,55	4,15	40,37	330,96	329,13	705,00	95,57	219,32	682,72	105,39	86,64	4,08	0,68	402,41	22,28	550,13	1,82
2007	407,38	2,30	30,25	323,48	228,76	691,54	45,94	149,51	813,40	61,99	67,70	3,33	0,27	446,49	21,20	653,85	1,78
2008	335,47	0,62	20,04	306,49	72,06	857,99	21,06	77,00	959,84	3,39	34,98	3,68	0,03	459,09	23,72	838,36	1,84
2009	403,36	3,20	33,10	210,30	31,64	1.032,78	43,12	41,34	963,21	31,63	20,50	6,76	4,29	486,90	26,73	753,24	1,76
2010	423,56	5,70	37,34	76,54	1,97	1.547,07	34,14	9,99	938,68	0,00	9,66	6,88	8,16	451,30	32,02	802,07	1,96
2011	401,84	4,80	33,58	240,15	15,96	1.391,60	38,09	19,76	941,58	30,28	13,39	6,90	10,29	473,95	34,08	566,80	102,67
2012	359,21	3,94	39,02	120,45	26,82	1.365,47	27,70	30,82	850,49	15,99	17,91	6,45	12,49	442,08	37,68	540,67	204,59
2013	365,03	7,90	32,28	228,20	27,02	1.367,04	18,69	23,50	887,19	21,82	12,80	4,69	12,84	442,00	46,92	423,68	314,71
2014	365,36	11,81	43,68	371,85	30,54	1.453,86	10,62	25,71	919,62	27,95	8,77	3,11	13,61	452,68	51,78	307,54	412,56
2015	459,42	9,60	42,05	233,55	33,11	1.373,76	12,99		885,72	26,33	13,00	3,46	11,61	443,30	41,67	211,58	455,47
2016	575,12	7,32	69,12	206,97	38,42	1.660,94	14,72	27,67	982,63	22,72	16,47	4,18	9,02	455,46	30,24	273,65	492,41
2017	652,68	9,60	72,86	236,40	44,72	1.759,40	18,84	27,68	1.035,02	17,56	12,86	5,14	9,15	483,56	34,09	220,18	523,37
2018	742,94	11,97	75,18	234,57	51,00	1.711,52	21,81	48,76	1.223,16	12,45	15,54	5,79	8,60	506,73	42,05	307,28	526,31

Tablica 58. Količine nastalog otpadnog tekstila (prikaz u tisućama tona) u 17 država EU-a

Godina	Belgija	Hrvatska	Češka	Danska	Estonija	Francuska	Mađarska	Irska	Italija	Latvija	Litva	Luksemburg	Malta	Nizozemska	Slovenija	Španjolska	Švedska
2004		0,01	2,85	0,00	0,91	305,60	19,46	157,52	80,26	0,20	0,17	2,41	0,00	71,31	0,93	49,35	0,00
2005	87,40	0,01	2,07	0,00	0,82	333,47	27,88	158,13	114,00	0,07	0,51	3,13	0,00	71,31	1,78	51,37	0,00
2006	98,44	0,01	1,25	0,00	0,38	305,60	32,43	176,47	78,25	0,00	1,00	2,78	0,02	77,60	2,20	24,87	0,00
2007	90,70	0,02	2,12	0,00	0,84	345,77	18,38	122,33	117,13	0,09	2,03	3,33	0,03	82,35	1,91	26,15	0,00
2008	71,62	0,02	2,95	0,00	0,41	366,00	1,82	61,00	94,65	0,00	3,15	3,00	0,00	85,32	1,12	30,68	0,00
2009	87,23	0,03	3,31	0,76	0,63	344,26	8,62	59,06	96,32	0,08	1,21	3,38	0,03	83,75	1,92	25,11	0,00
2010	100,77	0,03	3,67	0,85	0,04	346,84	16,46	61,00	82,89	0,00	0,11	3,67	0,02	80,91	1,52	28,33	0,00
2011	86,90	0,03	4,70	0,86	0,56	347,90	7,62	36,70	94,16	0,07	1,34	3,45	0,07	79,63	1,53	22,67	0,00
2012	91,57	0,03	5,59	0,79	0,61	406,93	2,41	10,50	108,83	0,01	2,76	3,63	0,13	76,06	1,21	28,97	0,00
2013	121,68	0,12	7,10	0,82	0,77	273,41	3,74	7,05	121,25	0,07	2,56	4,69	0,22	75,14	1,79	42,37	0,00
2014	126,87	0,21	8,81	0,49	0,90	134,58	6,69	6,28	134,70	0,15	1,50	5,75	0,34	77,64	2,34	52,65	0,00
2015	116,08	1,25	10,01	0,84	0,95	137,38	7,42		147,62	0,08	2,60	6,92	0,32	82,45	1,94	42,32	0,00
2016	85,72	2,30	12,48	0,88	1,12	166,28	10,46	13,31	147,39	0,10	2,48	8,58	0,28	86,88	2,12	40,29	1,83
2017	93,44	2,50	13,84	0,85	1,03	140,75	7,54	8,30	147,86	0,08	2,57	6,97	0,71	87,92	1,94	44,04	2,73
2018	103,25	2,71	15,45	3,51	1,20	149,45	6,99	2,31	164,52	0,10	2,66	4,82	1,19	93,25	2,50	45,51	3,15

### Prilog 3: Elementi matrice $W_1$ i vektora $B_1$ i matrice $W_2$ i vektora $B_2$ za kreiranje matematičkog modela ANN1

Tablica 59. Elementi matrice  $W_1$  i vektora  $B_1$  (prikazani u retku pristranosti) za matematički model ANN1

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Year	0.29	0.92	0.63	0.32	2.49	2.14	0.53	-0.48	-0.68	1.15	0.86	0.84	1.00	-3.18	0.07	2.05	-0.73	-1.03	-0.25	-0.83
POP	-1.31	-1.45	-0.57	-0.22	-0.47	-1.26	0.11	-0.85	-0.97	-0.37	-1.39	-1.17	-0.23	-0.64	-0.82	-1.52	-0.77	-1.32	-0.58	-0.91
LE	0.21	-0.01	-0.95	0.27	-0.40	0.57	0.91	-0.57	0.00	-0.07	0.89	0.73	4.61	2.01	0.25	4.45	-2.12	0.35	-1.62	-0.87
EL1	0.30	0.39	-0.56	0.22	-1.50	-0.12	-1.57	0.40	0.31	-0.14	0.23	-0.10	-3.36	-2.10	0.75	-1.83	-0.55	0.81	-0.68	0.27
EL2	-0.40	0.32	0.28	0.61	0.73	0.75	1.76	0.01	1.11	0.38	0.84	0.06	3.56	2.67	0.93	2.98	0.32	1.12	-0.09	-0.17
EL3	-0.86	-0.02	0.47	1.02	0.39	-0.48	1.09	0.00	0.74	0.45	0.44	0.02	1.71	2.60	2.30	1.62	0.44	1.71	0.03	0.09
ELT	0.75	0.78	-0.34	-0.62	0.63	2.39	1.55	-0.03	0.94	0.02	0.90	0.01	3.93	0.60	-2.24	2.76	-0.13	-0.80	-0.26	-0.47
GDP	-1.17	-2.24	-0.68	-0.77	0.61	-0.68	0.41	-0.80	-1.34	-0.67	-1.83	-1.22	-0.22	-0.93	-1.21	-1.25	-0.63	-1.65	-0.56	-0.83
RGDP	0.41	0.48	-0.59	0.04	-0.35	0.18	-0.32	-0.10	0.62	0.57	0.48	0.70	0.34	-0.31	0.71	0.38	-0.55	0.58	-0.65	-0.12
TFS	0.78	1.18	0.07	0.53	0.46	0.79	0.56	0.36	0.69	0.31	1.25	0.86	0.64	0.86	0.55	0.68	-0.14	0.61	-0.31	0.33
NED	-0.93	-2.25	-0.28	-0.25	-0.69	-0.11	-0.74	-0.02	0.25	-0.72	-1.10	-1.51	-0.94	-0.88	-0.74	0.19	0.23	-0.20	-0.20	-0.29
NEER	-1.92	1.08	0.63	0.42	-0.11	1.50	0.83	0.23	0.57	-0.99	1.18	-1.16	-1.01	1.80	-0.60	0.04	-0.07	-0.33	-0.10	-0.66
DIRE	0.31	-0.56	0.06	0.09	0.66	1.34	0.60	0.23	1.04	-0.19	0.67	0.19	0.25	0.64	-0.70	0.70	-0.03	0.31	-0.17	0.17
TEMP	-1.26	-1.30	-0.64	-0.57	-0.29	-1.35	0.80	-0.87	-0.75	-0.41	-1.50	-1.15	0.62	0.72	-0.76	-0.53	-0.77	-0.95	-0.62	-0.97
URAD	0.41	0.63	0.06	1.31	-0.80	0.67	1.05	-0.14	-0.27	0.15	1.49	-0.11	-0.44	-0.85	-0.81	-0.02	-0.42	-0.51	-0.31	-0.43
YUR	2.18	-1.58	-0.33	1.08	-0.82	-2.62	-1.46	-0.15	0.10	-1.18	-0.12	1.54	-0.42	-2.18	0.92	2.60	-0.94	0.07	-0.68	-0.35
MENI	0.38	-1.31	-0.72	-0.76	-0.02	0.70	-1.24	-0.15	-1.73	-0.62	-1.62	-0.24	-1.66	-4.11	-0.75	-0.91	-0.42	-1.81	-0.66	-0.25
ATAE	-1.12	-1.27	-0.51	-0.24	0.17	-0.98	0.00	-0.61	-0.87	0.15	-1.12	-0.82	0.38	1.30	-0.74	-3.44	-0.62	-1.03	-0.46	-0.64
NSTA	-0.57	0.86	-0.06	0.73	-0.62	-1.01	0.96	-0.25	-0.48	0.88	0.12	-0.41	-3.07	-1.68	0.07	-0.18	-0.34	-0.21	-0.15	-0.29

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
IGS	-1.08	1.94	-0.84	-0.25	1.04	-1.05	0.00	-0.82	0.22	-1.18	-0.01	-0.60	1.36	-0.48	0.41	0.02	-0.94	0.33	-0.87	-0.97
EGS	-1.11	2.16	-0.85	0.33	0.74	-1.26	-0.02	-0.94	-0.07	-0.33	0.18	-0.57	-1.85	-0.80	1.10	-1.55	-1.08	0.42	-0.92	-1.07
EOPP	-0.86	-0.49	-0.37	-0.80	-0.57	-1.47	-2.13	-0.49	-0.78	-1.68	-0.90	-0.41	-3.80	-2.10	-0.90	0.03	-0.51	-0.68	-0.49	-0.33
HPI	-1.43	1.36	-0.06	0.03	0.79	0.58	0.02	0.15	-0.38	0.67	-0.53	-1.24	-0.50	-1.12	-1.30	5.42	0.67	-0.74	0.32	0.48
RRMW	-0.66	-1.38	-0.95	-0.76	-0.60	-1.57	-0.59	-1.28	-1.53	0.13	-1.87	-0.63	-2.98	-0.74	0.53	-0.15	-1.10	0.03	-0.78	-0.84
DL	-0.83	1.09	-0.18	-0.07	-2.73	-0.68	0.11	-0.20	0.00	-1.63	-0.54	-0.97	4.48	-0.25	-2.52	0.10	-0.17	-1.87	-0.12	-0.26
GMWK	0.28	-1.36	-0.27	-0.81	-2.55	-1.35	-0.95	0.26	-1.27	-0.17	-1.53	0.03	-2.29	-1.06	0.72	-0.75	0.54	-0.19	0.22	0.90
GMWT	-1.25	-1.83	-0.65	-0.89	-0.47	-1.46	-0.08	-0.92	-1.05	-1.13	-1.74	-1.24	-0.63	-0.84	-1.59	-1.29	-0.74	-1.29	-0.57	-0.92
Belgija	-1.27	1.23	-0.57	-0.73	-1.66	-1.02	-1.12	-0.81	-0.76	-1.59	-0.69	-0.64	-2.23	-1.22	0.13	1.20	-0.80	1.14	-0.78	-0.44
Hrvatska	-0.62	0.32	0.86	0.10	-0.81	-0.84	0.15	-0.40	-0.43	-0.18	0.08	-0.76	0.41	0.52	-0.18	0.22	0.51	-0.25	0.62	-0.30
Češka	-0.94	-1.02	-0.38	0.12	0.86	0.72	0.49	0.05	-0.23	0.63	-1.50	-0.10	-0.33	-0.86	0.56	0.35	-0.45	-0.04	-0.24	0.41
Danska	0.91	-0.63	0.05	-0.02	-1.72	1.48	0.44	0.35	1.08	0.49	-0.78	-0.28	2.53	-1.85	-0.19	0.87	0.67	0.99	0.27	-0.16
Estonija	0.55	-0.92	-1.05	0.01	2.25	1.55	0.48	0.80	0.57	0.77	-1.20	0.81	-0.89	0.20	0.66	0.34	-0.08	0.86	0.52	0.93
Francuska	-0.51	-0.93	-0.52	-0.60	0.13	-0.23	1.08	-0.50	-0.42	-1.56	-0.66	-0.38	-3.72	2.42	-0.74	-3.72	-0.54	-0.63	-0.51	-0.42
Mađarska	-1.59	0.61	0.44	-0.16	-1.76	-1.47	0.17	-0.58	-0.54	-0.49	-0.11	-0.51	1.23	1.34	-1.05	-0.05	0.70	-1.01	0.72	-0.40
Irska	0.50	-0.36	-0.20	-0.38	-1.90	-1.47	-2.01	0.10	-1.80	-0.19	1.33	0.80	-2.77	-1.24	1.58	-3.19	0.13	-1.47	0.56	1.05
Italija	-0.10	-1.68	0.02	0.67	0.68	-0.35	-1.78	-0.08	-0.87	0.80	-0.23	0.05	0.83	-3.59	0.75	-0.32	-0.17	-0.64	-0.13	-0.14
Latvija	0.80	0.37	0.57	0.23	0.47	0.86	0.25	0.49	0.43	-0.09	1.01	0.09	0.33	0.35	-0.02	0.37	0.46	0.35	-0.08	0.21
Litva	0.60	0.75	0.84	0.22	-0.18	0.01	0.18	0.16	0.21	-0.45	1.03	-0.28	0.38	0.51	-0.11	0.28	0.57	0.23	-0.01	0.17
Luksemburg	0.78	1.54	0.12	0.76	0.60	1.09	0.95	0.50	0.95	0.58	1.53	1.16	0.83	1.27	0.85	1.11	-0.14	1.03	-0.43	0.45
Malta	1.44	1.48	-0.15	0.78	1.05	1.91	0.91	0.83	1.72	0.55	1.99	1.41	1.61	1.34	1.27	0.96	-0.51	1.78	-0.72	0.34
Nizozemska	-0.45	0.47	-0.32	-0.58	0.71	-1.68	-1.68	-0.36	-0.48	-0.47	-1.08	-1.57	-2.38	0.14	-0.51	0.55	-0.45	-0.16	-0.19	-0.53

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Slovenija	0.60	0.05	0.46	0.29	0.67	0.91	0.32	0.58	0.75	-0.14	1.07	-0.13	0.44	-0.26	0.09	0.50	0.29	0.27	-0.17	0.08
Španjolska	-0.12	2.07	0.03	0.26	-1.63	-0.17	1.30	0.09	0.75	0.84	0.30	-0.53	2.57	-0.05	-0.87	1.93	-0.05	0.09	0.05	-0.16
Švedska	-0.50	-2.63	-0.39	-0.14	1.44	-0.68	0.07	-0.83	0.50	0.67	-0.94	0.76	1.43	1.56	-0.63	-0.28	-0.30	-0.54	-0.24	-0.99
Bias	0.00	0.77	-0.25	0.85	-0.83	0.57	0.15	0.36	1.45	0.21	1.18	-0.02	0.23	0.71	1.61	1.11	-0.11	1.89	-0.74	0.05

Tablica 60. Elementi matrice  $W_2$  i vektora  $B_2$  (prikazani u stupcu pristranosti) za matematički model ANN1

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	Bias
Miješani komunalni otpad	0.40	0.14	1.17	-0.18	-0.94	-0.85	-0.22	-0.98	-0.41	-0.29	-0.48	-1.11	0.23	-0.11	-0.92	-0.03	1.00	-1.01	1.80	-1.26	0.07
Papir i karton	-2.45	-0.48	-0.58	-0.20	-0.40	-0.29	0.29	-0.38	-1.90	0.33	-1.43	0.52	-0.11	0.14	0.05	0.03	0.13	-0.11	1.39	0.60	-0.21
Drvni otpad	-1.56	-1.78	0.23	0.01	1.58	2.45	0.06	0.95	-0.50	-2.72	-1.84	-1.80	-1.31	-2.14	-1.93	0.74	1.74	-0.46	1.43	1.67	0.32
Tekstilni otpad	0.69	1.14	0.74	1.67	0.06	-2.78	-0.88	-0.52	-2.30	1.09	-0.76	0.82	-4.06	-3.66	-1.05	-2.35	1.28	-2.65	2.06	0.44	3.58

## Prilog 4: Elementi matrice $W_1$ i vektora $B_1$ i matrice $W_2$ i vektora $B_2$ za kreiranje matematičkog modela ANN2

Tablica 61. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu c

	1	2	3	4	5	6	7	8
Godina	-1,413	6,049	-3,610	-0,612	1,757	1,756	4,620	3,273
Belgija	-0,072	-0,655	-0,062	-0,183	0,391	0,322	0,211	0,226
Hrvatska	1,540	-1,456	0,539	1,191	1,224	-0,287	0,528	-0,551
Češka	0,005	-0,587	-0,056	-0,138	0,401	0,145	-0,030	0,311
Danska	1,124	-1,682	0,578	1,070	0,766	-0,292	0,326	-0,630
Estonija	1,405	-0,211	0,190	1,374	1,620	1,105	1,616	1,360
Francuska	-5,468	-4,800	-0,752	-5,426	-5,883	-5,570	-5,812	-5,478
Mađarska	0,221	-1,285	0,401	0,103	0,288	-0,158	-0,220	-0,097
Irska	1,111	-0,318	-0,229	1,099	1,353	0,489	1,141	-0,178
Italija	-4,217	-0,911	-0,253	-3,971	-5,433	-3,189	-5,259	-3,159
Latvija	1,637	-0,812	0,373	1,425	1,470	0,346	1,301	0,161
Litva	1,672	-1,422	0,668	1,391	1,048	-0,249	0,657	-0,422
Luksemburg	2,063	4,318	2,494	2,302	1,814	2,696	2,014	2,804
Malta	2,575	4,517	2,595	2,861	2,045	2,756	2,089	2,882
Nizozemska	-1,196	-0,236	-0,368	-1,225	0,526	1,219	1,205	0,319
Slovenija	1,270	-0,264	0,019	1,183	1,315	1,034	1,188	0,748
Španjolska	-3,764	0,814	-1,630	-3,495	-3,559	-0,492	-3,215	-0,972
Švedska	-0,284	-0,456	-0,136	-0,271	0,475	0,840	1,376	0,609
Nulti član	-0,380	-5,614	4,397	-0,668	-0,029	0,555	-1,059	-2,057

Tablica 62. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Broj stanovnika“

	1	2	3	4	5	6	7	8	Nulti član
POP	-2,114	-3,527	-7,886	-2,815	0,944	-3,477	0,334	-1,969	9,757

Tablica 63. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Očekivani životni vijek“

	1	2	3	4	5	6
Godina	-0,155	-1,317	-2,153	1,895	-0,195	-0,468
Belgija	0,014	-0,172	-0,365	0,779	-0,162	-0,067
Hrvatska	0,038	0,454	0,949	-0,478	0,110	0,280
Češka	-0,070	-0,032	-0,384	-0,301	-0,116	-0,296
Danska	-0,006	-0,148	-0,454	0,399	-0,090	-0,055
Estonija	-0,511	-0,104	2,424	-1,145	0,370	-0,174
Francuska	-0,027	-0,219	-0,583	0,832	-0,114	-0,256
Mađarska	0,063	0,590	1,095	-0,784	0,265	0,501
Irska	-0,053	-0,193	-0,758	0,048	-0,047	-0,254
Italija	-0,015	-0,340	-0,447	0,780	0,075	0,038
Latvija	-0,215	0,069	1,506	-1,794	0,123	0,125
Litva	0,526	1,413	0,523	-2,271	0,469	1,110
Luksemburg	-0,033	-0,151	-0,609	0,718	-0,061	-0,225
Malta	0,027	-0,095	-0,320	1,191	-0,108	-0,042
Nizozemska	-0,046	-0,178	-0,580	0,980	-0,117	-0,314
Slovenija	0,007	-0,100	-0,655	0,354	-0,125	-0,097

	1	2	3	4	5	6
Španjolska	-0,017	-0,191	-0,537	0,965	-0,051	-0,183
Švedska	-0,028	-0,139	-0,290	1,034	-0,126	-0,281
Nulti član	-0,281	0,300	0,532	1,223	0,291	-0,203

Tablica 64. Elementi matrice  $W_2$  i vektora  $B_2$  varijablu „Očekivani životni vijek“

	1	2	3	4	5	6	Nulti član
LE	5,764	-1,453	0,602	1,069	1,352	-1,940	-0,654

Tablica 65. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu koja označava osnovnoškolsko i niže srednjoškolsko obrazovanje

	1	2	3	4	5
Godina	3,288	1,522	1,326	5,018	2,055
Belgija	2,168	-0,340	-2,033	1,636	-1,562
Hrvatska	4,051	-4,563	0,308	2,972	-0,368
Češka	-7,210	3,308	2,136	-5,298	5,162
Danska	-6,280	-5,285	6,526	6,799	7,258
Estonija	-0,719	1,956	4,010	3,528	4,085
Francuska	3,049	-1,598	-2,112	2,123	-1,253
Mađarska	-0,920	1,510	0,449	-0,224	-1,905
Irska	-0,048	1,570	-1,448	-0,681	-2,448
Italija	-0,947	-5,466	-3,530	-2,016	-2,315
Latvija	3,983	2,561	0,461	0,927	0,834
Litva	5,634	1,711	0,258	2,474	3,306
Luksemburg	-2,818	2,360	-0,523	-1,190	-2,818
Malta	-2,497	-0,368	-1,449	-7,468	-4,035
Nizozemska	2,666	-1,946	-2,227	2,625	-0,539
Slovenija	-0,150	2,289	0,276	-1,338	-1,818
Španija	-4,094	-3,269	-3,001	-0,497	-2,731
Švedska	-4,685	2,303	3,929	2,245	4,535
Nulti član	-8,779	-3,370	2,143	6,576	3,436

Tablica 66. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu koja označava osnovnoškolsko i niže srednjoškolsko obrazovanje

	1	2	3	4	5	Nulti član
EL1	-6,713	-1,739	-0,951	-5,329	-4,994	10,397

Tablica 67. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu koja označava srednjoškolsko ili više obrazovanje

	1	2	3	4	5	6
Godina	-0,167	1,718	-0,089	-0,381	2,551	1,874



	1	2	3	4	5	6
Belgija	-0,802	-1,546	-1,297	-2,252	2,403	-0,084
Hrvatska	-1,028	4,982	4,434	0,950	-4,112	0,867
Češka	1,536	1,243	2,915	0,358	-3,747	0,504
Danska	-5,585	4,659	-1,532	-2,483	5,682	1,438
Estonija	-1,775	1,781	-0,658	0,694	2,988	1,006
Francuska	-0,770	-1,791	-1,105	-2,468	2,518	0,180
Mađarska	1,390	-0,561	-0,647	0,896	-0,689	-0,070
Irska	0,866	-1,181	-0,377	0,993	-0,733	0,353
Italija	2,207	-1,361	-1,709	0,367	-1,700	-0,259
Latvija	1,450	-0,914	-0,522	-0,840	-0,684	-0,474
Litva	1,297	-1,062	2,366	-1,566	-1,594	-0,172
Luksemburg	1,133	-1,198	1,114	1,001	-1,696	0,180
Malta	-3,162	-2,181	2,102	1,509	0,833	1,115
Nizozemska	-0,203	-0,879	-1,486	-2,135	2,391	-0,248
Slovenija	-0,471	-0,369	-0,055	0,910	0,788	0,452
Španjolska	-1,083	-1,080	-1,391	1,032	1,350	0,287
Švedska	-0,257	2,129	-0,468	0,722	1,064	0,135
	-5,216	0,754	1,835	-2,204	5,100	5,094

Tablica 68. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu koja označava srednjoškolsko ili više obrazovanje

	1	2	3	4	5	6	Nulti član
EL2	4,050	0,201	0,434	-2,021	3,218	-1,133	0,338

Tablica 69. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu koja obuhvaća sve stanovnike koji imaju završeno srednjoškolsko obrazovanje ili neki drugi program obrazovanja koji ne spada u visoko obrazovanje

	1	2	3	4	5	6	7	8
Godina	2,629	-5,392	-5,359	-6,108	1,224	0,178	-0,656	-6,327
Belgija	0,666	0,088	0,271	0,706	0,082	-1,047	-0,706	0,714
Hrvatska	1,331	-1,174	-1,306	-1,661	-0,873	1,039	2,209	-1,851
Češka	-0,727	0,616	1,969	-1,043	0,647	0,229	1,465	-1,520
Danska	0,079	0,106	0,345	0,864	-0,674	-0,444	-0,106	0,825
Estonija	-0,815	0,208	0,407	0,338	-0,300	-0,014	0,070	0,287
Francuska	0,614	0,442	0,633	1,011	-0,236	-0,205	-0,086	1,007
Mađarska	0,376	0,499	0,829	-0,588	0,188	0,752	0,398	-0,730
Irska	0,338	-0,809	-0,784	1,400	-0,469	-0,031	-0,082	1,404
Italija	1,446	-0,409	-0,206	0,656	0,523	0,769	-0,242	0,651
Latvija	-0,936	-0,403	-0,150	-0,004	-0,288	0,252	0,447	0,002
Litvanija	-2,141	0,613	-3,543	-1,822	-0,521	-0,579	-0,140	-0,700
Luksemburg	-0,708	-0,498	-0,395	-0,059	-0,422	0,002	-0,243	-0,144
Malta	0,159	0,920	1,057	1,305	1,224	-0,185	-1,056	1,280
Nizozemska	0,627	0,097	0,333	1,018	-0,340	0,466	0,016	1,028
Slovenija	-1,193	-0,016	0,190	-0,425	-0,022	0,407	0,193	-0,487

Španjolska	1,315	0,003	0,212	0,641	-0,212	-1,059	-1,063	0,656
Švedska	-1,085	0,729	1,052	0,345	0,456	0,254	-0,346	0,257
Nulti član	-0,530	1,022	0,843	2,566	-1,311	0,704	0,806	2,693

Tablica 70. Elementi matrice  $W_2$  i vektora  $B_2$  za EL3

	1	2	3	4	5	6	7	8	Nulti član
EL3	-0,194	-2,128	2,018	-2,479	0,298	-0,335	0,775	2,338	0,722

Tablica 71. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Visoko obrazovanje“

	1	2	3	4	5	6	7	8	9
Godina	1,500	1,122	-1,376	2,505	8,206	0,153	3,161	-4,646	-8,821
Belgija	0,581	0,041	-0,020	0,551	1,963	0,286	0,618	-1,090	-0,973
Hrvatska	-0,652	-0,157	-0,391	-0,249	-2,308	0,178	-0,420	1,726	3,264
Češka	-1,044	-0,538	0,570	-0,725	-1,343	-0,179	-0,218	0,844	2,611
Danska	-0,668	-0,448	0,362	0,708	0,573	-0,565	-0,109	-2,337	-1,807
Estonija	1,263	0,133	-0,113	0,371	1,933	0,501	0,753	-0,225	-0,726
Francuska	0,377	-0,120	0,040	0,588	0,543	0,078	-0,011	-0,585	0,409
Mađarska	-0,580	-0,644	0,535	-0,299	-1,235	0,107	-0,718	-0,055	2,086
Irska	0,941	0,683	-0,688	-0,097	2,954	0,349	1,235	0,174	-2,798
Italija	-1,504	-0,992	1,002	-1,214	-2,536	0,067	-1,528	2,435	3,464
Latvija	-0,003	0,109	-0,110	-0,034	-0,711	0,313	0,116	0,114	-0,801
Litva	1,213	0,483	-0,828	0,486	-1,577	0,029	-0,408	-1,705	-3,114
Luksemburg	0,549	1,471	-0,756	-0,506	1,144	0,164	1,014	-0,104	-2,201
Malta	-0,451	-0,239	0,261	-1,069	-0,806	-0,085	-0,667	1,693	3,007
Nizozemska	0,281	-0,059	0,095	0,172	1,224	0,360	0,540	-0,545	-0,616
Slovenija	-0,606	-0,315	0,288	-0,205	-0,302	-0,128	-0,640	0,753	1,046
Španjolska	0,829	0,150	-0,203	0,720	1,144	0,109	0,399	-1,148	-2,091
Švedska	0,997	0,216	-0,674	0,829	0,244	-0,413	0,523	0,093	-2,380
Nulti član	1,474	-0,272	-0,534	-0,076	0,782	1,232	0,549	0,123	-1,622

Tablica 72. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Visoko obrazovanje“

	1	2	3	4	5	6	7	8	9	Nulti član
ELT	3,064	1,699	4,404	1,649	-5,907	-1,279	2,167	0,988	-5,403	-1,486

Tablica 73. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „BDP po tržišnim cijenama“

	1	2	3	4	5
Godina	-3,9978	4,8723	0,8210	-2,9570	-0,4174
Belgija	-0,2004	-0,7744	-0,1423	0,2066	0,0367
Hrvatska	2,0011	-1,5791	-2,4433	3,4633	-0,0554
Češka	2,2001	0,3405	-1,0433	1,8237	0,1112
Danska	1,9333	1,1821	-0,2103	1,4614	0,1286

	1	2	3	4	5
Estonija	2,0002	0,7857	-1,8906	3,1303	0,1242
Francuska	-8,7750	-4,9201	8,5305	-13,7385	-0,3789
Mađarska	1,8344	0,6164	-1,4461	2,3330	-0,0252
Irska	1,2197	2,6262	-1,0741	2,5884	-0,1404
Italija	-6,1158	-0,1995	6,0345	-9,6491	-0,3221
Latvija	2,2270	0,6555	-2,0506	3,4477	0,0564
Litva	2,2032	0,2480	-1,5639	3,0061	0,2049
Luksemburg	2,1324	-0,2395	-1,3863	2,7374	0,2020
Malta	2,1137	0,8135	-2,3691	3,5776	0,5184
Nizozemska	-1,8108	-0,2997	0,9236	-1,6461	-0,0667
Slovenija	1,8595	-0,4024	-1,4544	2,8825	0,1903
Španjolska	-3,3829	-0,3897	2,4556	-4,7789	-0,1661
Švedska	-0,1418	-1,3313	0,1034	0,1693	0,0741
Nulti član	1,3655	-2,9385	1,0451	0,7847	0,4831

Tablica 74. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „BDP po tržišnim cijenama“

	1	2	3	4	5	Nulti član
GDP	1,095	-0,622	2,269	-0,636	-6,801	-1,852

Tablica 75. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „BDP po stanovniku“

	1	2	3	4	5	6	7
Godina	3,383	-3,152	-4,660	-0,958	-0,055	-1,677	-10,922
Belgija	1,886	-2,036	-1,020	-0,305	-1,179	-0,575	2,964
Hrvatska	2,248	1,771	-0,918	1,994	2,170	-2,272	1,296
Češka	0,385	1,920	0,385	0,803	0,641	2,204	1,409
Danska	-1,523	-2,133	0,367	-1,869	-1,867	-2,722	0,961
Estonija	0,761	2,144	1,767	1,434	1,257	4,248	0,518
Francuska	1,721	-1,542	-2,729	-0,140	-0,973	-0,298	2,243
Mađarska	2,367	1,731	-0,970	2,291	2,593	-2,434	0,259
Irska	-4,562	-2,677	1,656	-1,516	1,801	-2,891	-2,908
Italija	0,418	-0,345	-1,199	-1,868	-0,130	3,312	2,712
Latvija	1,824	1,492	0,809	2,095	2,058	1,037	1,049
Litva	1,544	1,097	1,109	2,024	1,884	1,789	0,487
Luksemburg	-4,950	-3,595	2,104	-4,902	-4,471	-4,684	-3,359
Malta	1,207	0,823	-0,354	0,767	0,304	-0,521	0,159
Nizozemska	0,960	-1,992	-0,911	-1,171	-1,684	-1,524	1,350
Slovenija	0,052	1,589	-0,490	0,492	0,453	2,175	0,977
Španjolska	-0,269	-0,919	-1,616	0,311	-0,264	0,690	1,331
Švedska	-1,069	-1,053	0,282	-1,073	-1,592	-1,369	1,076
Nulti član	3,047	-3,843	-1,796	-0,580	1,073	-4,031	12,507

Tablica 76. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „BDP po stanovniku“

	1	2	3	4	5	6	7	Nulti član
RGDP	-4,847	-1,410	-9,056	-0,564	-2,833	1,808	-2,601	8,411

Tablica 77. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Ukupne obveze financijskog sektora“

	1	2	3	4	5
Godina	3,037	4,269	3,040	3,473	0,138
Belgija	0,225	-0,390	0,061	0,279	0,430
Hrvatska	0,387	-0,271	0,214	0,444	0,468
Češka	0,513	-0,199	0,333	0,570	0,466
Danska	0,163	-0,412	0,001	0,217	0,404
Estonija	0,498	-0,336	0,314	0,547	0,465
Francuska	0,265	-0,380	0,096	0,317	0,421
Mađarska	0,380	-0,169	0,213	0,447	0,460
Irska	-0,094	-0,627	-0,235	-0,004	0,312
Italija	0,391	-0,404	0,211	0,436	0,446
Latvija	0,525	-0,267	0,342	0,582	0,465
Litva	0,386	-0,440	0,205	0,425	0,469
Luksemburg	-5,390	3,963	-2,494	-6,089	-6,793
Malta	-0,322	0,518	-0,438	-0,276	0,300
Nizozemska	-0,073	-0,714	-0,233	-0,034	0,335
Slovenija	0,340	-0,494	0,160	0,375	0,461
Španjolska	0,395	-0,271	0,224	0,462	0,444
Švedska	0,251	-0,448	0,078	0,292	0,422
Nulti član	-1,254	-1,184	-0,964	-1,039	-0,039

Tablica 78. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Ukupne obveze financijskog sektora“

	1	2	3	4	5	Nulti član
TFS	-2,562	-0,085	3,887	-1,162	-0,446	0,160

Tablica 79. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Neto vanjski (inozemni) dug“

	1	2	3	4	5	6	7	8	9
Godina	15,135	4,892	-2,218	-4,950	-32,250	-163,252	-115,689	0,566	24,368
Belgija	10,170	1,840	-1,329	-20,830	13,958	33,204	0,711	11,244	-3,800
Hrvatska	8,288	-44,635	12,480	34,532	33,175	34,376	35,196	15,143	-5,040
Češka	-9,661	-51,624	0,604	44,671	23,252	42,803	38,748	4,762	-17,145
Danska	2,935	0,683	0,474	-12,427	5,002	42,022	-1,112	2,079	-5,952
Estonija	-0,197	26,706	9,625	-18,083	-5,830	-26,639	-11,531	-16,674	32,837
Francuska	3,020	14,179	-0,041	-19,581	-4,273	14,722	1,236	13,657	-10,166
Mađarska	5,053	-60,052	1,253	41,490	37,494	29,828	48,931	11,820	-49,997
Irska	-9,123	-107,597	-0,953	-19,498	7,227	26,755	37,095	-14,034	19,082
Italija	-7,224	136,229	-40,753	-74,067	-73,468	-79,014	-78,674	-28,674	28,772

	1	2	3	4	5	6	7	8	9
Latvija	23,383	-59,402	31,858	37,762	40,486	53,396	40,758	24,154	6,694
Litva	10,256	-63,241	10,322	37,287	37,702	43,958	49,031	18,550	-0,415
Luksemburg	-37,515	-30,299	-2,029	-22,836	-34,727	-53,766	-39,039	-34,328	-30,672
Malta	-16,719	96,649	-1,215	16,010	-17,562	-79,890	-77,916	3,306	-14,371
Nizozemska	9,554	-4,505	21,274	6,650	3,850	14,866	-0,068	5,337	3,555
Slovenija	-4,562	-32,131	1,330	18,644	17,101	33,948	26,873	12,004	1,338
Španjolska	-6,422	103,377	-49,221	-48,500	-54,096	-8,688	-70,810	-16,964	20,070
Švedska	15,474	-29,240	11,543	25,121	18,809	26,636	12,368	16,137	1,733
Nulti član	-3,282	-102,957	5,234	26,242	48,135	148,602	11,693	27,477	-23,410

Tablica 80. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Neto vanjski (inozemni) dug“

	1	2	3	4	5	6	7	8	9	Nulti član
NED	0,188	12,681	16,336	-5,815	0,402	0,436	-0,171	1,557	-0,158	-10,673

Tablica 81. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Nominalni efektivni tečaj“

	1	2	3	4	5	6	7	8	9
Godina	10,044	-214,419	-71,786	-160,951	123,983	82,888	204,108	-10,901	-266,451
Belgija	7,500	12,791	12,616	-11,362	-8,093	0,691	9,312	0,209	13,552
Hrvatska	6,222	-4,180	-9,636	-10,148	8,140	1,186	15,322	-12,345	-2,365
Češka	9,899	36,169	-59,830	-13,348	-23,324	20,632	-106,627	10,193	-35,322
Danska	9,178	9,137	6,136	-9,237	-7,695	1,087	-1,940	-1,115	13,384
Estonija	24,413	8,139	-7,197	-19,699	-8,784	14,005	-29,251	11,781	24,640
Francuska	1,653	9,823	34,503	0,029	-7,770	12,521	10,459	5,782	-2,712
Mađarska	-20,766	-101,147	-51,360	-1,991	111,398	-84,347	50,548	-17,615	-106,218
Irska	-11,554	4,376	-17,224	-17,130	-2,580	-15,325	17,266	-9,535	-7,113
Italija	11,811	-52,239	37,384	19,938	1,638	13,757	14,992	-5,759	-60,043
Latvija	-5,055	6,399	48,940	59,395	-5,079	24,488	1,231	-1,186	39,470
Litva	-21,777	57,945	-21,475	70,924	-33,819	55,206	-67,296	12,086	69,131
Luksemburg	-9,663	-5,445	1,026	-19,029	4,619	-15,298	7,356	-8,020	12,404
Malta	3,707	0,179	-11,102	-8,903	-2,976	-0,944	-0,793	10,503	-4,962
Nizozemska	8,702	9,767	16,659	-11,733	-7,838	0,401	1,532	-0,393	13,326
Slovenija	22,714	-5,272	-0,270	-43,993	-7,610	-34,114	27,628	-1,987	28,654
Španjolska	5,040	10,979	4,341	-9,166	-7,867	5,792	32,161	4,359	13,318
Švedska	-20,055	4,790	-17,888	-16,356	-2,156	-3,897	9,764	-9,975	-24,983
Nulti član	22,004	2,139	-34,289	-41,838	0,198	-4,142	-8,542	-12,951	-15,755

Tablica 82. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Nominalni efektivni tečaj“

	1	2	3	4	5	6	7	8	9	Nulti član
NEER	25,042	46,117	0,834	-45,065	46,372	0,082	-0,241	62,450	46,630	39,233

Tablica 83. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Inozemna izravna ulaganja“

	1	2	3	4	5	6	7	8
Godina	-192,721	93,784	6,899	66,965	-88,405	139,150	-115,511	82,888
Belgija	-1,314	4,808	6,967	-6,290	-7,989	5,931	-3,467	-1,379
Hrvatska	-0,373	1,379	1,116	-4,811	-7,394	5,491	-1,580	0,219
Češka	-10,586	6,170	-6,983	-3,503	-11,961	13,164	-6,770	3,830
Danska	1,241	-0,530	-2,497	4,867	-5,518	6,256	-11,809	-2,569
Estonija	23,354	-9,374	-14,142	-13,250	2,687	-10,592	10,203	-9,743
Francuska	-0,654	1,117	-15,940	-3,828	-7,129	4,377	-2,345	0,597
Mađarska	16,345	-0,729	1,490	-10,115	-4,932	-8,676	19,572	-5,021
Irska	29,706	-13,594	2,907	-19,432	6,483	-15,897	16,542	-13,272
Italija	7,393	-2,678	-10,478	-10,529	-3,537	-2,030	1,463	-2,868
Latvija	-7,222	6,673	-11,541	-3,912	-11,801	10,936	-4,531	2,394
Litva	-7,787	4,304	-2,869	-1,499	-10,015	16,423	-7,785	1,336
Luksemburg	74,647	-33,742	65,203	35,497	131,148	-97,676	31,799	-45,268
Malta	-49,872	-13,493	18,877	37,063	6,100	-12,931	-1,675	40,548
Nizozemska	24,366	-2,600	9,499	-7,377	-2,883	-14,384	23,409	-7,576
Slovenija	-0,932	1,566	-11,252	-7,384	-7,590	6,061	-3,701	0,597
Španjosla	-7,743	3,404	-4,154	-3,492	-9,161	16,356	-7,645	0,593
Švedska	-10,400	5,067	-3,834	-3,707	-10,865	12,355	-6,638	3,758
Nulti član	80,015	-42,329	22,391	-21,711	45,685	-64,764	45,063	-34,008

Tablica 84. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Inozemna izravna ulaganja“

	1	2	3	4	5	6	7	8	Nulti član
DIRE	-22,554	-22,831	4,256	0,155	-34,018	-11,363	-0,215	-22,749	-5,141

Tablica 85. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Ukupno zaposleni“

	1	2	3	4	5	6
Godina	1,812	0,748	-2,669	-1,916	9,308	1,666
Belgija	-0,630	0,332	-1,474	-0,154	-1,025	-1,039
Hrvatska	0,775	0,665	-0,027	0,005	-1,059	-0,222
Češka	-2,166	-2,335	-2,294	0,603	-1,768	-1,453
Danska	-0,601	0,461	-2,210	0,214	-0,678	-1,035
Estonija	0,824	0,892	1,353	0,252	0,034	1,009
Francuska	-6,320	-6,686	-5,567	0,578	-7,021	-4,316
Mađarska	-0,374	0,341	-1,329	-0,308	-0,237	-0,803
Irska	2,030	2,218	-0,975	-1,318	1,047	1,066
Italija	-2,758	-2,968	2,422	0,249	-0,016	-4,621
Latvija	0,464	0,320	1,020	0,421	-1,414	0,247
Litva	0,231	-0,060	0,825	0,500	-2,100	-0,393
Luksemburg	2,021	2,148	1,831	2,760	2,450	2,516
Malta	2,108	2,225	1,919	3,238	2,446	2,609
Nizozemska	2,059	0,565	2,336	-2,142	2,977	1,920
Slovenija	0,707	0,814	1,163	0,020	-0,439	0,783

Španjolska	-3,605	-1,321	7,252	-2,303	0,515	5,472
Švedska	0,315	0,130	-0,031	-0,531	-0,007	-0,686
Nulti član	-5,021	-2,332	6,259	2,004	-6,298	1,058

Tablica 86. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Ukupno zaposleni“

	1	2	3	4	5	6	Nulti član
TEMP	-3,542	-2,834	-3,396	-7,470	-1,140	-4,545	10,630

Tablica 87. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Godišnji podaci o stopi nezaposlenosti“

	1	2	3	4	5	6	7
Godina	-10,514	-5,224	14,154	-3,405	-9,242	-9,030	1,150
Belgija	0,398	0,263	1,184	-0,470	-0,274	-0,845	-0,340
Hrvatska	8,580	-1,795	-5,440	1,487	1,574	1,521	-0,977
Češka	-3,695	-1,922	3,704	-0,315	-0,893	-3,703	0,085
Danska	-4,435	-0,003	4,575	-0,367	-1,028	-0,292	-0,256
Estonija	7,166	-2,449	-5,252	0,511	0,133	0,767	-0,156
Francuska	0,325	1,762	0,013	0,205	0,171	1,567	-0,921
Mađarska	-3,213	1,994	2,809	-0,231	-0,385	0,765	0,236
Irska	-1,058	2,782	-1,208	-0,312	-0,831	0,902	0,817
Italija	0,492	2,975	-1,852	0,758	0,817	2,309	-0,221
Latvija	3,777	2,736	-0,598	-0,700	-0,072	0,617	0,690
Litva	-0,779	2,416	-5,169	-2,269	-0,363	0,990	0,294
Luksemburg	-7,442	-7,629	7,060	1,691	1,181	0,784	-0,086
Malta	0,607	-4,625	0,537	0,390	-1,102	-2,984	0,080
Nizozemska	-4,225	-2,116	4,511	-2,215	-3,344	-5,693	1,666
Slovenija	-3,163	2,246	3,640	-0,371	-0,704	1,688	0,048
Španjolska	10,311	3,507	-11,720	1,695	5,343	4,940	-1,416
Švedska	-3,154	1,375	2,853	-0,269	-0,122	0,888	-0,271
Nulti član	0,436	1,593	-0,266	-0,924	0,136	4,245	-0,627

Tablica 88. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Godišnji podaci o stopi nezaposlenosti“

	1	2	3	4	5	6	7	Nulti član
URAD	1,040	1,596	-0,892	2,452	-2,822	-1,684	-0,927	0,017

Tablica 89. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Stopa nezaposlenosti mladih“

	1	2	3	4	5
Godina	9,944	-18,687	-18,744	-4,603	16,880
Belgija	0,708	-2,826	-3,694	-1,207	0,675
Hrvatska	0,548	3,595	6,926	5,854	-0,020
Češka	4,256	-4,928	-4,761	-6,013	5,777
Danska	-2,265	-1,871	-1,782	0,169	-4,264

	1	2	3	4	5
Estonija	-2,802	2,419	-3,433	1,735	2,047
Francuska	-1,667	2,626	-1,125	-3,787	1,162
Mađarska	-0,637	2,973	4,571	1,641	-0,986
Irska	0,141	2,110	4,994	1,692	-0,143
Italija	-4,221	3,387	3,817	5,961	-6,202
Latvija	0,766	2,214	4,449	1,719	0,587
Litva	-2,537	1,754	0,288	1,917	-3,125
Luksemburg	-0,071	-4,957	-5,387	-1,589	-0,872
Malta	1,532	1,525	1,089	-4,458	0,864
Nizozemska	0,284	-4,842	-5,355	-1,297	-0,417
Slovenija	-2,311	3,154	1,094	-0,127	-3,341
Španjolska	1,828	1,964	6,659	4,481	1,466
Švedska	2,359	-0,263	0,088	-4,249	1,227
Nulti član	-3,999	8,115	8,325	2,293	-5,638

Tablica 90. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Stopa nezaposlenosti mladih“

	1	2	3	4	5	Nulti član
YUR	-0,443	-0,376	0,413	-0,152	0,346	0,376

Tablica 91. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Srednji ekvivalent neto prihoda“

	1	2	3	4
Godina	-1,308	-0,281	2,462	1,414
Belgija	-0,329	0,676	1,408	0,358
Hrvatska	0,834	-0,392	-0,791	-0,402
Češka	0,787	-0,613	-1,139	-0,868
Danska	-0,814	0,850	2,321	1,577
Estonija	0,404	-0,428	-1,471	-0,733
Francuska	-0,473	0,344	1,059	0,377
Mađarska	1,205	-0,763	-1,999	-1,290
Irska	-1,371	-0,291	0,289	1,176
Italija	0,194	-0,240	-0,367	-0,645
Latvija	0,826	-0,725	-1,680	-0,991
Litva	0,723	-0,627	-1,651	-0,813
Luksemburg	-0,983	1,214	3,864	2,479
Malta	0,141	-0,082	-0,458	-0,323
Nizozemska	-0,568	0,428	0,902	0,549
Slovenija	0,314	-0,231	-0,481	-0,557
Španjolska	0,374	-0,249	-0,513	-0,719
Švedska	-0,652	0,613	0,943	0,958
Nulti član	0,664	-0,482	0,207	0,294



Tablica 92. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Srednji ekvivalent neto prihoda“

	1	2	3	4	Nulti član
MENI	-1,477	0,456	2,084	-2,492	-1,163

Tablica 93. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Dolasci u turističke smještajne objekte“

	1	2	3	4	5	6	7	8
Godina	-3,652	-1,900	-0,490	-5,921	2,968	1,119	1,405	1,713
Belgija	2,847	1,572	0,890	1,121	-3,092	0,194	-1,273	2,113
Hrvatska	-1,142	-0,214	0,163	-0,008	1,491	0,157	-1,081	-3,375
Češka	1,547	0,796	0,828	0,651	-1,267	0,128	-1,369	0,140
Danska	1,692	1,670	0,735	0,554	-1,433	0,203	-1,985	0,989
Estonija	1,312	1,265	0,242	0,433	-1,215	0,135	-1,260	0,482
Francuska	-4,946	-7,824	0,030	-3,533	5,465	-1,900	8,540	-1,368
Mađarska	1,733	0,893	0,683	0,008	-1,327	0,148	-1,632	0,222
Irska	0,161	2,253	0,976	1,126	-0,709	0,206	-3,497	2,702
Italija	-3,060	-5,196	-0,409	-3,368	3,197	-0,568	5,366	-1,488
Latvija	0,880	1,937	-0,623	1,181	-0,427	0,395	-1,960	-0,632
Litva	0,708	1,763	-1,067	0,975	-0,144	0,354	-1,752	-1,129
Luksemburg	1,086	1,843	0,293	1,090	-0,944	0,386	-2,081	0,024
Malta	1,070	1,661	0,332	0,844	-1,200	0,303	-1,817	0,058
Nizozemska	1,191	-0,392	0,249	0,371	-1,004	0,051	0,935	0,343
Slovenija	0,936	1,422	0,377	0,834	-0,751	0,278	-1,561	0,142
Španjolska	-5,982	-4,516	-4,362	1,011	3,035	0,846	4,716	1,180
Švedska	2,223	-0,208	0,223	0,931	-1,830	0,135	1,098	-0,253
Nulti član	2,303	-1,172	-0,538	4,291	-2,132	1,416	-0,542	0,007

Tablica 94. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Dolasci u turističke smještajne objekte“

	1	2	3	4	5	6	7	8	Nulti član
ATAE	2,019	-0,909	3,339	-0,193	3,345	0,510	1,490	0,620	-1,859

Tablica 95. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Noćenja u turističkim smještajnim objektima“

	1	2	3	4	5	6	7	8
Godina	-1,159	-1,795	0,042	0,235	-0,743	0,143	-1,614	-0,436
Belgija	0,246	-0,242	0,343	0,156	0,465	0,327	0,520	0,222
Hrvatska	-0,255	0,266	-0,036	-0,397	-0,015	-0,328	-0,212	0,193
Češka	0,266	-0,166	0,210	0,076	0,358	0,234	0,406	0,092
Danska	0,356	0,024	0,394	0,360	0,517	0,460	0,755	0,497
Estonija	0,293	0,916	0,512	0,588	0,496	0,474	0,522	0,563
Francuska	-1,209	-0,946	-0,668	-0,111	-0,944	-0,602	-0,917	-0,609
Mađarska	0,195	-0,026	0,314	0,253	0,512	0,304	0,573	0,390
Irska	0,211	-0,340	0,304	0,244	0,493	0,434	0,765	0,246

Italija	-1,089	-0,581	-1,593	-1,013	-2,058	-1,311	-2,438	-2,052
Latvija	0,478	0,533	0,604	0,637	0,719	0,592	0,842	0,724
Litva	0,502	0,570	0,576	0,644	0,682	0,589	0,733	0,666
Luksemburg	0,477	0,617	0,529	0,551	0,470	0,541	0,672	0,580
Malta	0,264	0,354	0,485	0,383	0,417	0,339	0,594	0,536
Nizozemska	0,159	-0,524	0,063	-0,125	0,176	0,099	0,130	-0,106
Slovenija	0,398	0,345	0,508	0,424	0,572	0,454	0,616	0,522
Španjolska	-1,769	-0,372	-2,877	-2,814	-3,224	-2,784	-3,928	-3,278
Švedska	0,212	0,253	0,277	0,413	0,345	0,305	0,427	0,464
Nulti član	-0,154	0,733	0,092	0,309	-0,024	0,137	0,182	-0,294

Tablica 96. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Noćenja u turističkim smještajnim objektima“

	1	2	3	4	5	6	7	8	Nulti član
NISTA	-2,242	-1,544	-0,584	-1,008	0,226	-0,911	1,211	0,215	2,280

Tablica 97. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Uvoz roba i usluga“

	1	2	3
Godina	-1,567	-0,484	-2,953
Belgija	-0,285	-0,571	-1,208
Hrvatska	0,410	0,778	0,933
Češka	0,287	-0,149	-0,014
Danska	0,348	-0,144	-0,675
Estonija	0,129	1,080	1,227
Francuska	-2,050	-0,953	-1,635
Mađarska	0,336	0,004	-0,309
Irska	-1,529	-1,023	2,181
Italija	1,089	-0,578	-0,982
Latvija	0,163	1,045	1,287
Litva	0,209	0,692	0,739
Luksemburg	0,242	-0,012	0,321
Malta	0,182	1,189	1,384
Nizozemska	-1,034	-0,770	-1,545
Slovenija	0,341	0,652	0,644
Španjolska	1,005	-0,459	-0,799
Švedska	0,200	-0,283	-0,871
Nulti član	-0,098	0,719	0,689

Tablica 98. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Uvoz roba i usluga“

	1	2	3	Nulti član
IGS	0,524	-2,420	-0,900	-1,872

Tablica 99. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Izvoz roba i usluga“

	1	2	3	4	5	6	7	8	9
Godina	0,066	0,293	0,135	-2,546	-0,217	-0,542	0,454	0,561	0,291
Belgija	-0,072	-0,123	-0,316	-0,844	0,130	0,094	0,657	-0,050	0,004
Hrvatska	0,250	0,076	0,622	0,391	0,240	-0,110	-0,734	-0,261	-0,102
Češka	0,050	0,057	0,163	0,003	0,057	-0,045	0,165	-0,090	0,050
Danska	0,078	0,034	0,362	-0,597	-0,056	-0,229	-0,130	-0,661	-0,008
Estonija	0,288	0,021	0,587	0,719	0,278	-0,011	-0,704	-0,055	-0,081
Francuska	-0,409	-0,211	-0,772	-1,485	-0,223	0,754	0,965	1,327	0,034
Mađarska	0,075	0,033	0,320	-0,171	0,022	-0,191	-0,230	-0,495	0,024
Irska	-0,963	0,191	-1,802	3,413	-0,773	-0,272	0,390	1,500	0,388
Italija	-0,036	-0,205	-0,602	-0,898	0,167	0,183	1,092	-0,011	-0,070
Latvija	0,286	0,108	0,711	0,936	0,338	-0,014	-0,712	-0,067	-0,086
Litva	0,243	0,060	0,460	0,590	0,224	-0,037	-0,500	-0,052	-0,039
Luksemburg	0,005	0,040	0,125	0,017	-0,019	-0,189	-0,155	-0,113	-0,003
Malta	0,311	0,115	0,693	0,865	0,316	-0,011	-0,751	-0,058	-0,062
Nizozemska	-0,354	0,006	-0,651	-1,362	-0,423	0,605	0,458	0,888	0,124
Slovenija	0,168	0,050	0,466	0,111	0,197	-0,118	-0,527	-0,255	-0,078
Španjolska	-0,180	-0,047	-0,361	-0,746	0,004	0,164	0,575	0,187	0,060
Švedska	0,103	0,009	0,258	-0,778	0,036	-0,110	0,077	-0,744	-0,056
Nulti član	-0,001	0,064	0,360	-0,086	0,525	0,586	-0,227	0,818	0,111

Tablica 100. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Izvoz roba i usluga“

	1	2	3	4	5	6	7	8	9	Nulti član
EGS	-0,847	0,394	-1,194	-1,649	-1,040	-0,861	1,602	-1,750	0,766	-1,569

Tablica 101. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Izvoz nafte i naftnih derivata po zemljama partnerima“

	1	2	3	4	5	6	7
Godina	-2,693	-0,890	-4,322	-0,028	-7,152	5,859	0,353
Belgija	-19,901	14,026	-7,444	-10,136	-6,200	-4,179	30,498
Hrvatska	0,751	-1,324	0,936	0,755	0,834	0,200	-2,138
Češka	0,768	-1,281	0,901	0,736	0,809	0,198	-2,137
Danska	0,870	-1,235	0,832	0,764	0,725	0,204	-2,127
Estonija	0,672	-1,159	0,810	0,650	0,693	0,162	-1,912
Francuska	0,931	-0,999	0,613	0,625	0,550	0,230	-1,870
Mađarska	0,626	-1,207	0,847	0,669	0,709	0,162	-1,887
Irska	0,545	-1,620	1,267	0,860	1,077	0,135	-2,388
Italija	0,830	-1,175	0,731	0,720	0,649	0,206	-1,985
Latvija	0,578	-1,396	1,066	0,740	0,892	0,150	-2,144
Litva	0,447	-1,288	0,978	0,671	0,835	0,094	-1,890
Luksemburg	0,773	-0,995	0,657	0,626	0,591	0,118	-1,792
Malta	0,640	-0,536	0,262	0,389	0,251	0,148	-1,044
Nizozemska	0,995	-1,139	0,698	0,690	0,568	0,184	-2,041
Slovenija	0,625	-1,182	0,829	0,678	0,745	0,112	-1,880

Španjolska	0,747	-1,085	0,740	0,620	0,622	0,190	-1,898
Švedska	0,586	-0,708	0,434	0,459	0,380	0,118	-1,301
Nulti član	-8,541	-4,262	5,252	0,511	4,591	-1,522	-0,062

Tablica 102. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Izvoz nafte i naftnih derivata po zemljama partnerima“

	1	2	3	4	5	6	7	Nulti član
EOPP	14,180	6,389	-9,311	0,489	-7,128	3,140	-0,502	-3,570

Tablica 103. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Deflacionirane cijene nekretnina“

	1	2	3	4	5	6	7
Godina	189,380	-13,244	13,341	13,341	13,828	12,896	-13,307
Belgija	-128,076	-0,612	-1,201	4,125	36,620	46,985	-5,565
Hrvatska	70,467	1,331	-1,628	-2,833	27,688	-42,589	2,912
Češka	-1,322	1,929	-2,230	-0,927	-55,362	26,136	1,011
Danska	-27,879	1,101	-1,392	-2,277	48,715	-32,560	2,354
Estonija	12,891	3,745	32,992	0,803	11,680	-51,516	-1,031
Francuska	50,770	4,011	-4,334	-3,000	34,063	23,299	3,078
Mađarska	-7,888	-45,912	10,863	-3,532	22,682	9,969	3,601
Irska	44,476	1,842	-7,583	-2,258	-57,649	-43,945	-3,100
Italija	-197,383	4,106	-4,427	-1,770	2,609	32,638	1,852
Latvija	-59,423	3,492	0,506	0,544	-60,552	-50,975	-0,484
Litva	42,968	3,728	-1,814	3,521	-55,706	35,402	-1,172
Luksemburg	40,473	5,345	-3,872	1,472	-55,874	4,534	0,436
Malta	53,574	1,847	-2,146	-1,235	53,818	94,097	1,317
Nizozemska	-76,115	6,088	-4,645	0,698	36,159	9,960	1,186
Slovenija	35,305	1,714	-2,012	-4,309	24,447	-9,589	4,380
Španjolska	55,379	6,061	-6,416	1,531	66,487	-1,884	-1,430
Švedska	30,638	2,166	-2,463	2,393	-20,823	-4,432	-2,289
Nulti član	-61,254	2,148	-1,871	-7,205	59,127	45,440	7,101

Tablica 104. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Deflacionirane cijene nekretnina“

	1	2	3	4	5	6	7	Nulti član
HPI	0,069	57,003	56,780	-56,422	-55,948	56,456	-56,581	-1,145

Tablica 105. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Stopa recikliranja komunalnog otpada“

	1	2	3	4	5	6	7	8
Godina	-1,613	-0,358	-0,008	-0,857	-3,708	0,129	-0,902	1,206
Belgija	1,286	-1,193	1,089	-0,877	0,624	1,579	0,817	0,693
Hrvatska	0,181	1,016	0,035	0,699	2,339	0,054	0,025	0,455

Češka	0,239	0,897	-0,087	0,378	1,695	-0,112	0,399	0,193
Danska	-0,661	-0,811	-0,252	-0,699	-1,086	-0,486	-0,591	-0,544
Estonija	0,434	0,615	0,290	0,256	0,948	0,065	0,004	-0,154
Francuska	-1,645	-0,053	-0,701	-0,212	-1,049	-1,281	-1,230	-0,754
Mađarska	-0,027	0,754	-0,055	0,317	1,310	-0,228	0,177	0,165
Irska	1,413	-0,579	1,042	-0,361	1,279	1,837	0,914	0,363
Italija	-1,550	1,143	-1,530	0,191	-0,194	-2,053	-0,461	0,191
Latvija	0,588	1,203	0,123	0,621	1,833	-0,041	0,708	0,236
Litva	0,720	1,149	-0,227	0,460	2,269	-0,107	0,920	0,596
Luksemburg	0,337	-0,711	0,221	-0,526	-0,062	0,187	0,026	-0,151
Malta	0,431	-3,104	1,362	0,052	-7,285	2,077	-0,644	-0,430
Nizozemska	-1,840	-1,300	-1,117	-0,704	-2,546	-1,792	-1,634	-1,124
Slovenija	-1,256	1,437	-1,116	0,169	0,519	-1,367	-0,161	0,725
Španjolska	1,251	-0,068	0,886	-0,024	0,925	1,246	0,677	0,110
Švedska	0,284	-0,329	0,054	-0,358	-0,251	0,120	0,136	-0,325
Nulti član	0,305	0,155	0,058	-0,533	1,240	-0,238	-0,006	0,302

Tablica 106. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Stopa recikliranja komunalnog otpada“

	1	2	3	4	5	6	7	8	Nulti član
RRMW	0,793	-0,261	-0,677	-0,814	-0,531	-0,022	0,271	0,147	0,080

Tablica 107. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Odlaganje komunalnog otpada“

	1	2	3	4	5	6
Godina	2,583	-0,068	-2,991	0,479	-0,610	2,626
Belgija	0,358	-0,386	-0,037	-0,269	0,352	-0,173
Hrvatska	-0,639	-0,162	-0,339	0,105	0,631	-0,326
Češka	0,484	-0,047	-0,174	-0,386	-0,271	-0,026
Danska	-0,156	-0,377	-0,057	-0,130	0,492	-0,377
Estonija	-0,176	-0,284	-0,057	-0,085	0,492	-0,355
Francuska	0,101	0,895	-0,318	-0,030	-1,520	0,613
Mađarska	-0,251	0,015	0,024	0,123	0,144	-0,185
Irska	-0,451	-0,198	0,046	0,286	0,630	-0,334
Italija	-0,131	1,324	0,143	0,479	-0,431	3,286
Latvija	-0,324	-0,291	-0,109	-0,012	0,491	-0,364
Litva	-0,122	-0,288	-0,158	-0,019	0,423	-0,218
Luksemburg	-0,247	-0,310	-0,081	-0,021	0,496	-0,388
Malta	-0,319	-0,272	-0,107	-0,034	0,501	-0,393
Nizozemska	0,663	-0,384	-0,112	-0,376	0,337	-0,021
Slovenija	-0,127	-0,260	-0,099	-0,041	0,455	-0,285
Španjolska	-0,058	1,099	1,705	0,372	-2,090	-0,517
Švedska	0,265	-0,284	-0,004	-0,133	0,316	-0,209
Nulti član	-1,173	-0,264	0,454	-0,134	1,325	-0,341

Tablica 108. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Odlaganje komunalnog otpada“

	1	2	3	4	5	6	Nulti član
DL	-1,132	-0,288	1,463	-0,432	-0,625	2,550	-0,626

Tablica 109. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Nastali komunalni otpad - kilogram po stanovniku“

	1	2	3	4	5	6	7
Godina	11,978	11,032	-10,671	-16,453	2,508	-4,670	-5,742
Belgija	-0,584	-3,050	-1,625	-0,542	1,202	4,099	-0,033
Hrvatska	2,315	11,909	-0,281	4,409	4,044	2,652	0,881
Češka	6,091	6,609	5,038	-2,281	3,153	5,268	-1,332
Danska	-6,778	-7,946	5,542	-9,974	-6,198	-0,610	-2,133
Estonija	-3,760	-3,815	3,983	4,992	1,508	-1,714	2,244
Francuska	0,482	-2,971	-0,300	1,031	-0,919	-0,837	1,281
Mađarska	6,853	4,683	3,087	6,332	1,448	4,625	-3,727
Irska	-5,911	-3,757	-5,698	-6,267	-4,798	-2,351	1,451
Italija	0,775	-2,907	-0,578	0,764	0,045	-0,788	0,743
Latvija	3,705	9,788	-1,860	4,484	3,107	-0,693	3,122
Litva	2,122	1,971	-1,037	1,577	-0,107	2,162	-0,563
Luksemburg	-0,549	-2,841	-2,357	-1,000	-2,465	-0,099	0,515
Malta	-1,954	-4,289	3,891	-11,465	-2,996	-2,292	-0,429
Nizozemska	-1,749	-3,674	-1,408	0,046	-0,264	-4,104	0,792
Slovenija	-4,688	1,155	-0,375	5,564	-0,920	-2,468	-0,719
Španjolska	-3,486	-0,986	-0,982	6,602	1,872	-1,578	-1,137
Švedska	1,038	-3,221	0,183	1,048	2,278	1,614	0,565
Nulti član	-6,123	-3,338	5,238	5,198	0,051	2,932	1,389

Tablica 110. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Nastali komunalni otpad - kilogram po stanovniku“

	1	2	3	4	5	6	7	Nulti član
GMWK	0,786	-1,693	-0,880	1,036	-0,880	-0,397	-1,481	0,950

Tablica 111. Elementi matrice  $W_1$  i vektora  $B_1$  za varijablu „Nastali komunalni otpad – prikaz u tisućama tona“

	1	2	3	4	5
Godina	8,016	1,778	-7,070	-0,343	-0,484
Belgija	0,494	1,041	-0,723	-0,023	-0,960
Hrvatska	1,795	0,775	-0,667	1,814	0,345
Češka	-1,217	0,877	1,122	0,208	-0,584
Danska	1,060	-1,606	-1,148	0,530	0,371
Estonija	1,067	1,281	2,243	2,059	1,852
Francuska	-9,100	-5,867	0,424	-4,823	-5,134
Mađarska	2,080	1,003	-2,420	-0,416	-0,309

Irska	2,923	-0,036	-2,109	1,396	0,229
Italija	-2,831	-5,090	0,298	-2,949	-3,079
Latvija	0,504	1,648	0,102	1,505	1,934
Litva	-1,389	0,903	1,103	0,702	1,467
Luksemburg	2,523	2,362	2,450	2,503	2,349
Malta	2,857	2,901	3,340	2,938	2,668
Nizozemska	0,464	0,402	-0,948	-1,871	-0,545
Slovenija	-1,480	1,591	0,924	0,895	1,698
Španjolska	-1,745	-4,512	-1,283	-4,047	-0,926
Švedska	-0,064	-0,302	-0,471	0,363	0,005
Nulti član	-2,046	-2,527	2,139	0,830	1,452

Tablica 112. Elementi matrice  $W_2$  i vektora  $B_2$  za varijablu „Nastali komunalni otpad – prikaz u tisućama tona“

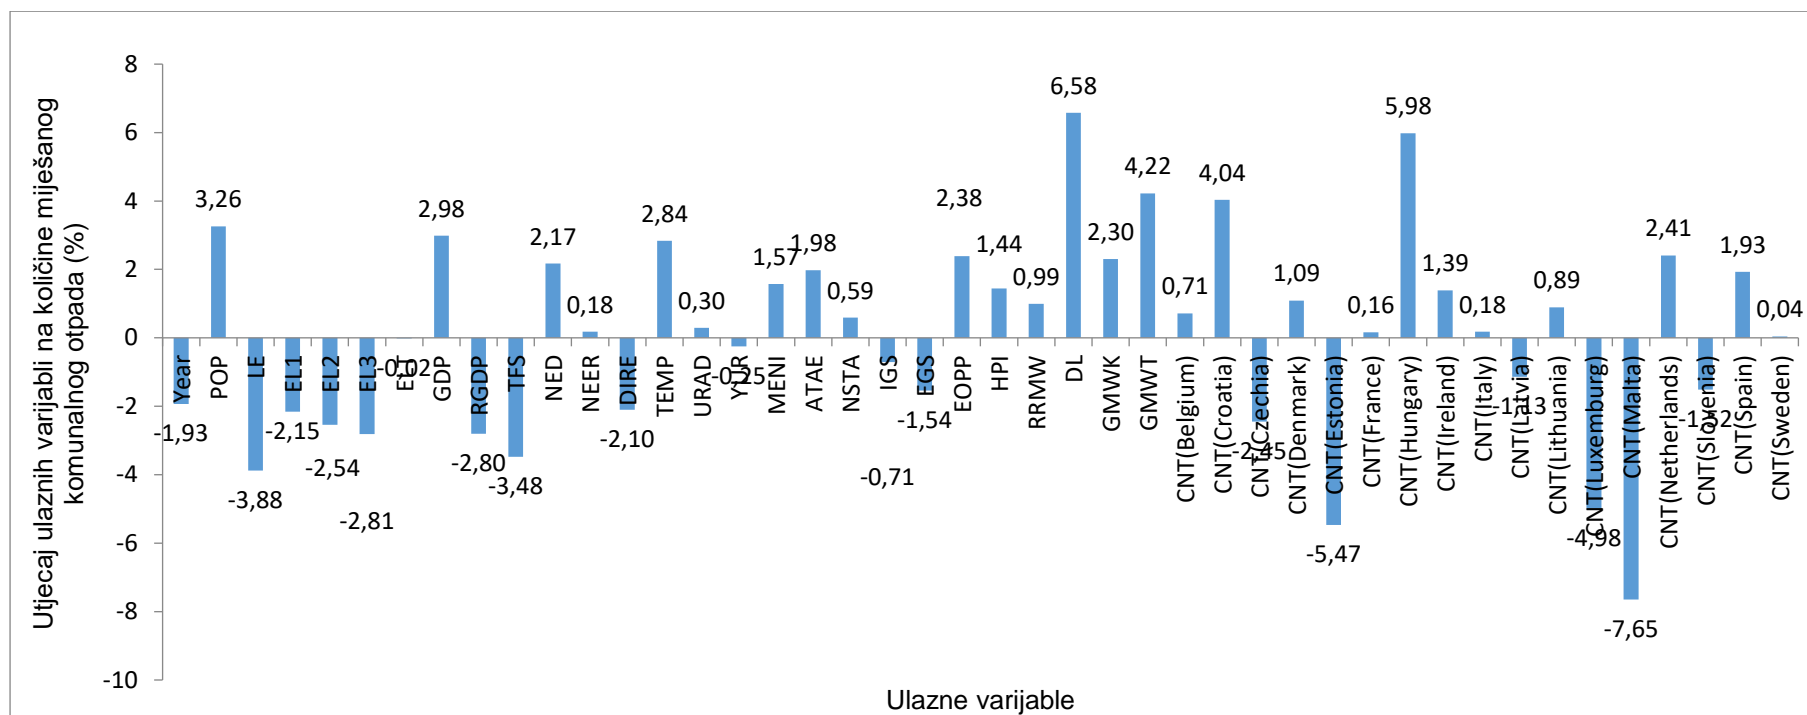
	1	2	3	4	5	Nulti član
GMWT	-2,023	-2,445	-2,610	-1,747	-3,073	4,077

## Prilog 5: Statistički pokazatelji za model ANN2


	Chi2	RMSE	MBE	MPE	SSE	AARD	r <sup>2</sup>	Skew	Kurt	Mean	StDev	Var
POP	9,0·10 <sup>9</sup>	9,4·10 <sup>4</sup>	1,2·10 <sup>4</sup>	5,2·10 <sup>-1</sup>	1,9·10 <sup>12</sup>	1,3·10 <sup>7</sup>	1,000	2,668	18,038	1,2·10 <sup>4</sup>	9,4·10 <sup>4</sup>	8,8·10 <sup>9</sup>
LE	6,2·10 <sup>-2</sup>	2,5·10 <sup>-1</sup>	1,1·10 <sup>-3</sup>	2,4·10 <sup>-1</sup>	1,4·10 <sup>1</sup>	4,7·10 <sup>1</sup>	0,995	-0,410	3,158	1,1E·10 <sup>-3</sup>	2,5·10 <sup>-1</sup>	6,2·10 <sup>-2</sup>
EL1	1,7·10 <sup>1</sup>	4,1	-3,3·10 <sup>-1</sup>	3,3	3,6·10 <sup>3</sup>	2,9·10 <sup>2</sup>	0,984	-8,501	82,372	-3,3·10 <sup>-1</sup>	4,0	1,6·10 <sup>1</sup>
EL2	3,6·10 <sup>1</sup>	5,9	-4,3·10 <sup>-1</sup>	1,7	7,7·10 <sup>3</sup>	3,7·10 <sup>2</sup>	0,981	-8,930	87,243	-4,3·10 <sup>-1</sup>	5,9	3,5·10 <sup>1</sup>
EL3	2,4·10 <sup>1</sup>	4,8	-3,5·10 <sup>-1</sup>	1,2	5,1·10 <sup>3</sup>	2,3·10 <sup>2</sup>	0,993	-9,610	97,223	-3,5·10 <sup>-1</sup>	4,8	2,3·10 <sup>1</sup>
ELT	1,2	1,1	-3,2·10 <sup>-2</sup>	2,5	2,7·10 <sup>2</sup>	1,3·10 <sup>2</sup>	0,994	-5,512	47,621	-3,2·10 <sup>-2</sup>	1,1	1,2
GDP	5,0·10 <sup>8</sup>	2,2·10 <sup>4</sup>	1,8·10 <sup>3</sup>	1,2·10 <sup>1</sup>	1,1·10 <sup>11</sup>	3,3·10 <sup>6</sup>	0,999	2,579	15,703	1,8·10 <sup>3</sup>	2,2·10 <sup>4</sup>	4,9·10 <sup>8</sup>
RGDP	1,2·10 <sup>6</sup>	1,1·10 <sup>3</sup>	-2,3·10 <sup>1</sup>	4,1	2,7·10 <sup>8</sup>	1,7·10 <sup>5</sup>	0,993	-0,055	5,199	-2,3·10 <sup>1</sup>	1,1·10 <sup>3</sup>	1,2·10 <sup>6</sup>
TFS	5,6·10 <sup>3</sup>	7,4·10 <sup>1</sup>	-6,3	8,3	1,2·10 <sup>6</sup>	9,6·10 <sup>3</sup>	0,991	-5,801	52,607	-6,3	7,4·10 <sup>1</sup>	5,4·10 <sup>3</sup>
NED	5,3·10 <sup>3</sup>	7,2·10 <sup>1</sup>	2,4·10 <sup>1</sup>	2,8·10 <sup>1</sup>	1,0·10 <sup>6</sup>	1,0·10 <sup>4</sup>	0,977	2,006	5,009	2,4·10 <sup>1</sup>	6,8·10 <sup>1</sup>	4,6·10 <sup>3</sup>
NEER	7,1	2,6	9,8·10 <sup>-2</sup>	7,7	1,5·10 <sup>3</sup>	4,3·10 <sup>2</sup>	0,619	-0,182	0,569	9,8·10 <sup>-2</sup>	2,6	6,9
DIRE	1,2·10 <sup>4</sup>	1,1·10 <sup>2</sup>	-1,4·10 <sup>1</sup>	1,5·10 <sup>2</sup>	2,6·10 <sup>6</sup>	4,3·10 <sup>3</sup>	0,159	-8,411	71,364	-1,4·10 <sup>1</sup>	1,1·10 <sup>2</sup>	1,2·10 <sup>4</sup>
TEMP	5,90·10 <sup>4</sup>	2,41·10 <sup>2</sup>	-1,06·10 <sup>1</sup>	2,99	1,28·10 <sup>7</sup>	2,60·10 <sup>4</sup>	1,000	-8,716	108,276	-1,06·10 <sup>1</sup>	2,41·10 <sup>2</sup>	5,81·10 <sup>4</sup>
URAD	1,54	1,23	-6,56·10 <sup>-2</sup>	1,28·10 <sup>1</sup>	3,33·10 <sup>2</sup>	2,99·10 <sup>2</sup>	0,854	-0,066	1,422	-6,56·10 <sup>-2</sup>	1,23	1,51
YUR	2,96·10 <sup>1</sup>	5,39	-7,19·10 <sup>-1</sup>	5,56	6,32·10 <sup>3</sup>	7,22·10 <sup>2</sup>	0,751	-2,646	12,320	-7,19·10 <sup>-1</sup>	5,36	2,87·10 <sup>1</sup>
MENI	1,89·10 <sup>7</sup>	4,31·10 <sup>3</sup>	-1,72·10 <sup>3</sup>	3,58	3,45·10 <sup>9</sup>	4,46·10 <sup>5</sup>	0,991	-2,835	7,980	-1,72·10 <sup>3</sup>	3,96·10 <sup>3</sup>	1,57·10 <sup>7</sup>
ATAE	3,46·10 <sup>12</sup>	1,84·10 <sup>6</sup>	-8,86·10 <sup>4</sup>	1,26·10 <sup>5</sup>	7,48·10 <sup>14</sup>	2,52·10 <sup>8</sup>	0,998	-0,222	8,503	-8,86·10 <sup>4</sup>	1,84·10 <sup>6</sup>	3,40·10 <sup>12</sup>
NSTA	2,39·10 <sup>14</sup>	1,53·10 <sup>7</sup>	-1,41·10 <sup>6</sup>	2,01·10 <sup>1</sup>	5,14·10 <sup>16</sup>	1,28·10 <sup>9</sup>	0,986	-6,397	47,560	-1,41·10 <sup>6</sup>	1,53·10 <sup>7</sup>	2,33·10 <sup>14</sup>
IGS	2,17·10 <sup>8</sup>	1,46·10 <sup>4</sup>	-4,47·10 <sup>2</sup>	1,35·10 <sup>1</sup>	4,70·10 <sup>10</sup>	3,23·10 <sup>6</sup>	0,993	-0,354	3,554	-4,47·10 <sup>2</sup>	1,46·10 <sup>4</sup>	2,14·10 <sup>8</sup>
EGS	1,84·10 <sup>8</sup>	1,35·10 <sup>4</sup>	-7,16·10 <sup>1</sup>	9,41	4,00·10 <sup>10</sup>	2,92·10 <sup>6</sup>	0,994	-0,612	6,307	-7,16·10 <sup>1</sup>	1,35·10 <sup>4</sup>	1,82·10 <sup>8</sup>
EOPP	4,97·10 <sup>12</sup>	2,21·10 <sup>6</sup>	-1,31·10 <sup>5</sup>	8,58·10 <sup>1</sup>	1,07·10 <sup>15</sup>	4,04·10 <sup>8</sup>	0,998	-14,274	209,393	-1,31E·10 <sup>5</sup>	2,21·10 <sup>6</sup>	4,88·10 <sup>12</sup>
HPI	7,32	2,68	5,84·10 <sup>-2</sup>	6,57·10 <sup>1</sup>	1,59·10 <sup>3</sup>	5,05·10 <sup>2</sup>	0,915	-0,027	1,953	5,84·10 <sup>-2</sup>	2,69	7,22
RRMW	8,11·10 <sup>1</sup>	8,93	-1,68	2,25·10 <sup>1</sup>	1,70·10 <sup>4</sup>	8,57·10 <sup>2</sup>	0,982	-4,362	19,892	-1,68	8,7	7,72·10 <sup>1</sup>
DL	3,85·10 <sup>5</sup>	6,15·10 <sup>2</sup>	-5,27·10 <sup>1</sup>	1,35·10 <sup>1</sup>	8,29·10 <sup>7</sup>	5,91·10 <sup>4</sup>	0,996	-6,995	80,029	-5,27·10 <sup>1</sup>	6,14·10 <sup>2</sup>	3,77·10 <sup>5</sup>
GMWK	1,09·10 <sup>4</sup>	1,03·10 <sup>2</sup>	-1,79·10 <sup>1</sup>	2,73	2,29·10 <sup>6</sup>	7,61·10 <sup>3</sup>	0,986	-5,371	30,420	-1,79·10 <sup>1</sup>	1,02·10 <sup>2</sup>	1,04·10 <sup>4</sup>
GMWT	5,95·10 <sup>6</sup>	2,42·10 <sup>3</sup>	-2,45·10 <sup>2</sup>	6,13	1,28·10 <sup>9</sup>	9,62·10 <sup>4</sup>	0,999	-13,327	189,154	-2,45·10 <sup>2</sup>	2,41·10 <sup>3</sup>	5,81·10 <sup>6</sup>




## Prilog 6: Utjecaj ulaznih varijabli na izlazne vrijednosti




Slika 50. Utjecaj ulaznih varijabli na količine miješanoga komunalnog otpada za matematički model ANN1 korištenjem Yoon-ove metode za određivanje relativnog utjecaja ulaznih slojeva na izlazne slojeve



Slika 51. Utjecaj ulaznih varijabli na količine otpada od papira i kartona za matematički model ANN1 korištenjem Yoon-ove metode za određivanje relativnog utjecaja ulaznih slojeva na izlazne slojeve



Slika 52. Utjecaj ulaznih varijabli na količine otpada od drva za matematički model ANN1 korištenjem Yoon-ove metode za određivanje relativnog utjecaja ulaznih slojeva na izlazne slojeve



Slika 53 Utjecaj ulaznih varijabli na količine tekstilnog otpada za matematički model ANN1 korištenjem Yoon-ove metode za određivanje relativnog utjecaja ulaznih slojeva na izlazne slojeve