Model vrednovanja rezultata prognoza prijevozne potražnje u cestovnom prometu

Jakovljević, Marijan

Doctoral thesis / Disertacija

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:084819

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

Sveučilište u Zagrebu

Fakultet prometnih znanosti

Marijan Jakovljević

MODEL VREDNOVANJA REZULTATA PROGNOZA PRIJEVOZNE POTRAŽNJE U CESTOVNOM PROMETU

DOKTORSKI RAD

Zagreb, 2020.

Sveučilište u Zagrebu

Fakultet prometnih znanosti

Marijan Jakovljević

MODEL VREDNOVANJA REZULTATA PROGNOZA PRIJEVOZNE POTRAŽNJE U CESTOVNOM PROMETU

DOKTORSKI RAD

Mentor:

doc. dr. sc. Marko Šoštarić

Zagreb, 2020.

University of Zagreb

Faculty of Transport and Traffic Sciences

Marijan Jakovljević

MODEL FOR VALIDATION OF RESULTS OF THE ROAD TRANSPORT DEMAND FORECASTS

DOCTORAL THESIS

Supervisor:

Asst. Prof. Marko Šoštarić, Ph. D.

Zagreb, 2020

Informacije o mentoru

Marko Šoštarić rođen je 30. travnja 1980. u Karlovcu. Osnovnu školu i Prirodoslovno-matematičku gimnaziju završio je u Karlovcu. Nakon završene gimnazije upisao je na Fakultetu prometnih znanosti Sveučilišta u Zagrebu sveučilišni dodiplomski studij cestovnog smjera. Diplomirao je 2004. godine s temom *Svjetlosna signalizacija kao čimbenik sigurnosti cestovnog prometa*. Na istom fakultetu je magistrirao 2010. godine na temi *Model mjerenja tranzitnog prometa na gradskim obilaznicama* te doktorirao 2014. godine s disertacijom *Model utvrđivanja udjela tranzitnog prometa u cestovnom prometnom toku*.

Pri kraju diplomskog studija zaposlio se u tvrtki Peek Traffic u kojoj je radio do 2005. Od 2005. do 2010. radio je na Institutu prometa i veza, a od 2010. do danas zaposlen je na Fakultetu prometnih znanosti Sveučilišta u Zagrebu.

Na fakultetu sudjeluje u nastavi na kolegijima preddiplomskog i diplomskog studija: Osnove prometnog inženjerstva, Osnove prometne infrastrukture, Parkiranje i garaže, Teorija prometnih tokova, Upravljanje prometnim sustavom u urbanim sredinama i Prometno tehnološko projektiranje te na kolegiju Prometno modeliranje doktorskog studija. Autor je priručnika u nastavi *Parkiranje i garaže*.

Kao voditelj, istraživač, autor ili suradnik sudjelovao je u preko 200 znanstveno-istraživačkih, razvojnih i stručnih projekta. Neki od značajnijih u posljednje vrijeme su *SPARK Sense - Inteligentna rješenja za reguliranje prometa u mirovanju, Razvoj inovativnih metoda utvrđivanja modalne raspodjele putovanja – Studija slučaja prijevoza na zahtjev u Gradu Zagrebu, HeReach – Innovative Mobility to Cope with Transport Poverty, Sustainable Urban Mobility Boost Smart Toolbox, Studija za pružanje multimodalnih informacija u prometu, Masterplan prometnog razvitka grada Zagreba i okolnog područja, Plan održive mobilnosti grada Splita, Prometni elaborat za uspostavljanje zone naplate zagušenja u gradu Dubrovniku*.

Rezultate znanstveno istraživačkog rada objavio je u 40-tak radova u časopisima i zbornicima znanstvenih i stručnih skupova u zemlji i inozemstvu.

Član je Hrvatske komore inženjera tehnologije prometa i transporta, ovlašteni inženjer cestovnog prometa i ovlašteni revizor cestovne sigurnosti.

PODACI I INFORMACIJE O DOKTORANDU

1. Ime i prezime: **Marijan Jakovljević, mag. ing. traff.**

2. Datum i mjesto rođenja: **27. travnja 1988., Požega**

3. Naziv završenoga fakulteta i godina diplomiranja: **Fakultet prometnih znanosti Sveučilišta u Zagrebu, 2013.**

INFORMACIJE O DOKTORSKOME RADU

1. Naziv doktorskoga studija: **Tehnološki sustavi u prometu i transportu**

2. Naslov doktorskoga rada: **Model vrednovanja rezultata prognoza prijevozne potražnje u cestovnom prometu**

3. Fakultet na kojemu je doktorski rad branjen: **Fakultet prometnih znanosti Sveučilišta u Zagrebu**

POVJERENSTVA, OCJENA I OBRANA DOKTORSKOGA RADA

1. Datum prijave teme doktorskoga rada: **9. srpnja 2019.**

2. Prvi mentor: **doc. dr. sc. Marko Šoštarić**

3. Povjerenstvo za ocjenu i obranu doktorskoga rada:

    1. prof. dr. sc. Tomislav Josip Mlinarić, predsjednik
    2. doc. dr. sc. Marko Šoštarić, mentor, član
    3. prof. emeritus Ivan Dadić, član
    4. doc. dr. sc. Marko Ševrović, član
    5. izv. prof. dr. sc. Irena Ištoka Otković, vanjski član (Građevinski i arhitektonski fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku)
    6. prof. dr. sc. Grgo Luburić, zamjena

4. Datum obrane doktorskoga rada: **30. prosinca 2020.**

5. Lektor: **Mateo Batinić, mag. philol. croat.**

SAŽETAK

Prognoziranje prijevozne potražnje jedan je od osnovnih elemenata u procesu prometnoga planiranja. Ono je nužno kod odlučivanja u procesima izgradnje i rekonstrukcije prometne infrastrukture, kao i ispitivanja ekonomske i financijske isplativosti te održivosti infrastrukturnih projekata. Unatoč navedenim činjenicama o važnosti prognoza prijevozne potražnje, dosadašnja istraživanja pokazuju kako se pogreške u posljednjih 30 godina kreću u rasponu od 20% do 35%, s trendom povećanja pogrešaka kod projekata novijega datuma. U ovome doktorskom radu istražen je odnos između godišnjih stopa promjena intenziteta prijevozne potražnje u cestovnome prometu te vanjskih pokazatelja gospodarskoga, demografskoga i prometnoga razvitka. Na temelju rezultata utvrđeni su ključni vanjski pokazatelji koji imaju utjecaj na buduće kretanje prijevozne potražnje u cestovnome prometu te su izrađeni prognostički modeli i modeli vrednovanja rezultata prognoza prijevozne potražnje u cestovnome prometu, a s ciljem smanjenja vjerojatnosti nastanka pogreške tijekom prognoziranja.

EXTENDED SUMMARY

Forecasting of road transport demand is one of the key elements in the transport planning process. Not only the final proposal but the efficiency of the transport system depends upon the quality of the transport demand forecasts. The complexity of the forecasting and/or predicting of road transport demand is acknowledged by many authors through their research on the accuracy of the forecasts as well as the constant creation of the new methods and models along with the models for higher-quality forecasting. However, despite the existence of numerous research by many authors, it is clear that notable changes in the process of transport demand forecasting are needed, shown by the fact that in the last 30, and it is safe to say even 70 years, the accuracy of the forecasts has not significantly been improved. On average, the errors of the transport demand forecasts vary between 20 and 35% depending on the research. The analysis of minimum and maximum values shows forecasted transport demand realization of only 15% up to slightly above 150%. A wide range between minimum and maximum values signifies high standard deviation which results in undercapacitating or overcapacitating of the transport system. Ultimately, both cases result in unplanned economical and financial losses.

When talking about accuracy of the road transport demand forecasts, it is firstly necessary to analyse the potential causes of the inaccuracy. If the reasons and presumptions

behind the erroneous results of the road transport demand forecasting are sublimed from the research done so far, three main causes arise. For a long time, low-quality input data used in forecasting process, which does not ensure that a planner can make a quality forecast (e.g. land use, trip generation, trip distribution etc.), is considered as a first cause. It is also important to note that where reference is made to input data as a cause of inaccurate forecasts, forecasting was most often based on the results of the four-step model. In time, several authors confirm that the accuracy of the forecasts does not change significantly regardless of substantial technological progress and a scientific and professional progress of planners themselves. Encouraged by these results, this yields reconsideration of the causes of inaccuracy and assumption is made that this can be attributed to, not only causes of the technical nature such as poor input data, but also to causes relating to human, namely psychological nature. As cause relating to psychological nature, the optimistic bias of the planner is stated. As the analysis of the accuracy has determined among others, the cases of the forecasting significantly below the real values, it is apparent that the cause is not always the optimistic bias hence it is concluded that the third most common cause is that of political and economic nature.

No matter the unassailable fact of the necessity and importance of the road transport forecasting, as well as a low accuracy of the existing forecasting models, exact models for validation of the quality of the transport demand forecasts in road transport have not been ascertained. One of the main reasons for facilitated manipulation of the forecasts (no matter whether it is caused by optimism of the planner or by politico-economical nature) is difficulty of the validation of forecasts results. Accordingly, research of this thesis is directed at the establishing the link between movement of annual rate of road transport demand change and economic, demographic and transport factors. That way it is possible to analyse economic, demographic, and transport trends by the means of the result of transport forecast, and consequently, easily conclude about the probability of occurrence of the specific result, i.e. about the quality of the forecast.

In this doctoral thesis, as a first step, defining of the relevant economic, demographic and transport factors for modelling of the road transport demand is conducted. On the basis of the results of the descriptive statistics, graphical and correlation analysis, it is determined that the number of registered motorised road vehicles (average annual change rate) followed by the real net wage growth (average annual change rate), real GDP growth rate and the number of tourist arrivals (average annual change rate) bears the biggest impact on the trend of the transport demand. It was also found that the change rate of road transport demand intensity

statistically significantly varies depending whether the motorways or state roads are concerned, as it was also found that, if the tourism activity is not taken into consideration, there is no statistically significant difference in relation to spatial distribution in the Republic of Croatia. This is corroborated by the fact that the statistically significant difference of GDP growth rate by county was not established. The correlation with the population has not also been proven as statistically significant and has a negative trend, which is expected when taken into consideration the fact that the population in the Republic of Croatia is in demographical decline for about 15 years now. As the majority of the previous forecasting models of road transport demand is based on population, it can be concluded that the relation between the population and the trend of transport demand has changed. The fact is that these are older models according to which owning an automobile was not the matter of need but rather prestige and with the development of the motorisation, owning at least one automobile per household is recently implied and is not even uncommon to own two or more automobiles per household. Likewise, if the population of the European Union from 1992 onwards is analysed, it is observed that it is characterised by the migrations that affect the overall increase in population, while the mortality rate exceeds birth rate. When it comes to fuel cost, the negative tendency in relation to the transport demand trend is noted, but not the significant impact, which is also not in accordance with the existing models. Based on determined connections of economic, demographic and transport trends to the changes in intensity of the road transport demand, first supporting hypothesis on the impact of these trends on the trend of road transport demand is confirmed.

After determining the relevant indicators, a model for forecasting the road transport demand was created. Considering the goal of the thesis and a relation between dependent and independent variables, multiple linear regression was used for creation of the model. Seeing as almost all established relevant indicators can be placed into economic category, with the purpose of avoiding multicollinearity and attaining high-quality results, three models were created (V1, V2 and V3). The first model as independent variable uses number of registered motorised road vehicles (average annual change rate), number of tourist arrivals (average annual change rate) and road category (motorway or state road), the second model uses real net wage growth (average annual change rate) and road category (motorway or state road), while the third model for that purposes utilises real GDP growth rate and road category (motorway or state road).

In the second step, based on the created forecasting models of the road transport demands, on established distributions of their independent variables and by applying the Monte

Carlo method, models for validation of results of the road transport demand forecast were created. Performance testing of the created validation models was conducted by analysing a success of the validation models not used in the creation of this model, in determining the values of the independent variables needed for the occurrence of the actual trend of transport demand in the period from 2017 to 2019 (annual average rate of change in the intensity of road transport demand (AADT)). Based on the success rate, it has been concluded that the discrepancies are in accordance with the statistical quality indicators of individual models. The results are also indicative of validation models recording smaller discrepancies for validation of forecasts in the longer periods and are more effective in analysis of the state roads by comparison with motorways. Based upon the created models and success rates, the second supporting hypothesis was confirmed stating that by combining deterministic models of economical, demographic and transport historical trends into unique stochastic model, evaluation of the results of transport demand forecasts can be made.

In addition to performance testing, two additional analysis were carried out, in order to test the possibilities of the created validation models. First additional analysis pertains to validation of the forecasts results using other determined/forecasted/envisaged distributions of independent variables within a set period of forecast. Objective of the analysis in question is to determine the quality of the validation model in a case of change in distribution of the independent variables and/or in a case of having quality forecasting data of independent variables. Second additional analysis pertains to the probability of the occurrence (validation) of the established, most commonly used road transport demand forecast in the Republic of Croatia. The purpose of this analysis is to determine the accuracy of road transport demand forecasting in the Republic of Croatia in respect to achieved values and best practice worldwide. According to the obtained results of the first additional analysis it can be concluded that by using higher-quality distributions/forecasting data on the trends of the independent variables in the forthcoming period, a significant impact can be made on the quality of the interpretation of the validation model results and consequently on the correct reasoning, even more so if the results of all three models, as well as trend of independent variables, are analysed and interpreted. The second analysis shows that according to the validation models in 57% of the analysed forecasts, the probability of occurrence of the forecasted value is lesser than 50%, while in 86% of the analysed forecasts the probability of the forecasted value occurring is lesser than 85%. In line with the validation models, low probabilities of the forecasted values occurring, support the necessity of performing detailed analysis of developed forecasts. This is

also supported by the fact that, on average, analysed forecasted values differ from actual values by 42%. Based on the success rates of the model and performance testing, it can be concluded that the suitability of the model application is confirmed and so is the hypothesis of this thesis affirming that it is possible to perform validation of the results of road transport demand forecasts using the data on economic, demographic and transport indicators.

In relation to the existing models in the Republic of Croatia and worldwide, created validation model of the results of the road transport demand forecasts allows conducting the analysis of probability of occurrence of the specific road transport demand scenario. Existing models forecast the road transport demand trend without insight into the probability of the forecasted result occurring. Besides that, alterations of thus far established connection between population and road transport demand trend were determined in the process of creating the validation model. Additionally, it is established that the fuel price does not have statistically significant impact on the road transport demand trend, which is not the case for some of the existing validation models for road transport demand trends. In addition, three variants of the validation models were created in this thesis, which reduces the likelihood of faulty reasoning and facilitates the utilization of the model.

Future research should be aimed at the possibility of introducing additional parameters, which will have the effect on increase of accuracy of created models. In relation to that, during the research, it is found that the transport demand trend differs between motorways and state roads and it would be necessary to consider the parameters which would describe the changes on the motorways with more precision. In addition and taking into consideration the fact that the created models are based on the transport demand trends outside of the urban environments, it is necessary for future research to be targeted at forecasts in urban environments with significantly developed public transport. Transport policy can have a significant impact on the road transport demand trends in urban environments regardless of economic indicators, i.e. stimulation of public transport will also have a strong impact on road transport demand trend. Taking that into consideration, it is necessary to conduct research and quantify relations between specific transport policy measures and road transport demand change rate.

Keywords: transport planning, forecasting, traffic demand, stochastic risk analysis

SADRŽAJ

SAŽETAK ..... **I**

EXTENDED SUMMARY ..... **I**

1. UVOD **1**

1.1. Predmet istraživanja 1

1.2. Svrha i ciljevi istraživanja 2

1.3. Pregled dosadašnjih istraživanja 3

1.4. Metode istraživanja 7

1.5. Kompozicija rada 7

2. RELEVANTNI POKAZATELJI ZA MODELIRANJE PRIJEVOZNE POTRAŽNJE U CESTOVNOME PROMETU **9**

2.1. Promet 11

2.1.1. Prometno opterećenje 13

2.1.2. Kategorija prometnice 15

2.1.3. Geografski položaj 19

2.1.4. Motorna vozila 25

2.1.5. Prijevoz robe 26

2.2. Gospodarstvo 28

2.2.1. BDP (RH) 29

2.2.2. BDP (EU) 30

2.2.3. Industrija 31

2.2.4. Cijene 32

2.2.5. Plaće 33

2.2.6. Gorivo 35

2.2.7. Zaposlenost 37

2.2.8. Turizam 38

2.3. Demografija 41

2.3.1. Populacija 41

2.3.2. Aktivno stanovništvo 42

2.4. Utvrđivanje relevantnih pokazatelja 43

3. MODEL PROGNOZIRANJA PRIJEVOZNE POTRAŽNJE U CESTOVNOME PROMETU **50**

3.1. Odabir prognostičkoga modela i metodologija izrade 51
3.2. Model prognoze prijevozne potražnje u cestovnome prometu 54
4. MODEL VREDNOVANJA PROGNOZA PRIJEVOZNE POTRAŽNJE U CESTOVNOM PROMETU 63
4.1. Distribucije 64
4.2. Modeliranje vjerojatnosti 69
5. TESTIRANJE MODELA 77
5.1. Testiranje modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu 77
5.2. Testiranje kvalitete modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu primjenom drugih distribucija i/ili prognostičkih podataka 83
5.3. Testiranje kvalitete prognoza prijevozne potražnje u Republici Hrvatskoj primjenom modela vrednovanja prognoza prijevozne potražnje 87
6. ZAKLJUČNA RAZMATRANJA 91
LITERATURA 96
PRILOZI 101
POPIS SLIKA 117
POPIS GRAFIKONA 117
POPIS TABLICA 121
ŽIVOTOPIS I POPIS JAVNO OBJAVLJENIH RADOVA 123

1. UVOD

1.1. Predmet istraživanja

Ponuda i potražnja jedan su od osnovnih obilježja gospodarstva te predstavljaju regulatore tržišnih odnosa. Prema teorijama tržišta, potražnja prikazuje količinu nekoga dobra koje su potrošači spremni kupiti po jedinici vremena ili po određenim cijenama toga dobra [1]. S druge strane, promet je oduvijek poznat kao jedna od najvažnijih gospodarskih djelatnosti nužnih za razvoj gospodarstva u cijelosti s obzirom na to da omogućuje povezivanje mjesta proizvodnje (ponuda) i potrošnje (potražnja), odnosno izvorište i odredište putovanja. Prema tome, prijevozna potražnja nije autonomna, već je određena potražnjom za određenim dobrom ili uslugom, što je čini izvedenom potražnjom. Izvedena potražnja ekonomski je pojam potražnje za dobrom ili uslugom u jednome sektoru koja nastaje kao rezultat potražnje u drugome sektoru [2]. Slijedom navedenoga, razvidno je da pružanje usluge prijevoza, odnosno prometa u širemu smislu, nije moguće bez postojanja potražnje za tom uslugom.

Nastajanjem prijevozne potražnje javila se i potreba za njezinim upravljanjem. U procesu upravljanja prijevoznom potražnjom jedan od osnovnih elemenata upravo je predviđanje i prognoziranje budućih trendova prijevozne potražnje [2], [3]. Prognoziranje prijevozne potražnje od samih početaka prometnoga planiranja zauzima važan element pri upravljanju prometnim sustavom te njegovome planiranju i projektiranju [2]-[6]. Naime, uzimajući u obzir da se prometna infrastruktura planira za dugoročna razdoblja, i do više od 30 godina, te da se proces prometnoga planiranja sastoji od prometne dijagnoze, prognoze i terapije, uloga je prognoze prijevozne potražnje u funkciji prometnoga planiranja očigledna. Prometnom dijagnozom analizira se postojeća prometna situacija, a prognoza predviđa buduću prometnu situaciju dok se terapijom utvrđuju optimalna rješenja i mjere unapređenja [7]. S obzirom na to da se prometno planiranje obično odnosi na geografski šire područje te da se njime ne definiraju detaljna projektna rješenja, točnost takvih prognoza obično nije visoka u usporedbi s prognozama izrađenih za potrebe projektnih rješenja, pa ih je potrebno interpretirati s oprezom [8].

U suvremenome prometnom planiranju urbanih sredina prognoze zauzimaju važno mjesto u kapacitiranju prometne infrastrukture, studijama (pred)izvodljivosti, analizama troškova i koristi (eng. *Cost-Benefit Analysis, CBA*), javno-privatnome partnerstvu, kao i modelima utvrđivanja utjecaja prometnoga sustava na okolinu i procjenu stanja sigurnosti,

odnosno procjenu broja nesreća [9]-[11]. Tijekom prognoziranja prijevozne potražnje nužno je razlikovati novonastalu i induciranu prijevoznu potražnju koja nastaje redistribucijom postojeće potražnje uslijed nove situacije na prometnoj mreži [10], [12]-[16]. Induciranu prijevoznu potražnju karakteriziraju značajnije devijacije u prvim godinama nakon realizacije projekta, nakon čega slijedi trend maloga rasta ili stagnacije. Prilikom prognoziranja u obzir je potrebno uzeti obje prijevozne potražnje te ih posebno analizirati. Ovaj je rad u nastavku usmjeren na prognoziranje novonastale prijevozne potražnje.

1.2. Svrha i ciljevi istraživanja

Ovim se radom želi istražiti odnos između godišnjih stopa promjena intenziteta prijevozne potražnje u cestovnome prometu i vanjskih pokazatelja koji opisuju gospodarski, demografski i prometni razvitak. U tome su smislu istraživani i utvrđeni ključni vanjski čimbenici koji imaju utjecaj na buduće kretanje prijevozne potražnje u cestovnome prometu poput broja registriranih cestovnih motornih vozila, realnoga rasta neto plaće, realnoga rasta BDP-a, broja turističkih dolazaka i sl.

Cilj istraživanja utvrđivanje je odnosa godišnjih stopa promjena intenziteta cestovne prijevozne potražnje (količine prometa) s gospodarskim, demografskim i prometnim pokazateljima te shodno tome kreiranje modela za vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu.

Glavna i pomoćne hipoteze istraživanja su sljedeće:

- Korištenjem izvanprognostičkih podataka o gospodarskim, demografskim i prometnim pokazateljima moguće je provesti vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu.
- Moguće je utvrditi statistički značajnu korelaciju između promjena intenziteta cestovne prijevozne potražnje i kretanja gospodarskih, demografskih i prometnih pokazatelja koji se tradicionalno ne koriste u prognostičkim modelima.
- Objedinjavanjem deterministčkih modela kretanja povijesnih, gospodarskih, demografskih i prometnih pokazatelja u jedinstveni stohastički model, moguće je provesti vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu.

Očekivani znanstveni doprinos predloženoga istraživanja proizlazi iz:

- utvrđivanja odnosa između godišnjih stopa promjena intenziteta cestovne prijevozne potražnje (količine prometa) s gospodarskim, demografskim i prometnim pokazateljima;
- identifikacije ključnih pokazatelja na temelju kojih se može vrednovati buduće kretanje prijevozne potražnje u cestovnome prometu;
- izrade i validacije modela za vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu.

1.3. Pregled dosadašnjih istraživanja

Uviđanje važnosti razvoja modela za prognozu prijevozne potražnje javlja se u kasnim 1940-ima te tijekom 1950-ih godina u Sjedinjenim Američkim Državama kada se intenzivnije krenulo s izradama prometnih studija metropolitanskih područja te razvojem računalnih simulacija [17]. Prognoziranje prijevozne potražnje prije 1950-ih uglavnom se temeljilo na koeficijentima ekspanzije postojeće potražnje [5]. Studija je, koja je postavila temelje suvremenoga prometnog planiranja, *Prometna studija Chicaga* izrađena 1959. godine pod vodstvom J. Douglasa Carrolla Jr.-a. U predmetnoj se studiji prognoza prijevozne potražnje temeljila na, i danas najčešće korištenome, tradicionalnome četverostupanjskom modelu koji sadrži generaciju putovanja, distribuciju putovanja, modalnu razdiobu te dodjeljivanje putovanja na mrežu [18]. U posljednjih dvadesetak godina, uz tradicionalni četverostupanjski model, razvijaju se *Activity-based* i *Tour-based* modeli koji prognozu prijevozne potražnje baziraju na dnevnim aktivnostima reprezenata putovanja, što omogućuje prevladavanje mnogih nedostatka koje sadrže klasični četverostupanjski modeli. Osnovni nedostatak ovih modela zahtijevanje je detaljnijih povijesnih podataka o putovanjima [19]-[22]. Uz prethodno navedene najčešće korištene modele, postoje i modeli bazirani na metodama vremenskih serija te uzročni modeli poput regresijskih modela [23]-[25]. Cilj ovakvih istraživanja uglavnom je bio kreiranje jednostavnih matematičkih modela koji će donositeljima odluka, kao i široj javnosti, omogućiti jednostavno korištenje i provjeru točnosti izrađenih prognoza, a uz zadržavanje dovoljne razine točnosti. Jedan od prvih takvih modela kreiran je 1987. godine za potrebe prognoziranja prijevozne potražnje državnih cesta u ruralnim područjima Sjedinjenih Američkih Država [23]. Za prognozu je izrađen model višestruke linearne regresije gdje je zavisna varijabla bila

prosječni godišnji dnevni promet (PGDP), a nezavisne varijable populacija države, populacija okruga te broj kućanstava.

U posljednjih desetak godina sve se više istražuju i promiču nekonvencionalni načini prognoziranja prijevozne potražnje čija osnova leži u prirodnim i društvenim znanostima poput psihologije. Što je jedan od osnovnih razloga za to nepostizanje značajnijega povećanja točnosti prognoza u posljednjih 30 godina unatoč značajnome tehnološkom napretku (pogotovo računalnih simulacija) [26]. Slijedom navedenoga, Američka planerska organizacija (engl. *American Planning Association, APA*) u travnju je 2005. godine odobrila korištenje nove metode prognoziranja pod nazivom *reference class forecasting* [27], [28] te preporuča njezino korištenje uz već tradicionalne metode prognoziranja prijevozne potražnje. Predmetna metoda prognoziranje temelji se na proučavanju i usporedbi projekata za koje se radi prognoza sa sličnim već izvedenim projektima, što je definirano kroz pojam *pogled izvana* (engl. *outside view*). Osnovni joj je cilj smanjenje utjecaja nerijetko prisutne optimistične pristranosti planera.

U Republici Hrvatskoj 2014. je godine razvijen ekonometrijski model višestruke linearne regresije za potrebe prognoze prijevozne potražnje na autocestama [25] koji kao nezavisne varijable koristi cijenu goriva, broj registriranih osobnih vozila, broj dolazaka turista te broj zaposlenih osoba. Osnovni nedostatak predmetnoga modela veličina je uzorka od samo osam mjerenja. Tijekom izrade prometnih studija u Republici Hrvatskoj [29]-[35], utvrđeno je da se prognoza prijevozne potražnje i dalje uglavnom temelji na koeficijentima ekspanzije postojeće potražnje. *Nacionalni prometni model* izrađen 2016. godine prognozu temelji na tradicionalnome čeverostupanjskom modelu [36].

Unatoč značajnome tehnološkom napretku kao i konstantnome provođenju novih istraživanja o prognozama prijevozne potražnje, točnost prognoza u posljednjih 30 godina nije zabilježila značajnije pomake, što pokazuju mnogi prometni infrastrukturni projekti koji su uslijed lošega prognoziranja generirali ili generiraju velike financijske gubitke država diljem svijeta. Kao poznatije primjere može se navesti Eurotunel ispod kanala La Manche otvoren 1994. godine. koji je generirao prihode 50% manje od prognoziranih [37], Međunarodna zračna luka Denver, koja je u godinama otvaranja također zabilježila svega pola od prognoziranoga broja putnika [37], autocesta CLEM7 u Australiji gdje je ostvareno tek nešto više od pola prognozirane prijevozne potražnje, što je rezultiralo bankrotom kompanije te 2014. godine i tužbom prema izrađivaču prognoze [38], projekt *Skytrain* u Bangkoku čija je prognoza bila čak dva i pol puta veća od stvarne što je uzrokovalo predimenzioniranje željezničkoga sustava, značajnije troškove u eksploataciji te manje prihode od predviđenih [37]. S druge strane, Ured

državne revizije Ujedinjenoga Kraljevstva u svojemu je izvješću 1988. godine pokazao veći broj projekata cestovne infrastrukture koji su temeljem niskih prognoza prijevozne potražnje potkapacitirani, što je rezultiralo dodatnim neplaniranim troškovima [39]. Kao prva sustavna analiza točnosti prognoza prijevozne potražnje mogu se smatrati istraživanja autora Baina i njegovih suradnika izrađena za potrebe *Standard & Poor's* kreditne agencije [40]-[43]. Istraživanja su provedena u periodu od 2002. do 2005. godine te su obuhvatila 104 objekta s naplatom cestarine (prometnice, mostove i tunele). Prvo istraživanje [40] provedeno 2002. godine obuhvatilo je 32 studije slučaja te je utvrđeno da se u prosjeku ostvarilo svega 58% prognozirane potražnje. Drugim istraživanjem [41] tijekom 2003. godine uzorak studija slučaja povećan je na 68 te je utvrđena aritmetička sredina od 74%, tj. 26% manje ostvarene potražnje od prognozirane. Tijekom trećega [42] i četvrtoga istraživanja [43] broj studija slučaja se povećao na 87, odnosno 104, dok rezultati o točnosti nisu bilježili značajnije promjene u odnosu na prethodna dva istraživanja. Temeljem predmetnih istraživanja također se može zaključiti da iz godine u godinu nisu zabilježena značajnija poboljšanja u prognoziranju. Najopširnije istraživanje točnosti prognoza prijevozne potražnje, koje je obuhvaćalo 210 projekata u 14 zemalja u vrijednosti od oko 58 milijardi dolara, proveli su Flyvberg i suradnici, a njegove su rezultate objavili u svojim istraživanjima 2005. [26] i 2006. godine [44]. Istraživanjem je utvrđeno da prognoza kod polovice cestovnih projekata ima odstupanje veće od ±20%, četvrtina odstupa više od ±40% dok 13% projekata ima odstupanje prognoze čak više od ±60%. Posljednje značajnije istraživanje razine točnosti prognoza prijevozne potražnje na temelju analize 14 prometnica u sustavu naplate na području Australije proveli su Li i Hensher 2010. godine [45]. Istraživanjem je utvrđeno da je stvarna potražnja u prosjeku 45% niža od prognozirane.

S obzirom na utvrđena konstantna značajna odstupanja između ostvarene i prognozirane prijevozne potražnje tijekom posljednjih 30 godina, prognoziranje je postalo predmetom mnogobrojnih znanstvenih istraživanja. Budući da je u tome periodu, pa i danas, četverostupanjski model najviše zastupljen, najveći broj istraživanja posvećen je upravo ispitivanju njegovih ograničenja [18], [20]-[22], [26], [46]. Prema istraživanjima Krigera i suradnika iz 2006. godine [19] te Baina iz 2009. godine [47], čest uzrok netočnosti prognostičkih modela, pogotovo kada je riječ o četverostupanjskome modelu, proizlazi iz nedovoljno točnih ulaznih podataka te loše postavljenih pretpostavki. Do sličnih zaključaka dolaze i Flyvberg i suradnici u svojemu istraživanju iz 2006. godine [26] te se nastavkom istraživanja 2008. godine [27] dolazi do novih spoznaja i zaključuje da tehnički uzroci poput

nevjerodostojnih ulaznih podataka, loše postavljenih pretpostavki i slično nisu dovoljni za potpuno objašnjenje uzroka netočnosti prognoziranja prijevozne potražnje. Slijedom navedenoga zaključuju da su glavni uzroci netočnosti prognoza psihološke te političko-ekonomske prirode. Kod analiza uzroka netočnosti prognoza prijevozne potražnje kod projekata javno-privatnoga partnerstva veći naglasak stavljen je upravo na pogreške psihološke i političko-ekonomske prirode. Prema istraživanju Vassallo 2007. godine [48], u sklopu istraživačkoga programa Europske investicijske banke, definira četiri osnovna parametra o kojima ovisi mogućnost nastanka pogrešaka kod prognoza prijevozne potražnje za potrebe javno-privatnih partnerstva: (1) konkurentnost natječaja, (2) nepotpunost (kvaliteta) ugovora, (3) spremnost vlada na pregovaranje te (4) nedostatak mehanizama za ublažavanje prometnih rizika.

Pregledom dosadašnjih istraživanja razvidno je da su nužne značajnije promjene u procesu prognoziranja prijevozne potražnje, što potvrđuje činjenica da se u proteklih 30 godina, a može se pretpostaviti i 70 godina, točnost prognoza nije značajnije povećala. S druge strane, analizom uzroka netočnosti utvrđena su mnogobrojna ograničenja postojećih tradicionalnih modela prometne prognoze kao što je složenost njihove izrade, visoka osjetljivost na ulazne podatke, zahtijevanje velikog broja ulaznih podataka i pretpostavki o trendovima kretanja socio-ekonomskih i prostornih aktivnosti i sl. Isto tako, postojeći tradicionalni modeli imaju nisku razinu objektivnosti, odnosno na relativno lak način omogućavaju argumentaciju pristranosti prometnoga planera ili političkoga djelovanja, što je u konačnici teško provjerljivo i dokazivo (npr. računalne simulacije, četverostupanjski model itd.).

Analizom postojećih modela prognoze također je utvrđen nedostatak manje složenih matematičkih modela koji bi donositeljima odluka na jednostavan i brz način omogućavali analizu budućih trendova prijevozne potražnje, ispitivanje različitih scenarija i validaciju dobivenih prognoza. Osim toga, analizirani jednostavniji matematički modeli uglavnom se temelje na metodi vremenskih serija koja ne omogućava ispitivanje međuovisnosti ulaznih varijabli te ispitivanje različitih scenarija promjenom ulaznih podataka. Analizirani uzročni statistički modeli starijega su datuma, a uglavnom se temelje na malome broju uzoraka te obuhvaćaju mali broj nezavisnih varijabli (npr. samo trendovi kretanja populacije i gospodarske aktivnosti). Također, pregledom literature nije utvrđena sustavna izrada analiza osjetljivosti i rizika prema postojećim modelima prognoze kojima bi se ispitivala vjerojatnost nastanka pojedinoga scenarija u ovisnosti o različitim ulaznim podacima.

1.4. Metode istraživanja

Shodno postavljenome cilju i hipotezama, istraživanje je rada provedeno kroz pet faza tijekom čega je korišteno nekoliko znanstvenih metoda.

U prvoj je fazi temeljem metoda analize, sinteze i kompilacije provedeno prikupljanje i interpretiranje povijesnih podataka o rezultatima postojećih prognostičkih modela te podataka relevantnih za kreiranje modela za vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu.

Za potrebe razumijevanja prikupljenih podataka u drugoj fazi su, uz metode analize, sinteze te deduktivne i induktivne metode, korištene i deskriptivne statističke metode s ciljem sistematizacije prikazivanja i interpretacije prikupljenih podataka.

Statističke metode korištene su i u trećoj fazi za potrebe utvrđivanja odnosa između godišnjih stopa promjena intenziteta cestovne prijevozne potražnje (količine prometa) i prikupljenih gospodarskih, demografskih i prometnih pokazatelja.

U četvrtoj je fazi uz statističke metode za potrebe izrade prognostičkoga statističkog modela prijevozne potražnje u cestovnome prometu korištena i metoda modeliranja. Metoda modeliranja korištena je za provođenje modeliranja vjerojatnosti kretanja godišnje stope promjene intenziteta cestovne prijevozne potražnje, a primjenom stohastičkih simulacija.

Na temelju matematičkih metoda u petoj je fazi provedeno vrednovanje rezultata povijesnih prognoza prijevozne potražnje u cestovnome prometu te analiza uspješnosti i kvalitete postavljenoga modela.

1.5. Kompozicija rada

Doktorski rad sastoji se od šest osnovnih poglavlja, literature, priloga te popisa tablica, slika i grafikona. Osnovna su poglavlja sadržaja rada sljedeća:

1. Uvod
2. Relevantni pokazatelji za modeliranje prijevozne potražnje u cestovnome prometu
3. Modeli prognoziranja prijevozne potražnje
4. Modeli vrednovanja prognoza prijevozne potražnje
5. Testiranje modela
6. Zaključak.

U uvodnome djelu rada argumentiran je i elaboriran predmet istraživanja, njegova svrha i cilj te postavljene hipoteze. U poglavlju je također prikazan i elaboriran očekivani znanstveni doprinos, ponuđen pregled dosadašnjih istraživanja vezanih za predmet rada te pregled korištenih znanstvenih metoda za potrebe potvrđivanja postavljenih hipoteza, odnosno ispunjavanje postavljenih ciljeva.

U drugome djelu analizirani su relevantni pokazatelji za modeliranje prijevozne potražnje u cestovnome prometu podijeljeni u tri osnovne kategorije: gospodarstvo, demografiju i promet. U poglavlju je provedena i identifikacija utjecajnih pokazatelja te prikazana smjernost i jačina njihove veze, a na temelju rezultata korelacijske analize.

U trećemu poglavlju na temelju su rezultata analize relevantnih pokazatelja predstavljeni deterministički modeli za prognoziranje prijevozne potražnje u cestovnome prometu prema kategoriji prometnice. U uvodnome dijelu poglavlja nalazi se i pregled mogućih prognostičkih modela uz odabir onoga optimalnoga, a prema postavljenim ciljevima rada. Modeli su kreirani dovođenjem u međuovisnost zavisne i nezavisnih varijabli metodom višestruke linearne regresije.

Na temelju determinističkih modela za prognoziranje cestovne prijevozne potražnje predstavljenih u trećemu poglavlju, u četvrtome poglavlju predstavljeni su stohastički modeli vrednovanja prognoza prijevozne potražnje u cestovnome prometu. Poglavlje također sadrži analizu distribucija utvrđenih relevantnih pokazatelja korištenih za izradu determinističkih modela prognoziranja cestovne prijevozne potražnje na temelju koje su izrađeni stohastički modeli vrednovanja prognoza prijevozne potražnje u cestovnome prometu.

U petome poglavlju provedeno je testiranje uspješnosti izrađenih stohastičkih modela za vrednovanje prognoza prijevozne potražnje u cestovnome prometu. Također su provedene dvije analize kvalitete izrađenih modela. Cilj prve analize kvalitete utvrđivanje je kvalitete modela vrednovanja u slučaju promjene distribucije nezavisnih varijabli i/ili u slučaju posjedovanja kvalitetnih prognostičkih podataka nezavisnih varijabli. Cilj druge provedene analize kvalitete obraćanje je pozornosti na nisku točnost prognoziranja cestovne prijevozne potražnje u Republici Hrvatskoj u odnosu na ostvarene vrijednosti.

Zaključna razmatranja iznesena su u šestome poglavlju. Poglavlje daje pregled provedenoga istraživanja, opis dobivenih rezultata te osnovne karakteristike razvijenih modela. U poglavlja su također prikazane mogućnosti primjene razvijenih modela, kao i njihova ograničenja i specifičnosti, te su ponuđene smjernice za daljnja istraživanja.

2. RELEVANTNI POKAZATELJI ZA MODELIRANJE PRIJEVOZNE POTRAŽNJE U CESTOVNOME PROMETU

Prema rezultatima analize dosadašnjih istraživanja i modela za predviđanje i prognoziranje prijevozne potražnje u cestovnome prometu, pretpostavljeno je da je moguće utvrditi statistički značajnu korelaciju između promjena intenziteta cestovne prijevozne potražnje te kretanja gospodarskih, demografskih i prometnih pokazatelja koji se tradicionalno ne koriste u prognostičkim modelima.

Shodno tome, u prvoj fazi rada provedeno je prikupljanje povijesnih podataka relevantnih za kreiranje prognostičkih modela, a u konačnici i modela za vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu. Podaci su prikupljani iz javno dostupnih izvora podataka (npr. godišnje publikacije o prijevoznoj potražnji upravitelja prometnom infrastrukturom u Republici Hrvatskoj, godišnje publikacije Državnoga zavoda za statistiku, jedinica lokalne samouprave i sl.), a s ciljem jednostavnije izrade samoga modela, kao i olakšane mogućnosti nadogradnje modela u budućnosti. Prikupljeni podaci obrađeni su i strukturirani na način da omogućavaju naknadnu izradu detaljnijih modela vrednovanja, primjerice samo pojedine dionice autocesta i sl.

Kao gospodarski pokazatelji prikupljeni su podaci o bruto domaćemu proizvodu (npr. ukupni, po stanovniku, po županiji, po državama članicama Europske unije, realne stope promjene i sl.), pokazatelji turističke aktivnosti (npr. broj dolazaka i noćenja turista, strukturi turista i sl-), pokazatelji zaposlenosti, indeksi proizvodnje i potrošačkih cijena i sl.

Demografski podaci analizirani su kroz podatke o broju stanovnika (ukupno i po županijama), o broju radno aktivnoga stanovništva te njihovim godišnjim promjenama i sl.

Kao prometni pokazatelji analizirani su javno dostupni podaci o prosječnome godišnjemu dnevnom prometu (PGDP) i prosječnome ljetnome dnevnom prometu (PLDP) pojedinih dionica prometnica i njihovim godišnjim promjenama, kategoriji prometnice, broju registriranih vozila i sl. Kroz analizu PGDP-a i PLDP-a uzela se u obzir i godišnja neravnomjernost prometnoga opterećenja.

Prilikom prikupljanja podataka, a gdje god je to moguće, provedeno je strukturiranje prema europskoj i nacionalnoj klasifikaciji prostornih jedinica (NUTS-1, NUTS-2 i NUTS-3) [49]. Kroz analizu podataka prema prostornim jedinicama u obzir se uzela i prostorna

komponenta odnosno specifičnosti koje iz nje proizlaze, a koje su usko vezane i za gospodarstvo. Analiza je provedena za vremensko razdoblje od 2003. do 2016. godine.

Za potrebe istraživanja, iz odabranih kategorija, analizirano je ukupno 26 pokazatelja za koje je provedena analiza statistički značajnoga utjecaja na kretanje prijevozne potražnje. Prikaz analiziranih pokazatelja prema definiranim kategorijama nalazi se u tablici 1.

Tablica 1. Analizirani pokazatelji prema kategorijama

Kategorija		Pokazatelj	Prostorna jedinica
Gospodarstvo	1.	Bruto domaći proizvod	NUTS 1 i 3
	2.	Bruto domaći proizvod po stanovniku	NUTS 1 i 3
	3.	Realne stope rasta bruto domaćega proizvoda	NUTS 1 i 3
	4.	Stope promjene bruto domaćega proizvoda po stanovniku	NUTS 1 i 3
	5.	Bruto domaći proizvod Europske unije (stope promjene)	EU (trenutni sastav)
	6.	Bruto domaći proizvod Europske unije (stope promjene)	EA12
	7.	Obujam industrijske proizvodnje (stope promjene)	NUTS 1
	8.	Indeks potrošačkih cijena (stope promjene)	NUTS 1
	9.	Indeks potrošačkih cijena bez energije i hrane (stope promjene)	NUTS 1
	10.	Nominalni rast neto plaće (stope promjene)	NUTS 1
	11.	Realni rast neto plaće (stope promjene)	NUTS 1
	12.	Cijena goriva (prosječna cijena i stope promjene)	NUTS 1 (prosjek)
	13.	Stopa registrirane nezaposlenosti	NUTS 1 i 3
	14.	Ukupan broj zaposlenih	NUTS 1 i 3
	15.	Dolasci turista (domaći, strani i stope promjene)	NUTS 1 i 3
	16.	Noćenja turista (domaći, strani i stope promjene)	NUTS 1 i 3
Demografija	1.	Populacija (ukupno i stope promjene)	NUTS 1, 2 i 3
	2.	Aktivno stanovništvo	NUTS 1, 2 i 3
Promet	1.	PGDP (stope promjene)	NUTS 3
	2.	PLDP (stope promjene)	NUTS 3
	3.	Prosječni izvanljetni dnevni promet (PiDP) (stope promjene)	NUTS 3
	4.	Kategorija prometnice	--
	5.	Broj registriranih cestovnih motornih vozila	NUTS 1 i 3

Kategorija	Pokazatelj	Prostorna jedinica
	6. Broj registriranih cestovnih osobnih vozila	NUTS 1 i 3
	7. Cestovni prijevoz robe (količina i stope promjene)	NUTS 1 i 3
	8. Željeznički prijevoz robe (količina i stope promjene)	NUTS 1 i 3

Detaljan prikaz rezultata analize nalazi se u nastavku poglavlja.

2.1. Promet

Uz gospodarstvo i demografiju, za potrebe razvoja modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu, analizirano je i osam pokazatelja iz kategorije prometnih pokazatelja. S ciljem lakše deskripcije i interpretacije, pokazatelji su, prema svojim karakteristikama, svrstani u sljedeće četiri grupe:

- prometno opterećenje (zavisna varijabla u modelima)
- kategorija prometnice
- geografski položaj
- motorna vozila
- prijevoz robe.

Kod prometnih pokazatelja posebna pažnja posvećena je analizi stopa promjena prijevozne potražnje u odnosu na različite pokazatelje s ciljem utvrđivanja statistički značajnih razlika sredina, što ima značajan utjecaj na izradu modela. Shodno tome, analizirano je postojanje statistički značajne razlike kretanja stopa promjena za:

- godine
- doba godine (PGDP, PLDP i PiDP[1])
- kategoriju prometnice
- geografski položaj.

Stope promjene intenziteta izračunate su kao godišnje stope promjene u odnosu na prethodnu godinu, a na temelju baze podataka brojenja prometa koje provode Hrvatske ceste

[1] PiDP – za potrebe istraživanja prosječni izvanljetni dnevni promet izračunat je na način da je iz PGDP-a izdvojen PLDP, a s ciljem objektivnijeg uvida i vjerodostojnije deskripcije intenziteta cestovne prijevozne potražnje izvan turističke sezone.

d.o.o. [50]. Shodno tome svaka stopa promjene izračunata je za svako brojilo prometa posebno. Mjerna je jedinica za stope promjene intenziteta cestovne prijevozne potražnje postotak.

Za potrebe analize nisu korišteni sljedeći podaci iz baze podataka Hrvatskih cesta d.o.o.:

- podaci koji se odnose na povremeno automatsko brojenje – uslijed drukčije metodologije u odnosu na neprekinuto automatsko brojenje
- podaci koji se odnose na neprekinuto automatsko brojenje na autocestama – naplatno brojenje ima veću pouzdanost te se radi o samo četiri lokacije neprekinuta brojenja
- podaci koji predstavljaju atipične vrijednosti – atipične vrijednosti određene su posebno na razini svake godine i vrste prometnice, a korištena metodologija identifikacije je *1,5 x interkvartilni raspon*[2] [51].

Shodno opisanoj metodologiji, za potrebe analize prometnih pokazatelja korišteno je ukupno 475 brojila prometa na području Republike Hrvatske, odnosno 9.350 mjerenja u analiziranome periodu. Detaljnijom analizom podataka o brojenju prometa utvrđeno je da do atipičnih vrijednosti na pojedinim brojilima prometa uglavnom dolazi uslijed zatvaranja pojedinih cestovnih pravaca, što posljedično uzrokuje značajnija povećanja, odnosno smanjenja intenziteta cestovne prijevozne potražnje na određenim pravcima, a ovisno o novoj regulaciji prometa (npr. obilazni pravci i sl.).

Važno je napomenuti da je, prije provođenja detaljnije analize prometnih pokazatelja, u prvome redu analizirano postojanje statistički značajne razlike u kretanju prosječnih godišnjih stopa promjena cestovne prijevozne potražnje tijekom godina, a s ciljem utvrđivanja postojanja varijabiliteta koji je u daljnjim koracima moguće opisati/predvidjeti/prognozirati/vrednovati matematičkim modelom. Za potrebe ispitivanja proveden je Tukey-Kramerov test[3]. Za potrebe korištenje predmetnoga testa ispitane su i zadovoljene polazne pretpostavke čiji su rezultati prikazani u 3. i 4. poglavlju. Korištena razina značajnosti je 0,05, dok je polazna hipoteza glasila da ne postoji statistički značajna razlika kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje tijekom analiziranoga perioda.

[2] Pravilo za određivanje atipičnih vrijednosti *1,5 x interkvartilni raspon* često je korišteno pravilo koje kaže da svi uzorci manji od *prvog kvartila* (Q_1) *– 1,5 x interkvartilni raspon* čine niske atipične vrijednosti dok svi uzorci veći od *trećeg kvartila* (Q_3) *+ 1,5 x interkvartilni raspon* čine visoke atipične vrijednosti [51].

[3] Tukey-Kramerov test je test višestrukih usporedbi kojim se mogu pronaći sredine koje se značajno razlikuju [51].

Provođenjem testa utvrđena je statistički značajna razlika kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje tijekom analiziranoga perioda (grafikon 1). Najveće razlike utvrđene su 2007. godine (6,47%), a u odnosu na 2012. godinu (-3,74%).

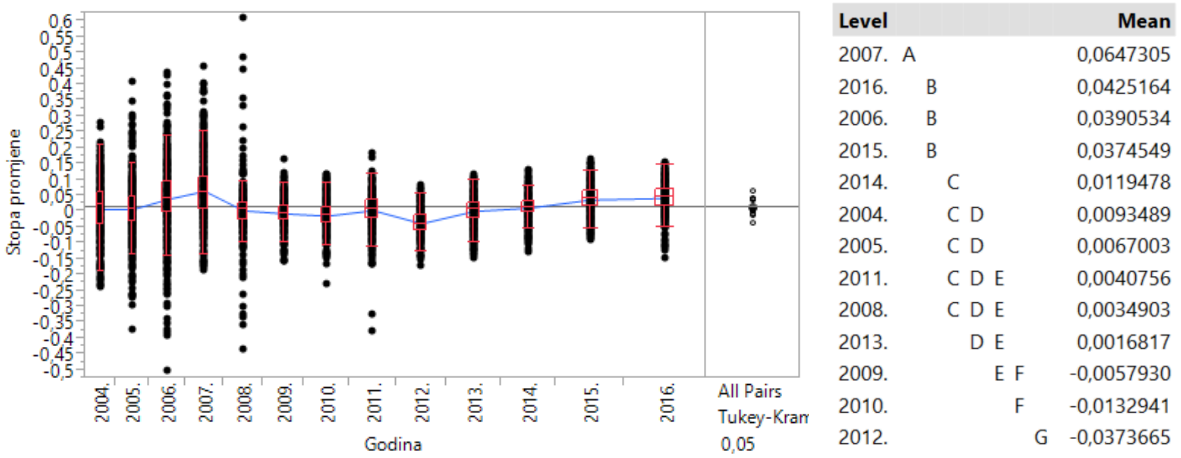

Level							Mean
2007.	A						0,0647305
2016.		B					0,0425164
2006.		B					0,0390534
2015.		B					0,0374549
2014.			C				0,0119478
2004.			C	D			0,0093489
2005.			C	D			0,0067003
2011.			C	D	E		0,0040756
2008.			C	D	E		0,0034903
2013.				D	E		0,0016817
2009.					E	F	-0,0057930
2010.						F	-0,0132941
2012.							G -0,0373665

Grafikon 1. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje tijekom analiziranoga perioda (Tukey-Kramerov test)

Detaljan prikaz rezultata analize prometnih pokazatelja nalazi se u nastavku poglavlja.

2.1.1. Prometno opterećenje

Prometno opterećenje korišteno je za istraživanje utjecaja vremenske neravnomjernosti na stope promjene intenziteta cestovne prijevozne potražnje, pri čemu su analizirane stope promjene PGDP-a, PLDP-a i PiDP-a tijekom analiziranoga razdoblja. PGDP predstavlja godišnji prosjek, PLDP turističku sezonu, a PiDP razdoblje izvan turističke sezone.

Analizom baze podataka brojenja prometa, utvrđeno je da je u analiziranome periodu PGDP u prosjeku rastao 1,38%, PLDP 1,58%, a PiDP 1,28%. Veći rast PLDP-a u odnosu na PGDP i PiDP očekivan je uzimajući u obzir brži oporavak gospodarstva Europske unije u odnosu na Republiku Hrvatsku, što ima značajan utjecaj na PLDP (turizam). Godišnji prosjeci stopa promjene PGDP-a kreću se od -4,20% do 7,12% što ukazuje na značajnija odstupanja (standardna devijacija iznosi 2,89%). Prikaz prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje nalazi se na grafikonu 2.

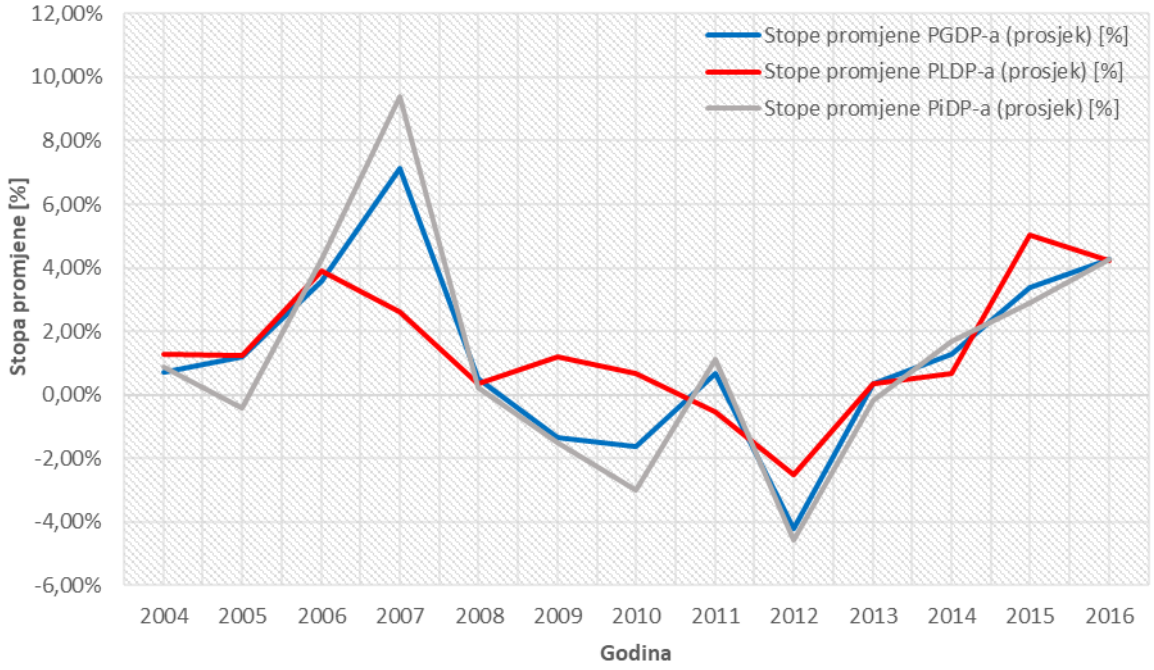

Grafikon 2. Trend analiza godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (Izvor:[50], autorova obrada)

Analizom postojanja statistički značajne razlike kretanja prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje za PGDP, PLDP i PiDP nije utvrđena statistički značajna razlika. Rezultati Tukey-Kramerovoga testa prikazani su grafikonom 3. Za potrebe korištenje predmetnoga testa ispitane su i zadovoljene polazne pretpostavke čiji su rezultati prikazani u 3. i 4. poglavlju. Korištena je razina značajnosti 0,05 dok je polazna hipoteza glasila da ne postoji statistički značajna razlika između prosječnih godišnjih stopa promjena PGDP-a, PLDP-a i PiDP-a tijekom analiziranoga razdoblja.

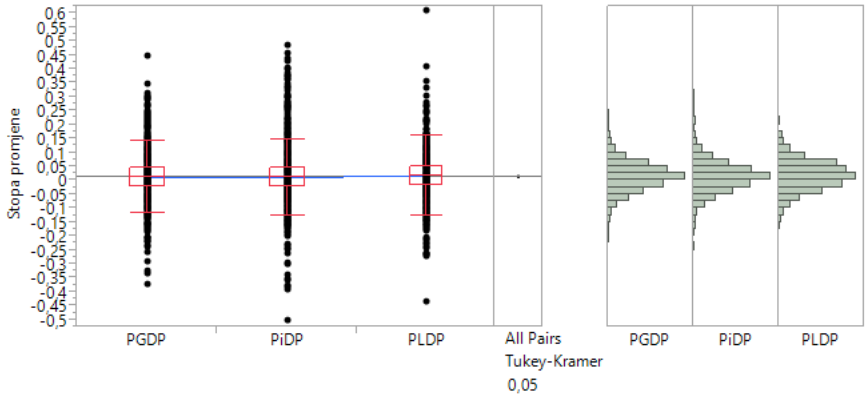

Level		Mean
PLDP	A	0,01577530
PGDP	A	0,01380265
PiDP	A	0,01283532

Level	- Level	Difference	Std Err Dif	Lower CL	Upper CL	p-Value
PLDP	PiDP	0,0029400	0,0016897	-0,001021	0,0069009	0,1904
PLDP	PGDP	0,0019726	0,0016862	-0,001980	0,0059251	0,4712
PGDP	PiDP	0,0009673	0,0016794	-0,002969	0,0049041	0,8330

Grafikon 3. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje ovisno o dobu godine (Tukey-Kramerov test)

2.1.2. Kategorija prometnice

Uzimajući u obzir značajnije razlike u opterećenjima na pojedinim kategorijama prometnica, samu prometnu funkciju pojedinih kategorija prometnica, kao i rezultate analize dosadašnjih istraživanja [23], [25] kategorija prometnica analizirana je kao zaseban pokazatelj. Sukladno dostupnim podacima o brojenjima prometa [50], u obzir su se uzele sljedeće kategorije prometnica:

- autoceste
- državne ceste
- županijske ceste.

Na autocestama je analizirano 2.506, na državnim cestama 5.877, a na županijskim cestama 967 mjerenja.

Analizom baze podataka brojenja prometa najveći prosječni rast godišnjih stopa promjena PGDP-a, PLDP-a i PiDP-a utvrđen je na autocestama, a zatim državnim cestama, dok je na županijskim cestama utvrđen blagi prosječni pad. Shodno tome, PGDP je u analiziranome periodu na autocestama godišnje u prosjeku rastao 4,24%, na državnim cestama svega 0,45%, dok je na županijskim cestama zabilježen trend pada od -0,61%. Najveći rast zabilježen je u 2007. godini (na autocestama u 2006. godini), a najveći pad u 2012. godini (na županijskim cestama u 2011. godini). Trendovi su prosječnih godišnjih stopa promjena intenziteta cestovne

prijevozne potražnje za PGDP, PLDP i PiDP po pojedinim kategorijama prometnica prikazani grafikonima 4 - 6.

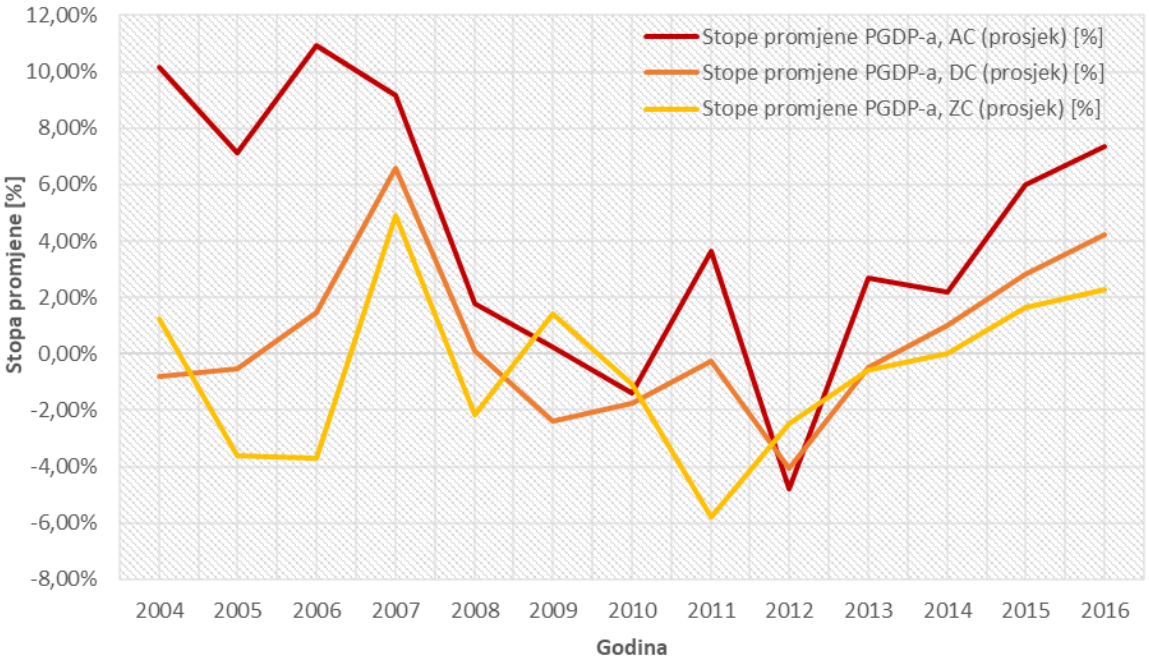

Grafikon 4. Trend prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje PGDP-a (Izvor:[50], autorova obrada)

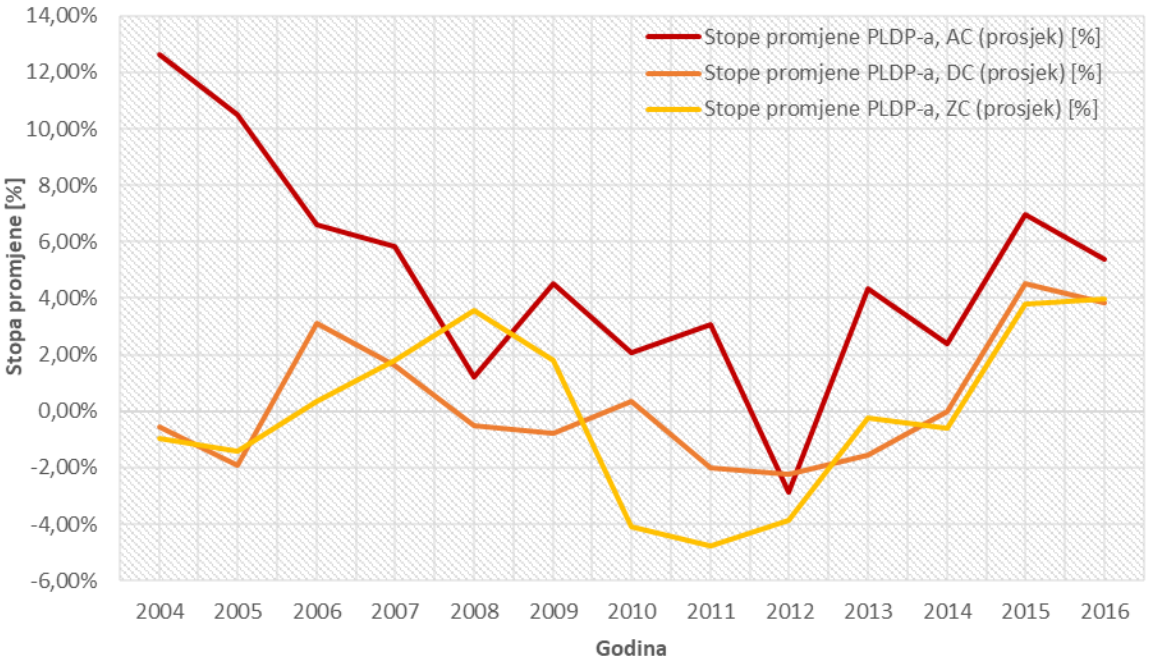

Grafikon 5. Trend prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje PLDP-a (Izvor:[50], autorova obrada)

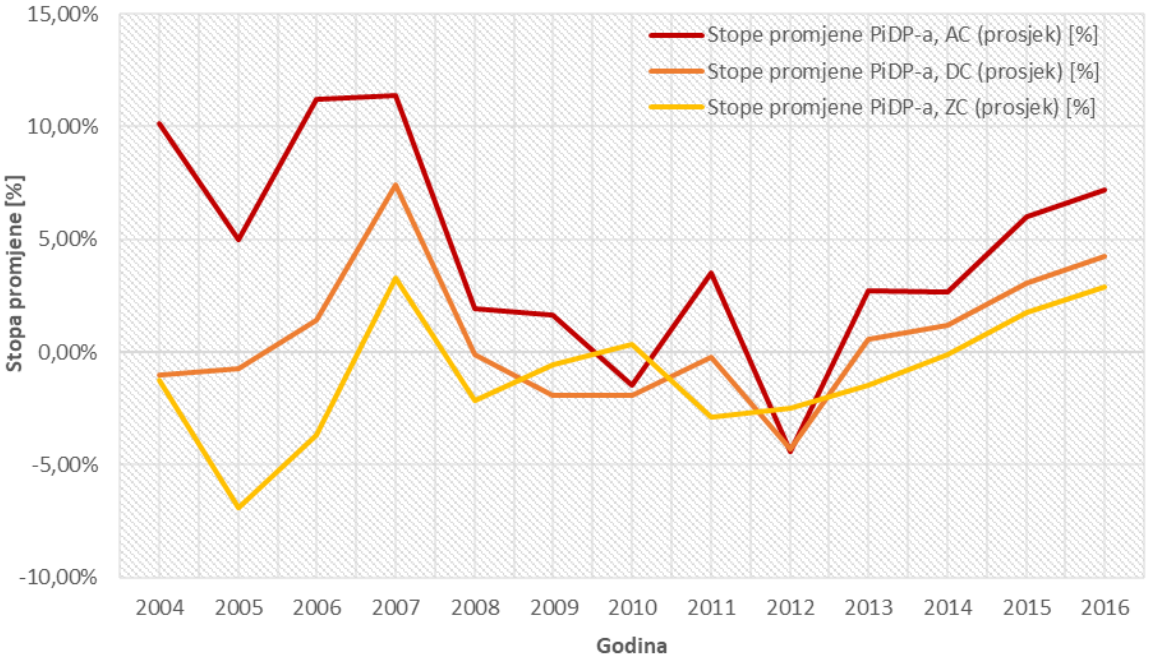

Grafikon 6. Trend prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje PiDP-a (Izvor:[50], autorova obrada)

Grafičkom i deskriptivnom analizom mogu se utvrditi razlike u vrijednostima prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje po pojedinoj kategoriji prometnice, pa je shodno tome provedeno ispitivanje razlike sredina. Analizom postojanja statistički značajne razlike kretanja prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje za PGDP, PLDP i PiDP prema pojedinoj kategoriji prometnice utvrđena je sljedeća statistički značajna razlika sredina:

- PGDP – utvrđena je statistički značajna razlika između autocesta te državnih i županijskih cesta. Između državnih i županijskih cesta nije utvrđena statistička značajna razlika.
- PLDP – utvrđena je statistički značajna razlika između svih kategorija prometnica.
- PiDP – utvrđena je statistički značajna razlika između autocesta te državnih i županijskih cesta. Između državnih i županijskih cesta nije utvrđena statistička značajna razlika.

Dobiveni rezultati sukladni su s podacima PGDP-a, PLDP-a i PiDP-a, a uzimajući u obzir sličnost vrijednosti PGDP-a i PiDP-a te značajnije razlike PLDP-a.

Rezultati Tukey-Kramerovoga testa prikazani su grafikonima 7 - 9. Za potrebe korištenja predmetnoga testa ispitane su i zadovoljene polazne pretpostavke čiji su rezultati prikazani u 3. i 4. poglavlju. Korištena razina značajnosti je 0,05, dok je polazna hipoteza glasila da ne postoji statistički značajna razlika između prosječnih godišnjih stopa promjena PGDP-a, PLDP-a i PiDP-a prema kategoriji prometnice, a tijekom analiziranoga razdoblja.

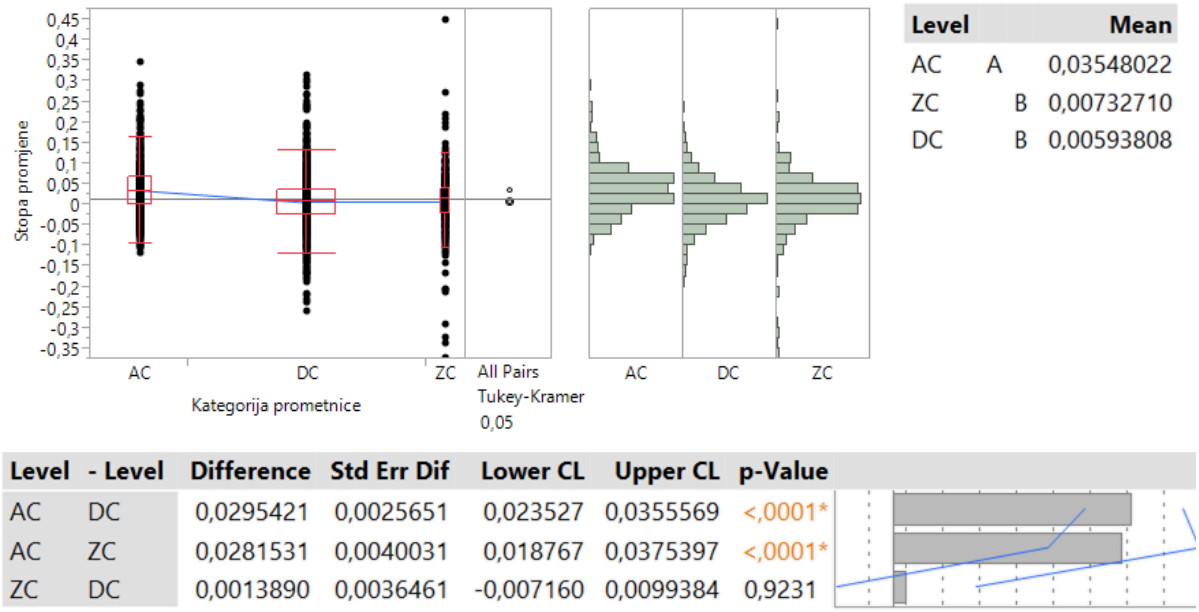

Level		Mean
AC	A	0,03548022
ZC	B	0,00732710
DC	B	0,00593808

Level	- Level	Difference	Std Err Dif	Lower CL	Upper CL	p-Value
AC	DC	0,0295421	0,0025651	0,023527	0,0355569	<,0001*
AC	ZC	0,0281531	0,0040031	0,018767	0,0375397	<,0001*
ZC	DC	0,0013890	0,0036461	-0,007160	0,0099384	0,9231

Grafikon 7. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje ovisno o kategoriji prometnice, PGDP (Tukey-Kramerov test)

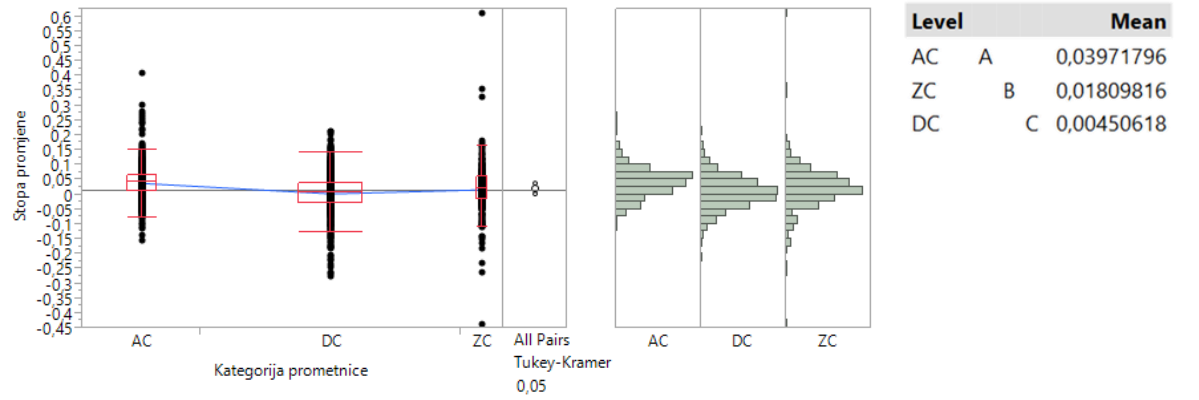

Level		Mean
AC	A	0,03971796
ZC	B	0,01809816
DC	C	0,00450618

Level	- Level	Difference	Std Err Dif	Lower CL	Upper CL	p-Value
AC	DC	0,0352118	0,0024509	0,0294649	0,0409587	<,0001*
AC	ZC	0,0216198	0,0039763	0,0122959	0,0309437	<,0001*
ZC	DC	0,0135920	0,0036826	0,0049568	0,0222271	0,0007*

Grafikon 8. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje ovisno o kategoriji prometnice, PLDP (Tukey-Kramerov test)

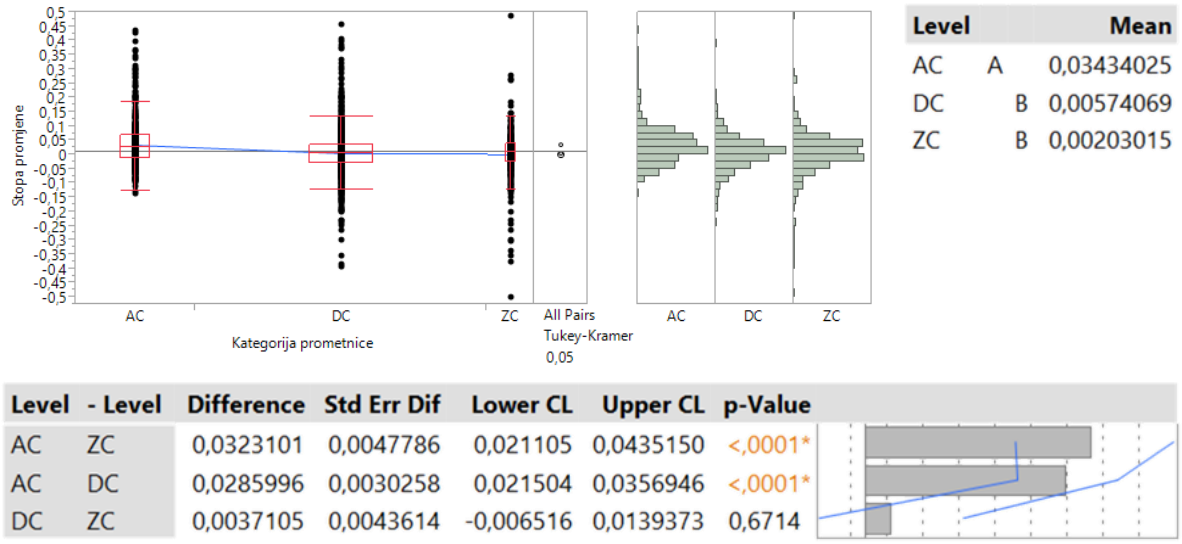

Level		Mean
AC	A	0,03434025
DC	B	0,00574069
ZC	B	0,00203015

Level	- Level	Difference	Std Err Dif	Lower CL	Upper CL	p-Value
AC	ZC	0,0323101	0,0047786	0,021105	0,0435150	<,0001*
AC	DC	0,0285996	0,0030258	0,021504	0,0356946	<,0001*
DC	ZC	0,0037105	0,0043614	-0,006516	0,0139373	0,6714

Grafikon 9. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje ovisno o kategoriji prometnice, PiDP (Tukey-Kramerov test)

2.1.3. Geografski položaj

Geografski položaj analiziran je prema nacionalnoj klasifikaciji prostornih jedinica (NUTS-1, NUTS-2 i NUTS-3) [49]. S obzirom na to da je ispitivana razlika sredina godišnjih stopa promjena cestovne prijevozne potražnje prema različitim prostornim jedinicama, ovaj pokazatelj analiziran je u sklopu grupe prometnih pokazatelja. Za potrebe ispitivanja proveden je Tukey-Kramerov test. Za potrebe korištenje predmetnoga testa ispitane su i zadovoljene polazne pretpostavke, čiji su rezultati prikazani u 3. i 4. poglavlju. Korištena je razina značajnosti 0,05, dok je polazna hipoteza glasila da ne postoji statistički značajna razlika kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema različitim prostornim jedinicama.

Za potrebe analize provedeno je statističko ispitivanje razlike sredina godišnjih stopa promjena PGDP-a, PLDP-a i PiDP-a po županijama (NUTS 3) te statističkim regijama (NUTS 2). Za područje Republike Hrvatske (NUTS 1) utvrđeno je da postoji statistički značajna razlika godišnjih stopa promjena cestovne prijevozne potražnje u analiziranome periodu (v. grafikon 1). Uz prethodno navedeno provedeno je i ispitivanje prema šest funkcionalnih regija koje prema *Strategiji prometnoga razvoja Republike Hrvatske* (2017.-2030.) [52] odražavaju veći dio dnevnih migracija u Republici Hrvatskoj. Tijekom analize po prostornim jedincima također je zabilježeno da ni NUTS 3, ni NUTS 2 ni funkcionalne regije ne predstavljaju stvarne gospodarske i prometno funkcionalne regije Republike Hrvatske već administrativne granice. Isto pokazuju značajne razlike razvoja (shodno tome i intenziteta prometa) po županijama (npr.

Grad Zagreb i svi drugi veći gradovi u odnosu na županije bez većih gradova u svojemu sastavu), kao i unutar samih županija (npr. županije Jadranske Hrvatske poput Ličko-senjske i Primorko-goranske županije imaju gospodarski značajno jače jedinice lokalne samouprave na obali nego u unutrašnjosti, a prema dostupnim statističkim podacima vrednuju se kroz prosječni BDP županije).

U prvome koraku provedena je analiza na razini županija (NUTS 3), pri čemu je utvrđeno postojanje statističke značajne razlike sredina godišnjih stopa promjene cestovne prijevozne potražnje kada su u pitanju PGDP i PLDP. Za PiDP nije utvrđeno postojanje statističke značajne razlike sredina godišnjih stopa promjene cestovne prijevozne potražnje po županijama (NUTS 3). Ako se detaljnije analiziraju županije, razvidno je da generalno veće stope promjene bilježe županije Jadranske Hrvatske, što se može protumačiti da je uzrokovano upravo PLDP-om, odnosno turističkom sezonom. Isto potvrđuje i činjenica da je upravo za PLDP zabilježen znatno veći broj razlika sredina između županija. Shodno tome, očekivano je i da za PiDP nije utvrđeno postojanje statističke značajne razlike sredina godišnjih stopa promjene cestovne prijevozne potražnje po županijama (NUTS 3) jer, ukoliko se izuzme utjecaj turističke aktivnosti, gospodarski i demografski pokazatelji u pravilu su slični na području cijele Republike Hrvatske (godišnja stopa promjene BDP-a statistički se ne razlikuje značajno prema NUTS 3). Rezultati provedene analize po županijama (NUTS 3) prikazani su grafikonima 10 - 12.

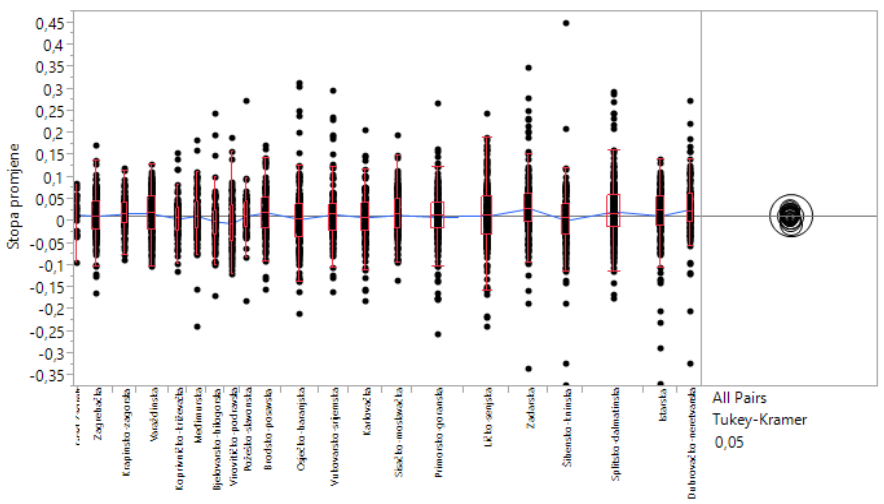

Level		Mean
Zadarska	A	0,0294523
Dubrovačko-neretvanska	A B	0,0273783
Splitsko-dalmatinska	A B	0,0224663
Brodsko-posavska	A B	0,0203172
Varaždinska	A B	0,0172738
Krapinsko-zagorska	A B	0,0171980
Vukovarsko-srijemska	A B	0,0161542
Grad Zagreb	A B	0,0152558
Sisačko-moslavačka	A B	0,0145684
Istarska	A B	0,0128554
Međimurska	A B	0,0125666
Požeško-slavonska	A B	0,0124646
Zagrebačka	A B	0,0123639
Ličko-senjska	A B	0,0121993
Primorsko-goranska	A B	0,0099004
Karlovačka	A B	0,0091011
Koprivničko-križevačka	A B	0,0061236
Osječko-baranjska	B	0,0050882
Šibensko-kninska	B	0,0026260
Bjelovarsko-bilogorska	B	-0,0002555
Virovitičko-podravska	B	-0,0045006

Grafikon 10. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 3, PGDP (Tukey-Kramerov test)

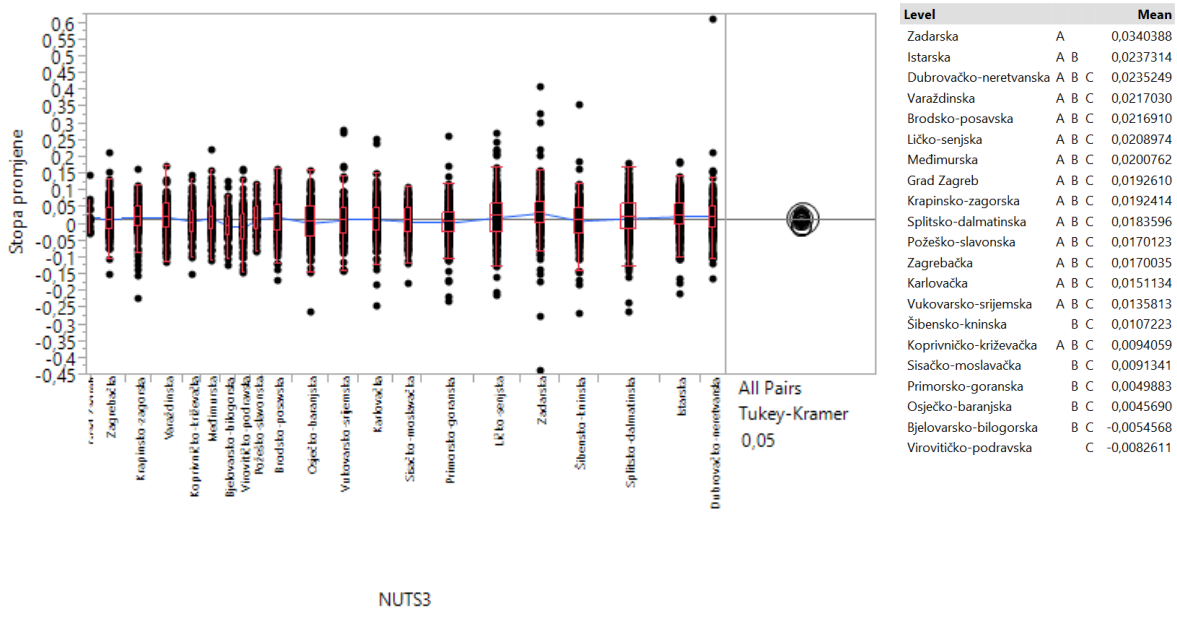

Level				Mean
Zadarska	A			0,0340388
Istarska	A	B		0,0237314
Dubrovačko-neretvanska	A	B	C	0,0235249
Varaždinska	A	B	C	0,0217030
Brodsko-posavska	A	B	C	0,0216910
Ličko-senjska	A	B	C	0,0208974
Međimurska	A	B	C	0,0200762
Grad Zagreb	A	B	C	0,0192610
Krapinsko-zagorska	A	B	C	0,0192414
Splitsko-dalmatinska	A	B	C	0,0183596
Požeško-slavonska	A	B	C	0,0170123
Zagrebačka	A	B	C	0,0170035
Karlovačka	A	B	C	0,0151134
Vukovarsko-srijemska	A	B	C	0,0135813
Šibensko-kninska		B	C	0,0107223
Koprivničko-križevačka	A	B	C	0,0094059
Sisačko-moslavačka		B	C	0,0091341
Primorsko-goranska		B	C	0,0049883
Osječko-baranjska		B	C	0,0045690
Bjelovarsko-bilogorska		B	C	-0,0054568
Virovitičko-podravska			C	-0,0082611

Grafikon 11. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 3, PLDP (Tukey-Kramerov test)

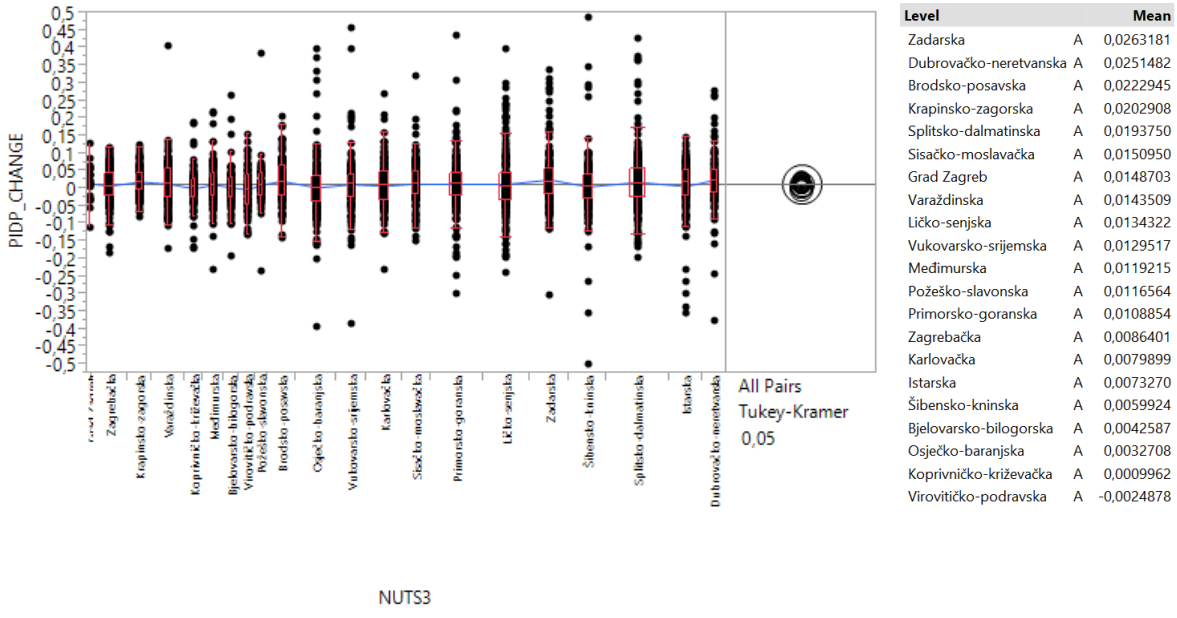

Level		Mean
Zadarska	A	0,0263181
Dubrovačko-neretvanska	A	0,0251482
Brodsko-posavska	A	0,0222945
Krapinsko-zagorska	A	0,0202908
Splitsko-dalmatinska	A	0,0193750
Sisačko-moslavačka	A	0,0150950
Grad Zagreb	A	0,0148703
Varaždinska	A	0,0143509
Ličko-senjska	A	0,0134322
Vukovarsko-srijemska	A	0,0129517
Međimurska	A	0,0119215
Požeško-slavonska	A	0,0116564
Primorsko-goranska	A	0,0108854
Zagrebačka	A	0,0086401
Karlovačka	A	0,0079899
Istarska	A	0,0073270
Šibensko-kninska	A	0,0059924
Bjelovarsko-bilogorska	A	0,0042587
Osječko-baranjska	A	0,0032708
Koprivničko-križevačka	A	0,0009962
Virovitičko-podravska	A	-0,0024878

Grafikon 12. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 3, PiDP (Tukey-Kramerov test)

Sukladno elaboriranim i prikazanim rezultatima na razini županija (NUTS 3), na razini statističkih regija (NUTS 2) utvrđeno je slično. Kad su u pitanju PGDP i PLDP, utvrđeno je postojanje statističke značajne razlike sredina godišnjih stopa promjene cestovne prijevozne potražnje po regijama (NUTS 2), dok za PiDP nisu utvrđene statistički značajne razlike. Pri tome je važno napomenuti da statistička značajnost za PGDP iznosi 0,03, dok je za PLDP

značajnost veća te iznosi 0,01, što je u skladu s utvrđenim podacima da su gospodarski i demografski pokazatelji u pravilu slični na području cijele Republike Hrvatske. Rezultati provedene analize po statističkim regijama (NUTS 2) prikazani su grafikonima 13 - 15.

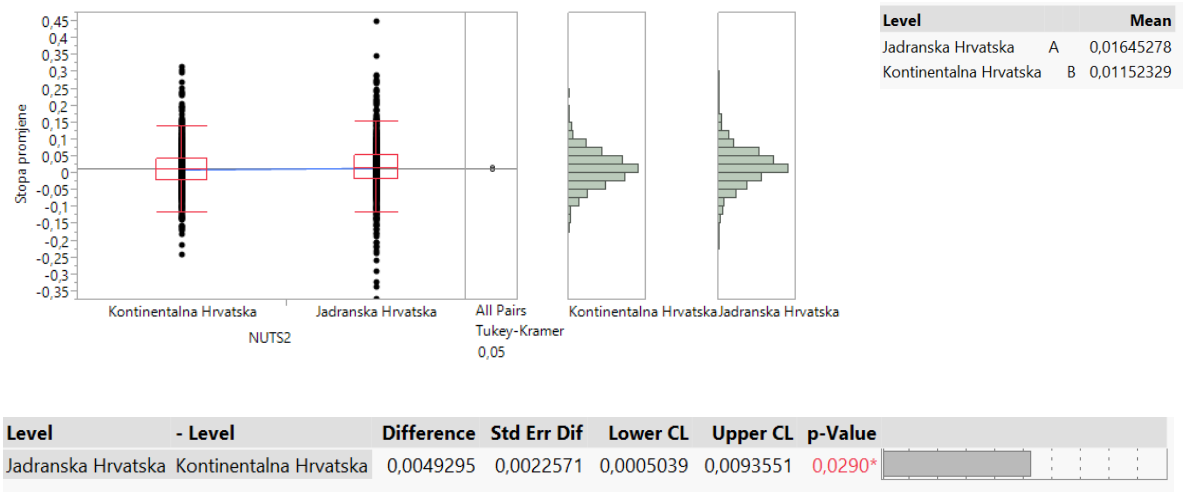

Level		Mean
Jadranska Hrvatska	A	0,01645278
Kontinentalna Hrvatska	B	0,01152329

Level	- Level	Difference	Std Err Dif	Lower CL	Upper CL	p-Value
Jadranska Hrvatska	Kontinentalna Hrvatska	0,0049295	0,0022571	0,0005039	0,0093551	0,0290*

Grafikon 13. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 2, PGDP (Tukey-Kramerov test)

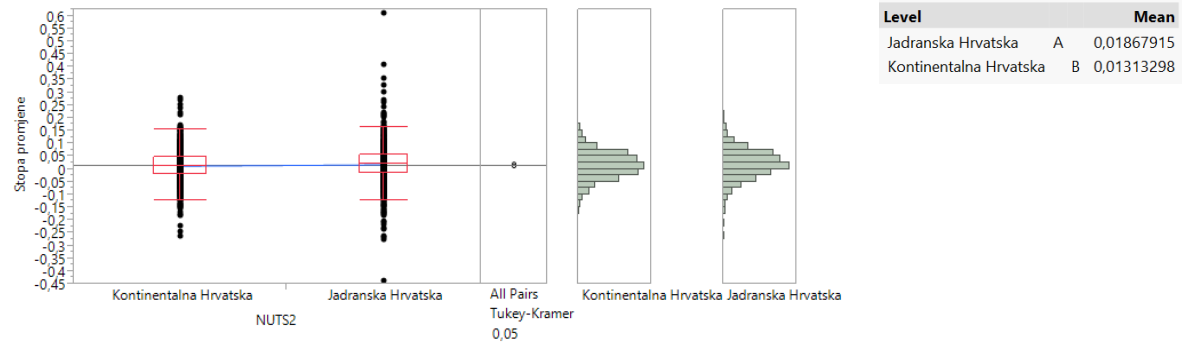

Level		Mean
Jadranska Hrvatska	A	0,01867915
Kontinentalna Hrvatska	B	0,01313298

Level	- Level	Difference	Std Err Dif	Lower CL	Upper CL	p-Value
Jadranska Hrvatska	Kontinentalna Hrvatska	0,0055462	0,0022278	0,0011780	0,0099143	0,0128*

Grafikon 14. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 2, PLDP (Tukey-Kramerov test)

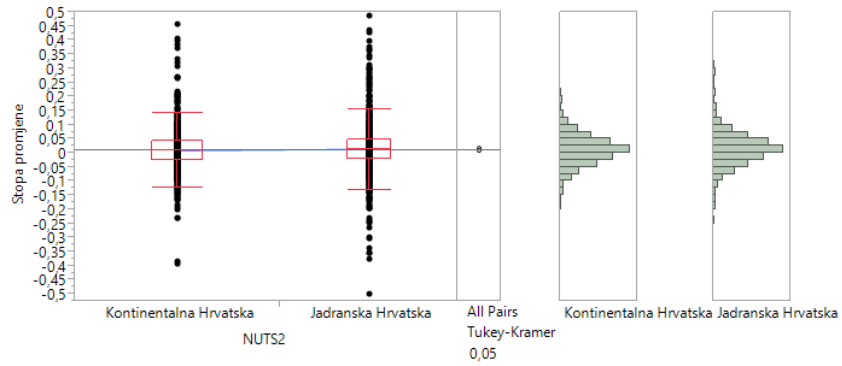

Level		Mean
Jadranska Hrvatska	A	0,01535538
Kontinentalna Hrvatska	A	0,01066368

Level	- Level	Difference	Std Err Dif	Lower CL	Upper CL	p-Value
Jadranska Hrvatska	Kontinentalna Hrvatska	0,0046917	0,0026503	-0,000505	0,0098882	0,0768

Grafikon 15. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 2, PiDP (Tukey-Kramerov test)

Analizom razlike sredine prema funkcionalnim regijama također je utvrđeno da, kada su u pitanju PGDP i PLDP, postoji statistički značajna razlika sredina godišnjih stopa promjene cestovne prijevozne potražnje po regijama (FR), dok za PiDP nisu utvrđene statistički značajne razlike. Rezultati provedene analize po funkcionalnim regijama (FR) prikazani su grafikonima 16 - 18.

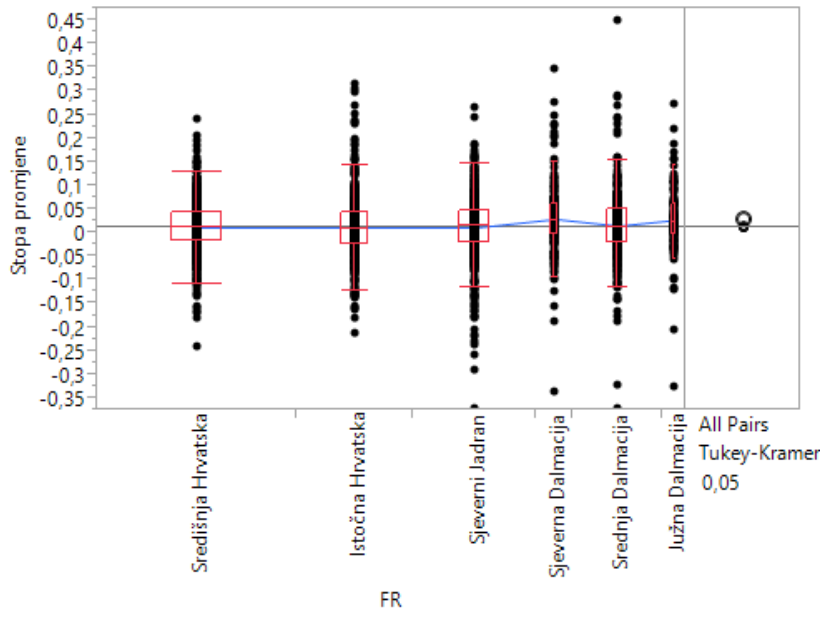

Level		Mean
Sjeverna Dalmacija	A	0,02945227
Južna Dalmacija	A B	0,02737827
Srednja Dalmacija	A B	0,01520256
Središnja Hrvatska	B	0,01198273
Sjeverni Jadran	B	0,01146168
Istočna Hrvatska	B	0,01073746

Grafikon 16. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema funkcionalnoj regiji, PGDP (Tukey-Kramerov test)

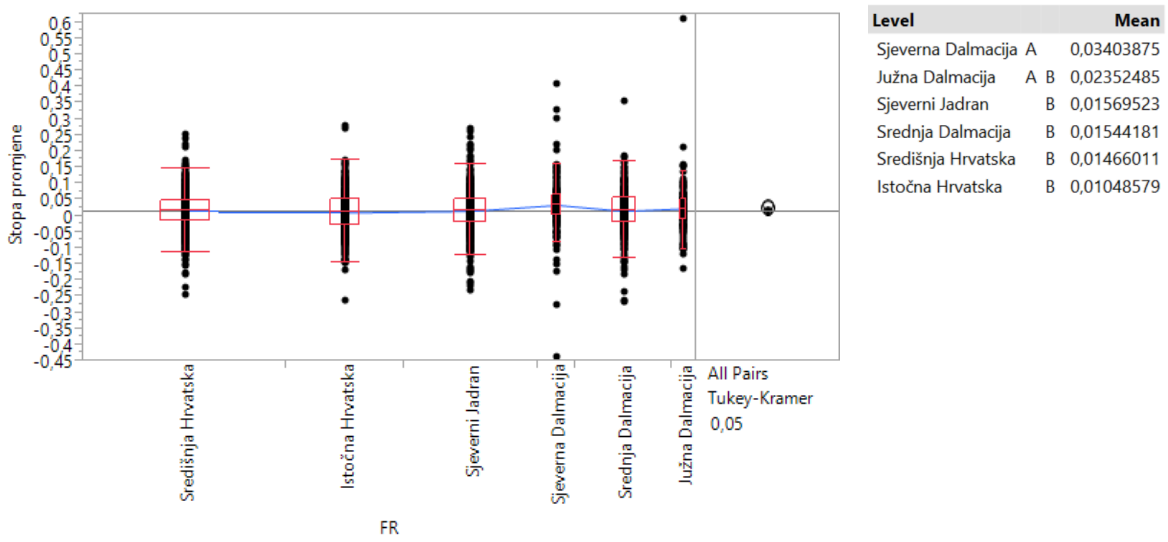

Grafikon 17. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema funkcionalnoj regiji, PLDP (Tukey-Kramerov test)

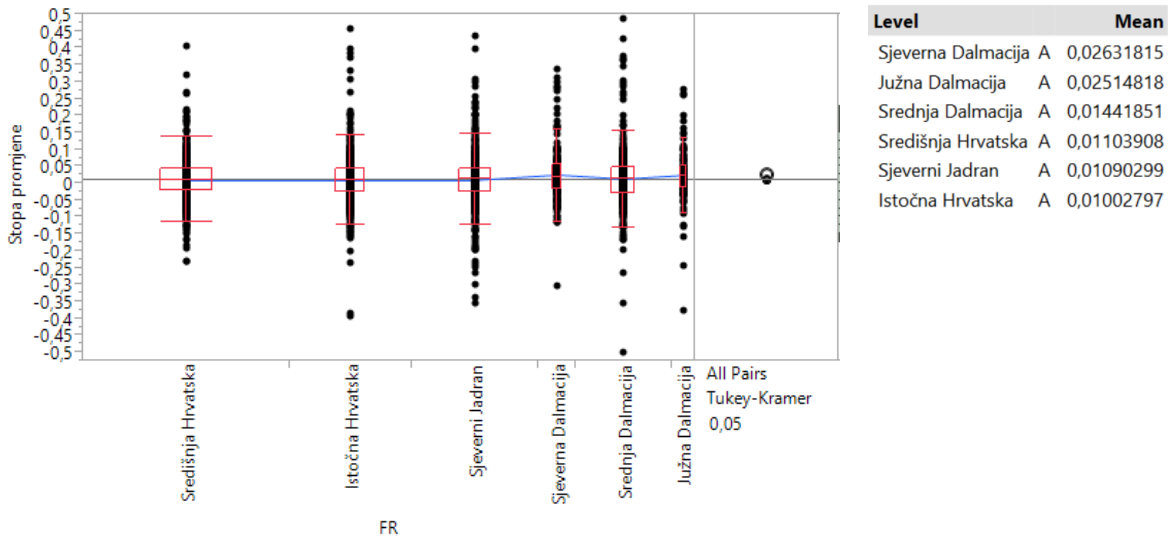

Grafikon 18. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema funkcionalnoj regiji, PiDP (Tukey-Kramerov test)

2.1.4. Motorna vozila

S obzirom na to da se cestovna prijevozna potražnja izvodi motornim vozilima, za očekivati je da broj registriranih vozila ima i utjecaj na kretanje prijevozne potražnje, odnosno modalnu raspodjelu. Jednako pokazuje i analiza dosadašnjih istraživanja [25], [36]. Shodno tome, provedena je analiza trenda broja registriranih cestovnih motornih vozila i broja osobnih vozila te njihovih stopa promjena za analizirani period.

Analizom je utvrđeno da je broj registriranih cestovnih motornih vozila godišnje u prosjeku rastao za oko 1,52% dok je broj registriranih osobnih vozila rastao za oko 1,45% [53]. Na temelju deskriptivne statistike može se utvrditi da su prosječne vrijednosti slične prosječnoj godišnjoj stopi promjene PGDP-a koja iznosi 1,38%. Grafičkom analizom također se može utvrditi vrlo sličan trend godišnjih stopa promjene PGDP-a i stopa promjene broja registriranih cestovnih motornih vozila i registriranih osobnih vozila. Prikaz trenda broja registriranih cestovnih motornih i osobnih vozila te njihovih stopa promjene nalaze se u grafikonima 19 i 20.

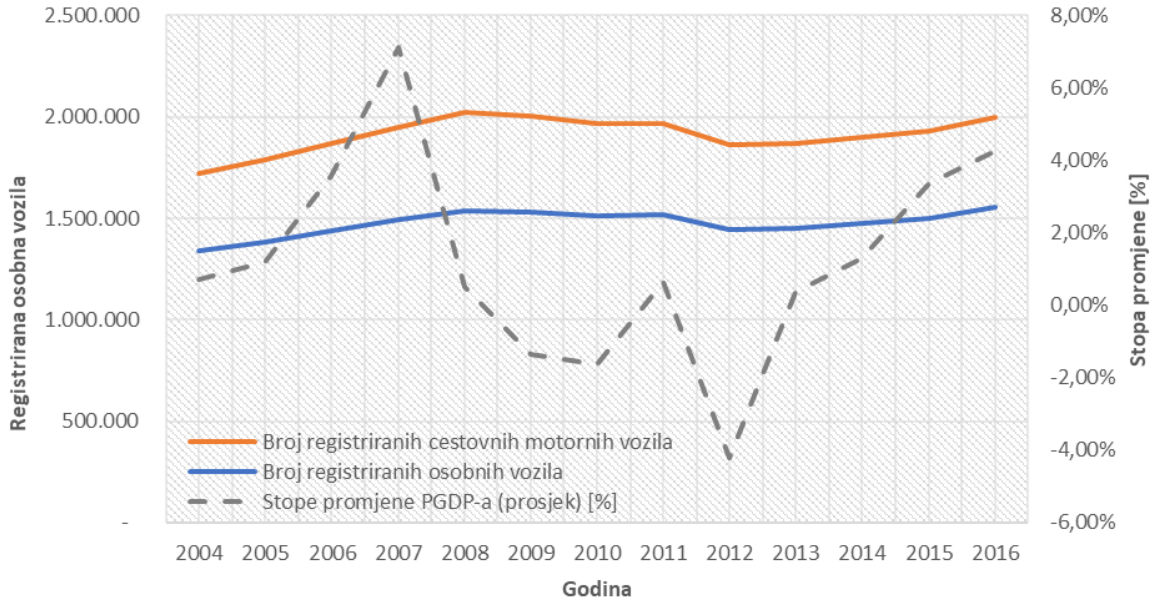

Grafikon 19. Trend analiza broja registriranih cestovnih motornih i osobnih vozila (Izvor: [53], autorova obrada)

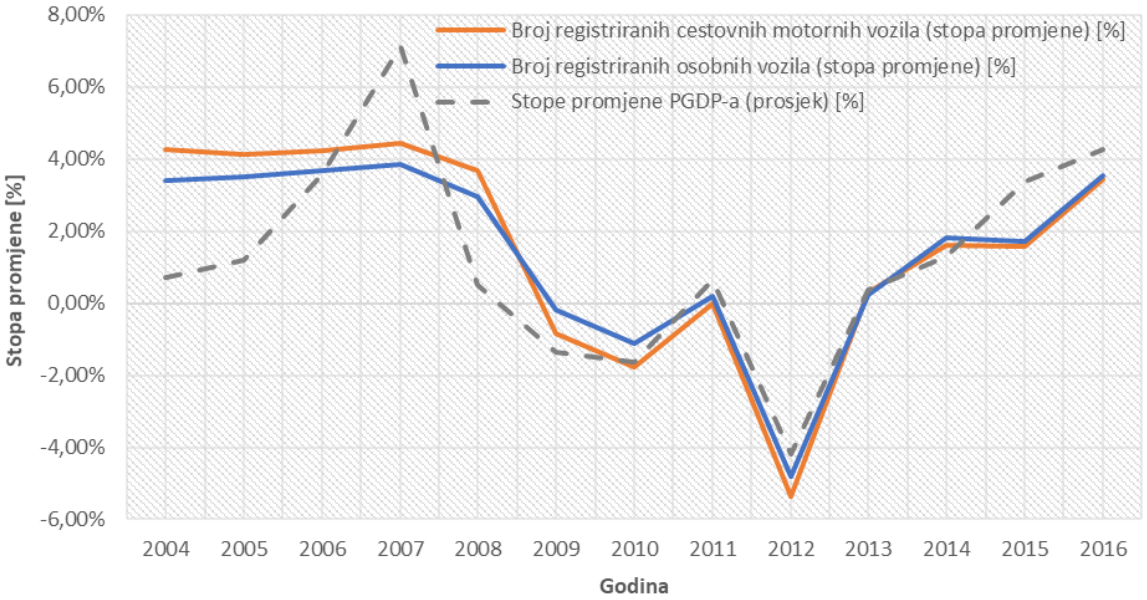

Grafikon 20. Trend analiza broja registriranih cestovnih motornih i osobnih vozila, stope promjene (Izvor: [53], autorova obrada)

Pregled broja registriranih cestovnih motornih i osobnih vozila za statističke regije NUTS 3 nalazi se u prilogu 6.

2.1.5. Prijevoz robe

Kako broj registriranih cestovnih motornih vozila ima utjecaj na modalnu raspodjelu putovanja, za očekivati je i da prijevoz robe ima utjecaj na cestovnu prijevoznu potražnju, napose u Republici Hrvatskoj, gdje željeznički prijevoz nije značajnije razvijen. Za potrebe analize prijevoza robe sagledan je trend robe prevezene cestom i željeznicom u analiziranome periodu te njihove godišnje stope promjene.

Analizom je utvrđeno da je cestovni prijevoz robe u analiziranome periodu u prosjeku godišnje bilježio pad od -1,03%, a željeznički prijevoz rast od 1,31% [53]. Grafičkom analizom trenda može se utvrditi da trend cestovnoga prijevoza robe prati trend stopa promjene PGDP-a, dok je željeznički prijevoz suprotan, odnosno kad se bilježi pad PGDP-a, željeznički prijevoz robe bilježi rast. Slično je i s njihovim godišnjim stopama promjene. Trendovi cestovnoga i željezničkoga prijevoza te njihovih stopa promjene prikazani su grafikonima 21 - 23.

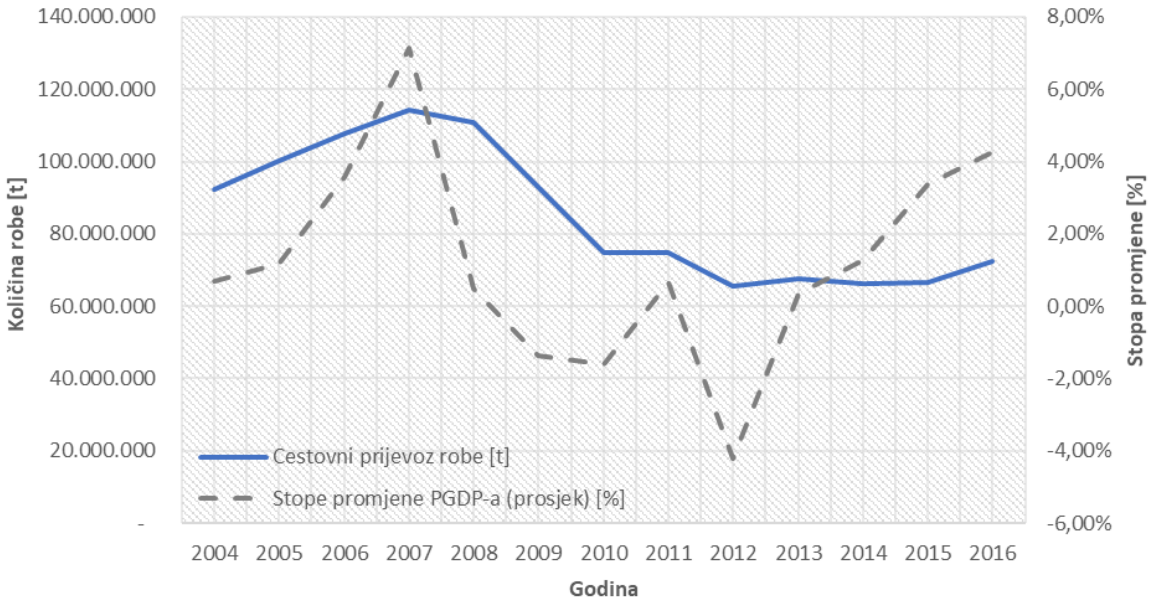

Grafikon 21. Trend analiza cestovnoga prijevoza robe (Izvor: [53], autorova obrada)

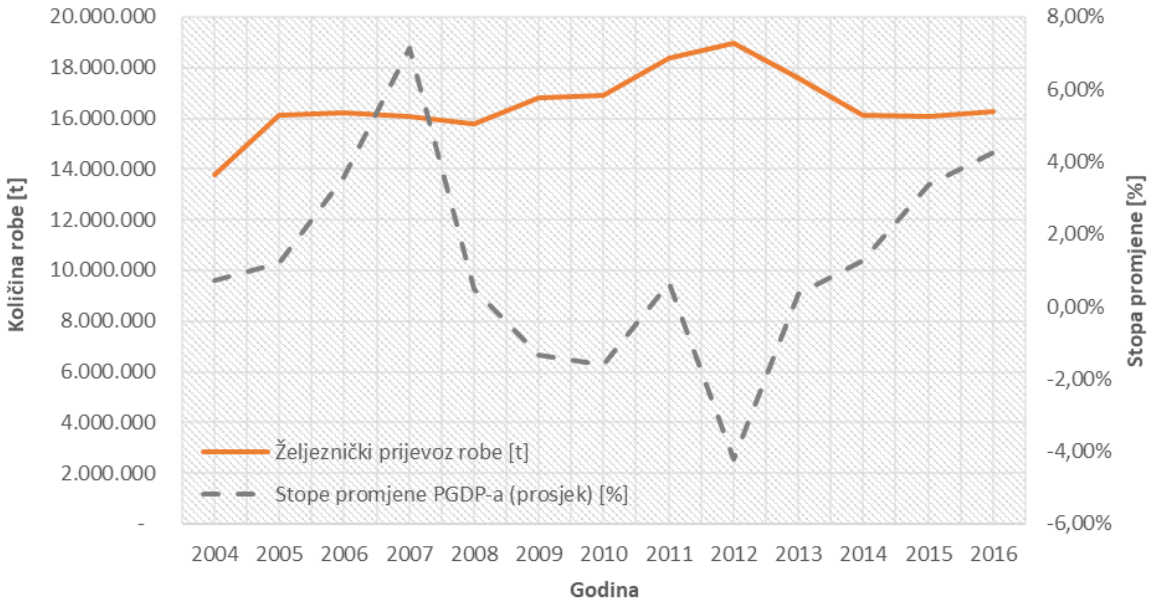

Grafikon 22. Trend analiza željezničkoga prijevoza robe (Izvor: [53], autorova obrada)

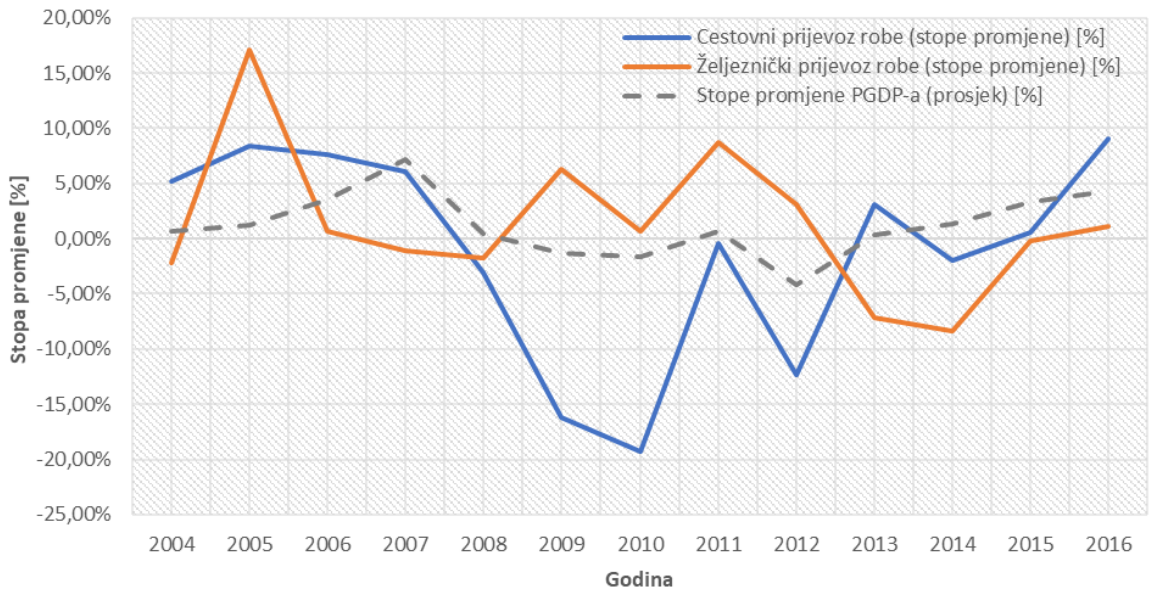

Grafikon 23. Trend analiza cestovnoga i željezničkoga prijevoza robe, stope promjene (Izvor: [53], autorova obrada)

2.2. Gospodarstvo

Prema provedenoj analizi postojećih istraživanja [2], [5], [6], [26], [36] gospodarstvo je jedan od osnovnih utjecajnih čimbenika koji određuje stanje prometnoga sustava općenito, pa tako utječe i na promjenu prijevozne potražnje. To argumentira i činjenica da je promet izvedena potražnja jer je razvidno da pružanje usluge prijevoza, odnosno prometa u širemu smislu, nije moguće bez postojanja potražnje za tom uslugom [2].

Za potrebe razvoja modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu analizirano je 16 pokazatelja iz kategorije gospodarstva. S ciljem lakše deskripcije i interpretacije, pokazatelji su prema svojim karakteristikama svrstani u sljedećih osam grupa:

- bruto domaći proizvod na području Republike Hrvatske
- bruto domaći proizvod na području Europske unije
- industrija
- cijene
- plaće
- gorivo
- zaposlenost

- turizam.

Detaljan prikaz rezultata analize nalazi se u nastavku poglavlja.

2.2.1. BDP (RH)

Bruto domaći proizvod makroekonomski je indikator koji pokazuje vrijednost svih dovršenih roba i usluga koji su proizvedeni u nekoj zemlji u određenome razdoblju te je pretpostavka da ima utjecaj i na kretanje prijevozne potražnje. Uz bruto domaći proizvod analiziran je i bruto domaći proizvod po stanovniku, kao i godišnje stope promjene bruto domaćega proizvoda i bruto domaćega proizvoda po stanovniku.

Prema informacijama Državnoga zavoda za statistiku [53], u analiziranome periodu od 2003. do 2016. godine BDP je u prosjeku iznosio 319.996.111 kuna, a BDP po stanovniku 74.873 kune. Ako se analiziraju realne stope rasta BDP-a (tržišne cijene), utvrđen je prosječni godišnji porast BDP-a od 1,11%. Značajni pad stope promjene BDP-a dogodio se 2008. godine s nastavkom na 2009. godinu, nakon čega slijedi rast do 2012. godine, kada je ponovno zabilježen značajniji pad od -2,24% (grafikon 24). Trend BDP-a po stanovniku prati trend BPD-a. Grafičkom analizom stopa promjena BDP-a i stopa promjena PGDP-a primjetan je sličan trend u analiziranome periodu (grafikon 24).

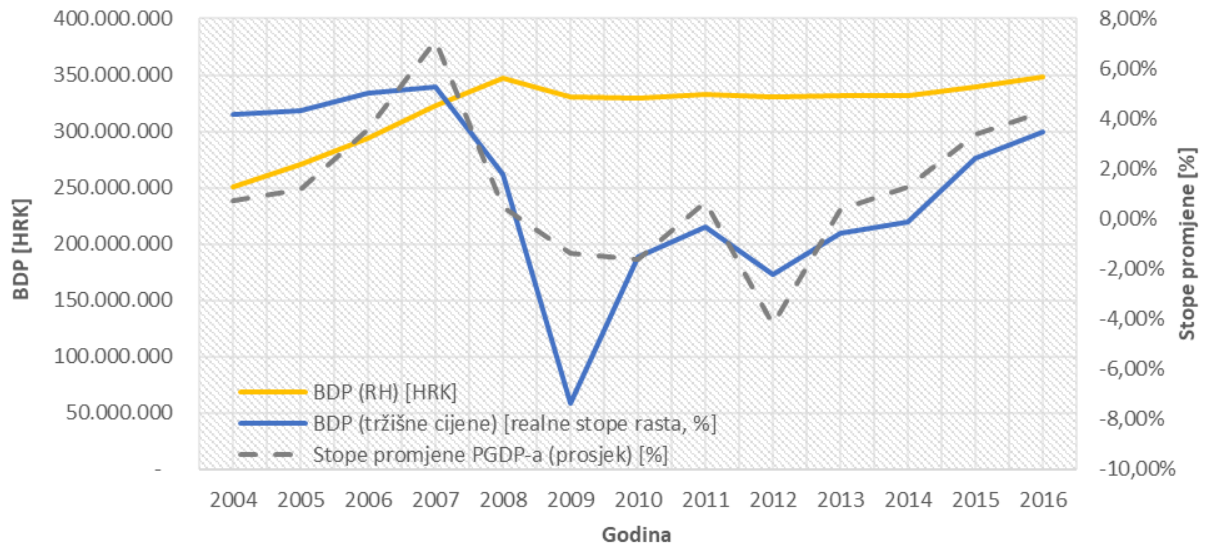

Grafikon 24. Trend analiza BDP-a u Republici Hrvatskoj (Izvor: [53], autorova obrada)

Ako se analizira BDP po županijama (NUTS 3), zamjetno je da četiri županije (19%) (Zagreb, Split, Rijeka i Osijek) nose 53% BDP-a zemlje. Pregled analiziranih podataka BDP-

a, BDP-a po stanovniku te stopa promjena BDP-a po stanovniku za statističke regije NUTS 3 nalazi se u prilogu 1.

2.2.2. BDP (EU)

S obzirom na to da je Republika Hrvatska članica Europske unije, provedena je i analiza osnovnih pokazatelja gospodarskih aktivnosti na razini Europske unije. Naime, osim značajne ovisnosti Hrvatske o turizmu, a samim time i o Europi, na gospodarstvo u Hrvatskoj imaju i utjecaji vanjske trgovine. Prema podacima Državnoga zavoda za statistiku [53], tvrtke koje izvoze u prosjeku zapošljavaju oko 51% zaposlenih u svim poduzećima te ostvaruju oko 66% od ukupnih prihoda od prodaje. Uz navedeno Hrvatska predstavlja tranzitnu zemlju za nemali broj roba i usluga.

Za potrebe rada provedena je analiza stopa promjene BDP-a (u odnosu na prethodnu godinu) na razini Europske unije te za prvih 12 država članica (EA12). Temeljem grafičke analize utvrđeni su vrlo slični trendovi stopa promjena BDP-a, kao što je to slučaj za Republiku Hrvatsku (grafikon 25). Razlike se očituju u manjim vrijednostima smanjenja kao i većim vrijednostima povećanja stopa promjena BDP-a, odnosno Europa bilježi manje gospodarske padove i brže gospodarske oporavke. To isto potvrđuje činjenica da je prosječni godišnji rast u analiziranome periodu iznosio 2,72%, što je više nego dvostruko u odnosu na Republiku Hrvatsku [53], [54]. Kada je u pitanju prvih 12 država članica, utvrđeni su manji padovi i manji porasti BDP-a, što pokazuje da se radi o gospodarski razvijenijim i stabilnijim državama.

Kao što je to i slučaj u Republici Hrvatskoj, grafičkom analizom stopa promjena BDP-a i stopa promjena PGDP-a primjetan je sličan trend u analiziranome periodu (grafikon 25).

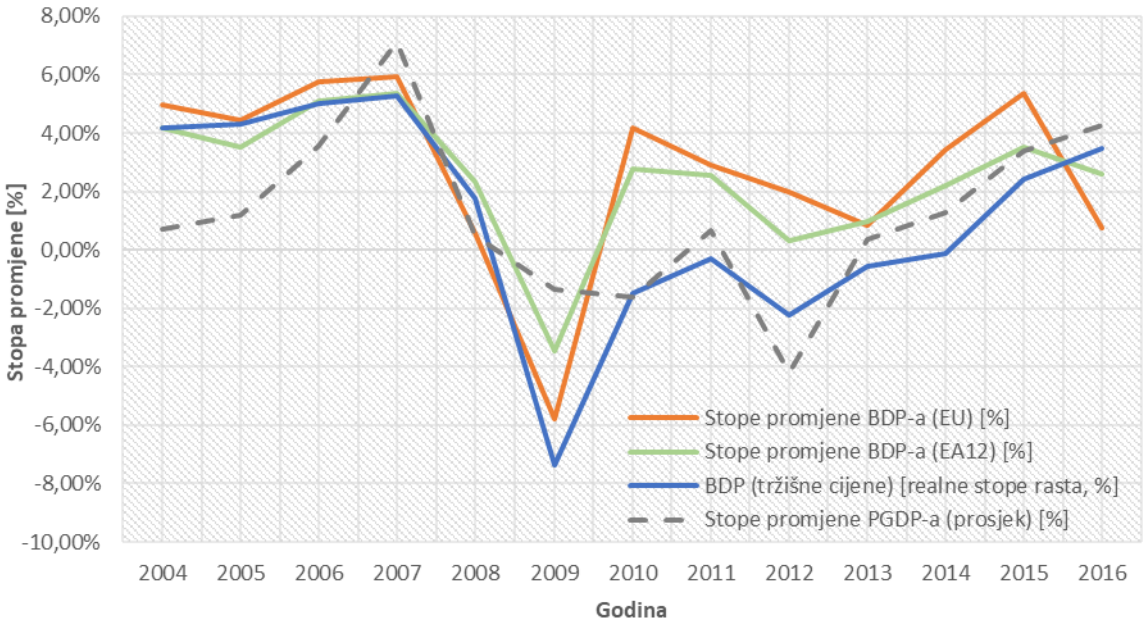

Grafikon 25. Trend analiza BDP-a u Europskoj uniji (Izvor: [53], [54], autorova obrada)

2.2.3. Industrija

Analize industrijske proizvodnje temeljena je na indeksu fizičkoga obujma industrijske proizvodnje (stope promjene) za analizirani period. Indeks fizičkoga obujma industrijske proizvodnje središnji je pokazatelj rezultata koje postiže industrijski sektor [53]. Za potrebe rada korišten je godišnji prosjek stope promjene obujma industrijske proizvodnje izračunat kao prosjek obujma industrijske proizvodnje svakoga mjeseca u pojedinoj godini.

Trend analizom obrađenih podataka utvrđen je sličan trend kao što je to slučaj kod BDP-a. Prosječni godišnji porast obujma industrijske proizvodnje iznosi 0,50% dok medijalna vrijednost iznosi 1,16%, što pokazuje veći iznos standardne devijacije koja iznosi 4,19%. Uzimajući u obzir da je industrija jedna od nestabilnijih sastavnica gospodarstva, dobiveni rezultati su očekivani. [53]

Grafičkom analizom stopa promjena obujma industrijske proizvodnje i stopa promjena PGDP-a primjetan je sličan trend u analiziranom periodu (grafikon 26).

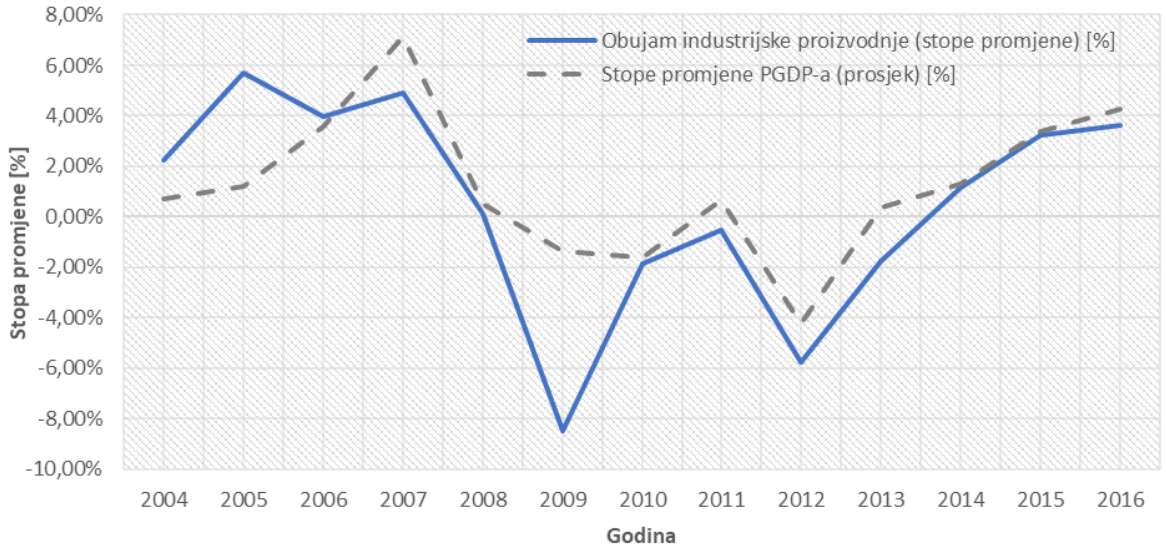

Grafikon 26. Trend analiza obujma industrijske proizvodnje (Izvor: [53], autorova obrada)

2.2.4. Cijene

S ciljem uzimanja u obzir vrijednost novca, odnosno inflacije, analizirani su i indeksi potrošačkih cijena koji prikazuju promjene cijena dobara i usluga koje plaća stanovništvo radi potrošnje [53].

Za potrebe rada analizirane su stope promjene indeksa potrošačkih cijena te indeksa potrošačkih cijena bez energije i hrane. Grafičkom analizom utvrđen je sličan trend kretanja stopa promjena predmetnih indeksa u odnosu na stope promjene PGDP-a te se može konstatirati da indeksi potrošačkih cijena imaju pomak jednu godinu naprijed (grafikoni 27 i 28). Prosječni porast stopa promjena indeksa potrošačkih cijena iznosio je 2,08%, a stopa promjena indeksa potrošačkih cijena bez energije i hrane 1,69% [53].

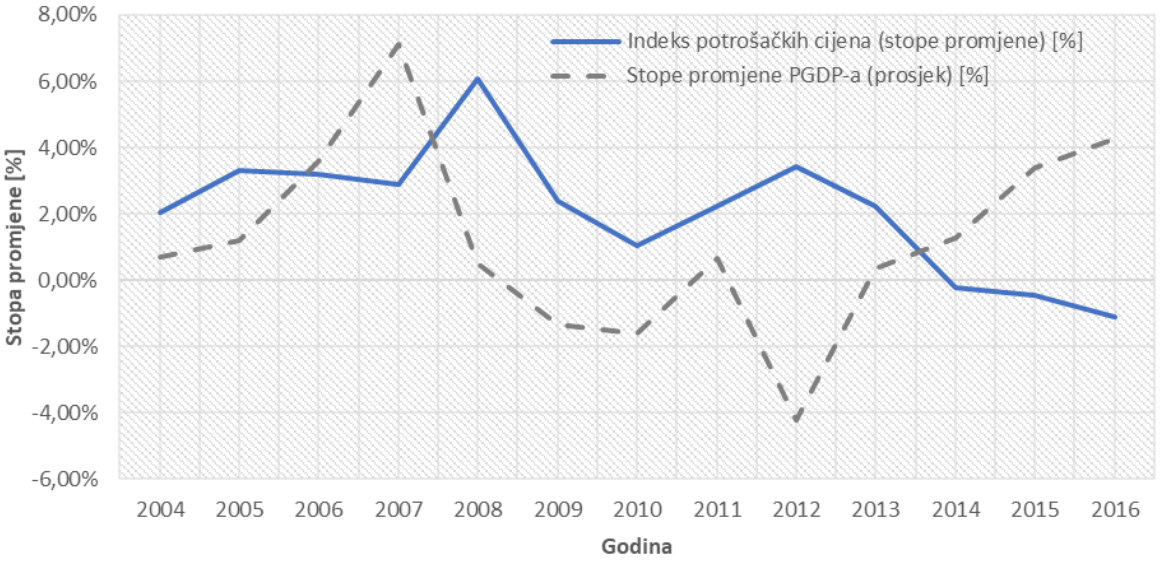

Grafikon 27. Trend analiza indeksa potrošačkih cijena (Izvor: [53], autorova obrada)

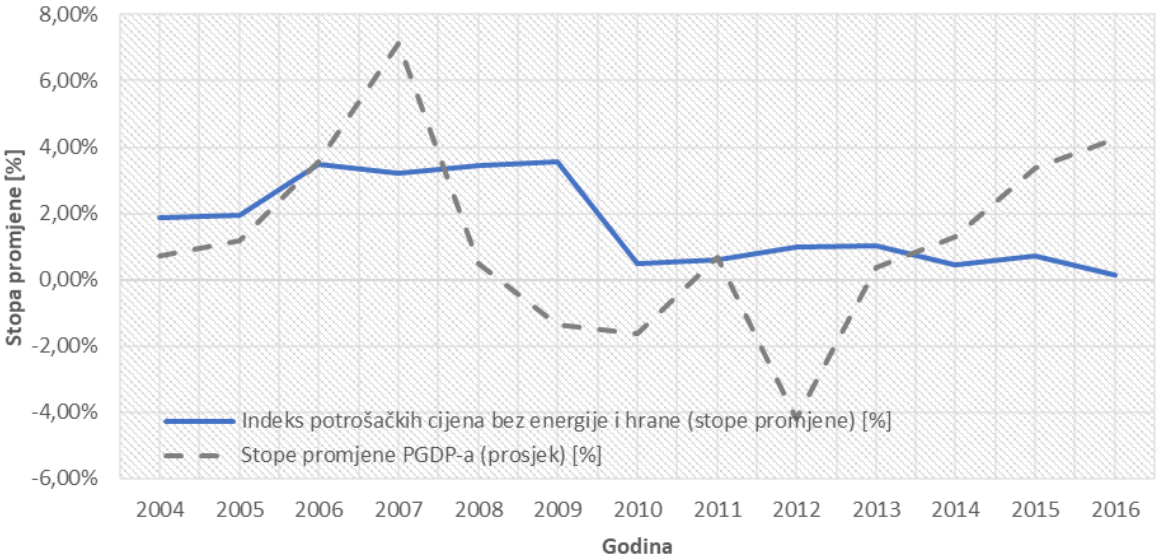

Grafikon 28. Trend analiza indeksa potrošačkih cijena bez energije i hrane (Izvor: [53], autorova obrada)

2.2.5. Plaće

S ciljem utvrđivanja potrošačke moći stanovništva, analizirani su podaci o plaćama kroz nominalne i realne indekse neto plaće, odnosno nominalni i realni rast neto plaće. Nominalni indeksi neto plaća izračunavaju se prema prosječnim mjesečnim iznosima neto plaća, dok se realni indeksi neto plaća izračunavaju dijeljenjem nominalnih indeksa neto plaća s indeksom troškova života za odgovarajuće mjesece i godine [53].

Grafičkom analizom utvrđen je sličan trend kretanja predmetnih indeksa sa stopama promjena PGDP-a, pri čemu stope promjene realnoga rasta neto plaća imaju nešto sličniji trend u odnosu na stope promjene nominalnoga rasta (grafikoni 29 i 30). U analiziranome periodu prosječan nominalni rast neto plaće iznosio je 3,06%, a prosječan realni rast neto plaće svega oko 0,98%. Prema grafičkoj se analizi također može konstatirati da nominalni rast neto plaće ima pomak jednu godinu naprijed u odnosu na stope promjene PGDP-a, što nije slučaj kod realnoga rasta.

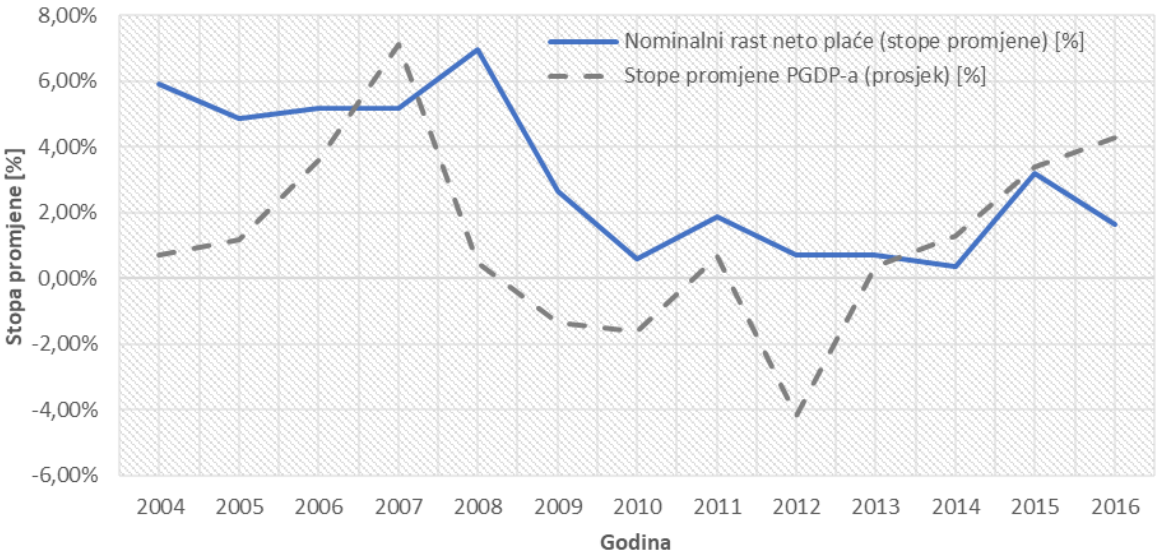

Grafikon 29. Trend analiza nominalnoga rasta neto plaće (Izvor: [53], autorova obrada)

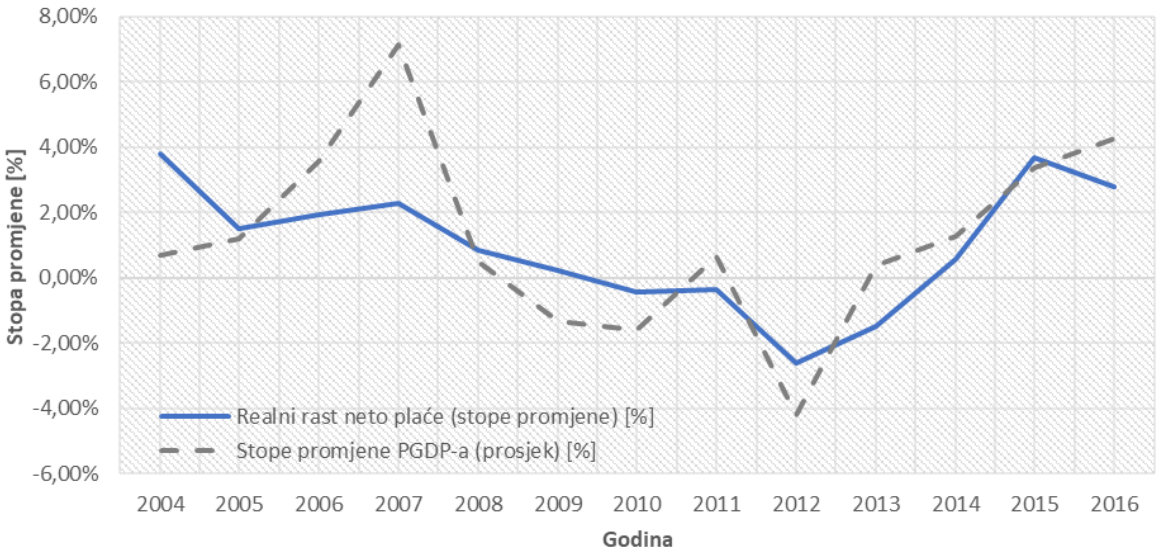

Grafikon 30. Trend analiza realnoga rasta neto plaće (Izvor: [53], autorova obrada)

2.2.6. Gorivo

Uzimajući u obzir da trošak goriva ima značajan udio u troškovima cestovnih putovanja, provedena je i analiza troška goriva. Analiza je provedena na temelju podataka Ministarstva zaštite okoliša i energetike [55] za sljedeće tipove goriva: Euro98, Euro95 i Eurodiesel. Na temelju podataka o troškovima pojedinoga tipa goriva na razini godine izračunati su godišnji prosjeci troška goriva kao i stope promjene godišnjih prosjeka troška goriva.

Grafičkom analizom predmetnih pokazatelja može se konstatirati da trošak goriva (prosječni) do 2009. godine u određenoj mjeri prati trendove stope promjene PGDP-a, što je vidljivo kroz stope promjene prosječnoga troška goriva. Nakon 2009. godine trend nije sličan. Također se može konstatirati da stope promjene prosječnoga troška goriva imaju pomak jednu godinu naprijed u odnosu na stope promjene PGDP-a (grafikoni 31 - 33). U analiziranome periodu prosječna cijena goriva iznosila je 8,68 kuna za litru, a prosječni je godišnji porast iznosio 3,33%.

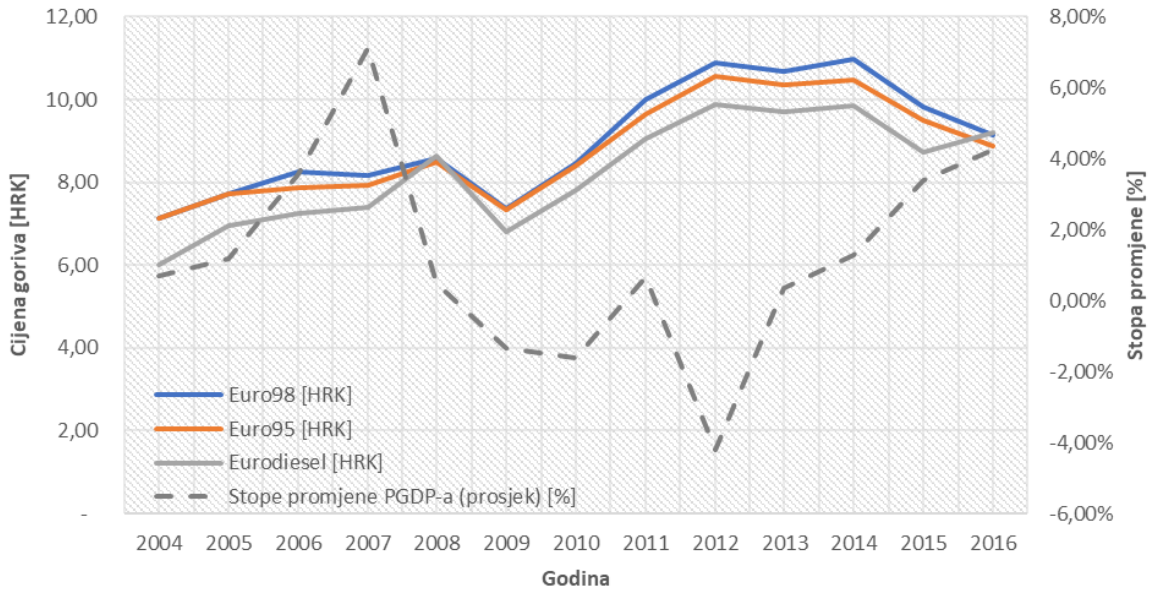

Grafikon 31. Trend analiza troška goriva (Izvor:[55], autorova obrada)

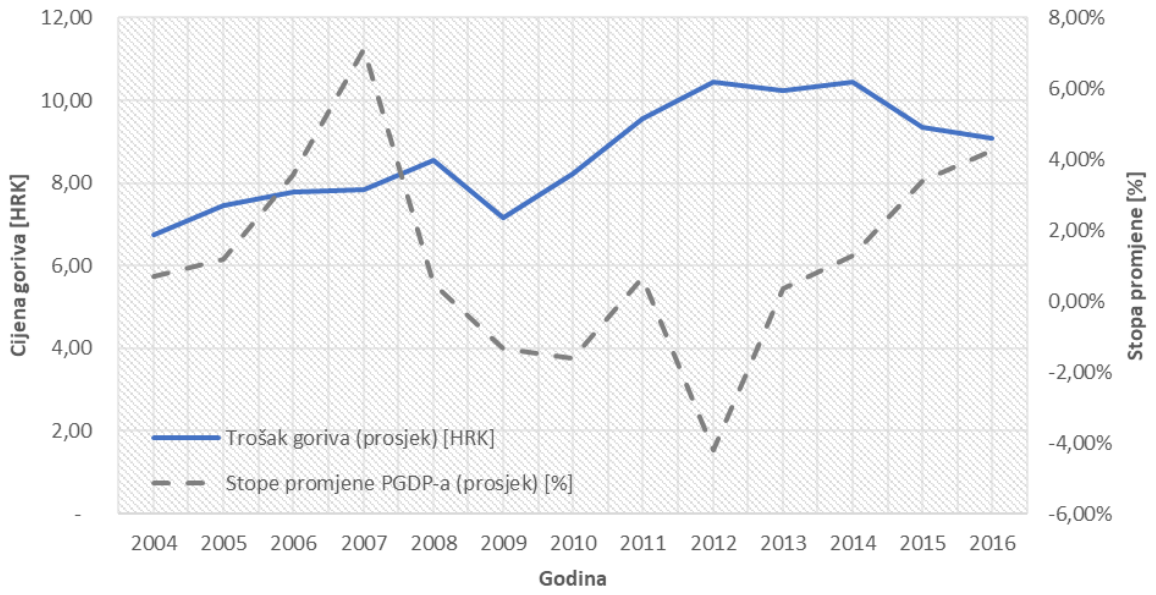

Grafikon 32. Trend analiza prosječnoga troška goriva (Izvor:[55], autorova obrada)

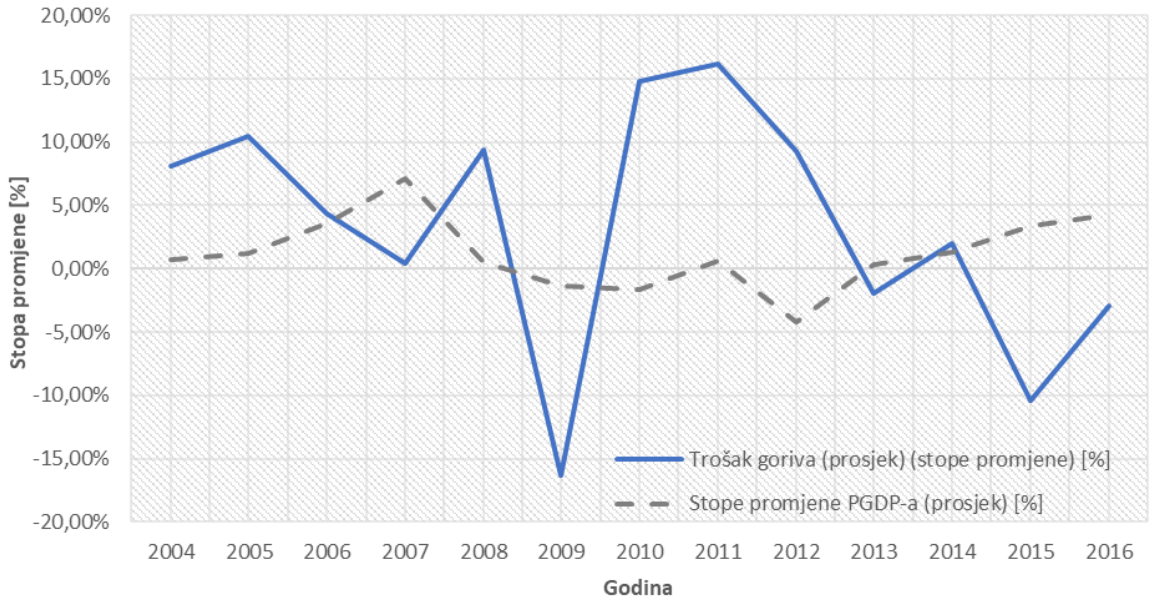

Grafikon 33. Trend analiza prosječnoga troška goriva, stope promjene (Izvor:[55], autorova obrada)

2.2.7. Zaposlenost

Budući da je odlazak na posao jedan od najčešćih razloga putovanja cestovnim prijevozom u Republici Hrvatskoj, provedena je i analiza zaposlenosti kroz analizu ukupno zaposlenih osoba te analizu stope registrirane nezaposlenosti. Stopa registrirane nezaposlenosti izračunava se kao omjer registrirane nezaposlenosti i ukupnoga aktivnog stanovništva [53].

Grafičkom analizom broja zaposlenih može se utvrditi rast do gospodarske krize 2009. godine nakon čega se bilježi pad do 2014. godine, a od onda rast, što nije u skladu s trendom stopa promjene PGDP-a (grafikon 34). Ukoliko se analizira stopa registrirane nezaposlenosti može se utvrditi obrnuta situacija, odnosno trend pada do gospodarske krize 2009. godine te rast do 2015. godine, nakon čega slijedi pad (grafikon 35). Prosječna stopa registrirane nezaposlenosti u analiziranome periodu iznosi gotovo 19% [53].

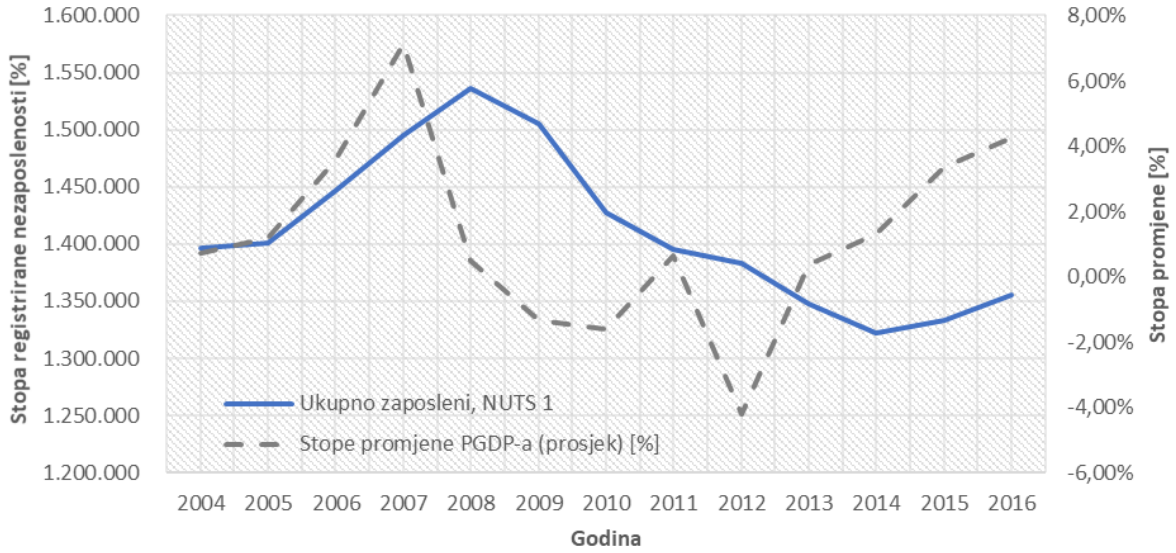

Grafikon 34. Trend analiza broja zaposlenih (Izvor: [53], autorova obrada)

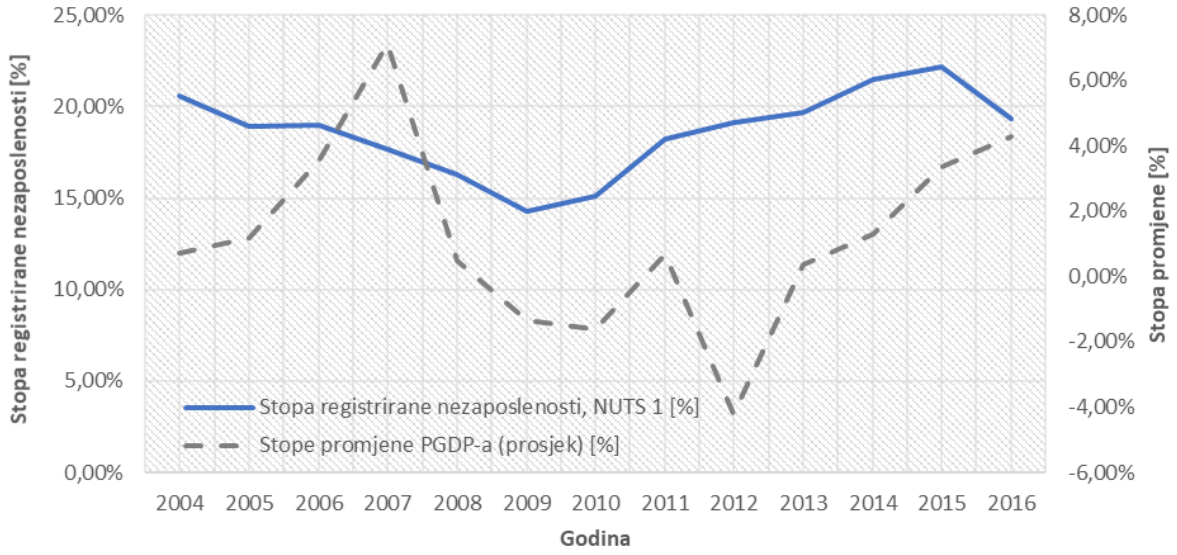

Grafikon 35. Trend analiza stope registrirane nezaposlenosti (Izvor: [53], autorova obrada)

Pregled ukupno zaposlenih te stope registrirane nezaposlenosti za statističke regije NUTS 3 nalazi se u prilogu 2.

2.2.8. Turizam

S obzirom na izraženu turističku aktivnost Republike Hrvatske te činjenicu da se većina putovanja obavlja osobnim vozilima, provedena je i analiza pokazatelja turističke aktivnosti. Analiza je provedena temeljem podataka o dolascima i noćenjima turista te njihovim stopama promjena.

Grafičkom analizom trenda stopa promjena broja dolazaka turista i stopa promjena PGDP-a može se konstatirati sličan trend, a napose kada su u pitanju stope promjene dolazaka domaćih turista (grafikon 36). Broj noćenja i dolazaka u manjoj mjeri prati stope promjene PGDP-a u odnosu na njihove stope promjena (grafikoni 37 - 39).

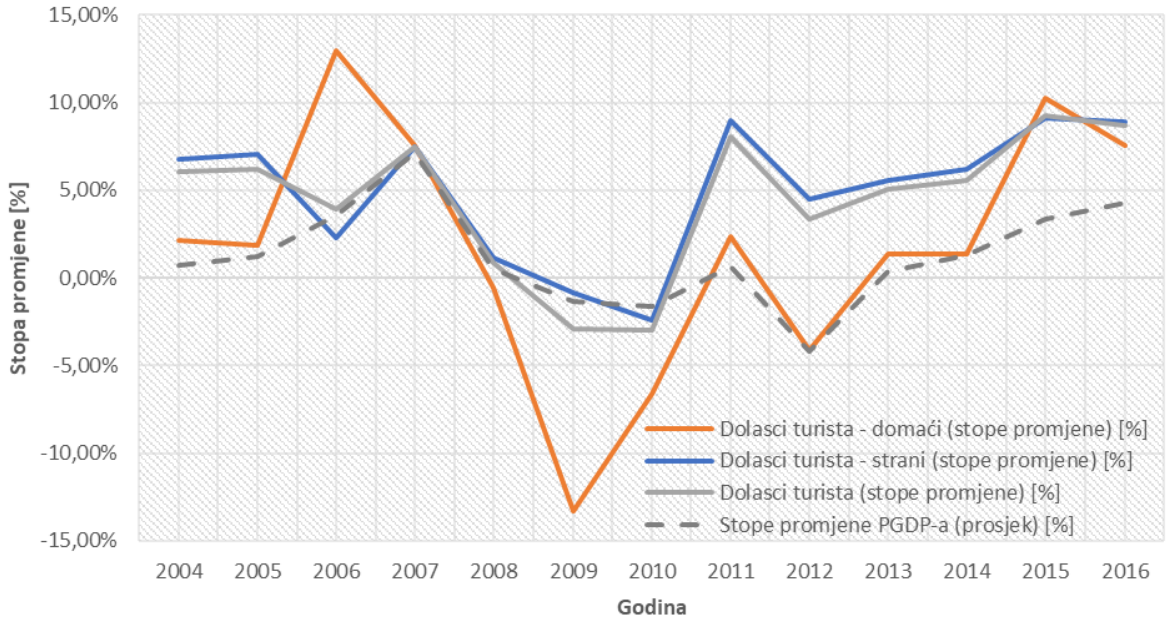

Grafikon 36. Trend analiza dolazaka turista, stope promjene (Izvor: [53], autorova obrada)

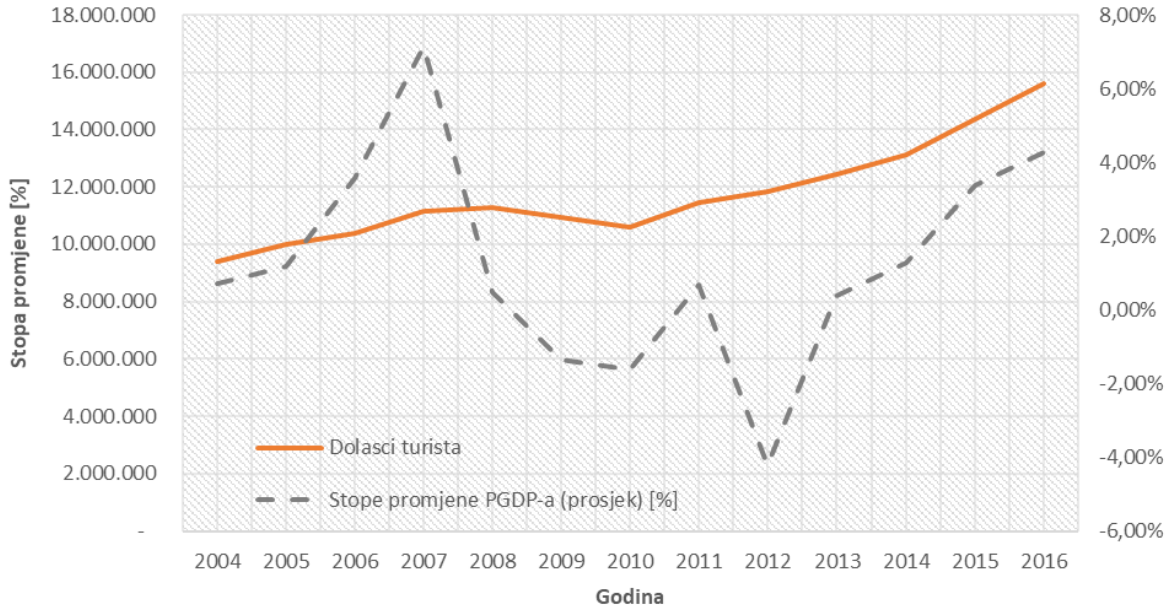

Grafikon 37. Trend analiza dolazaka turista (Izvor: [53], autorova obrada)

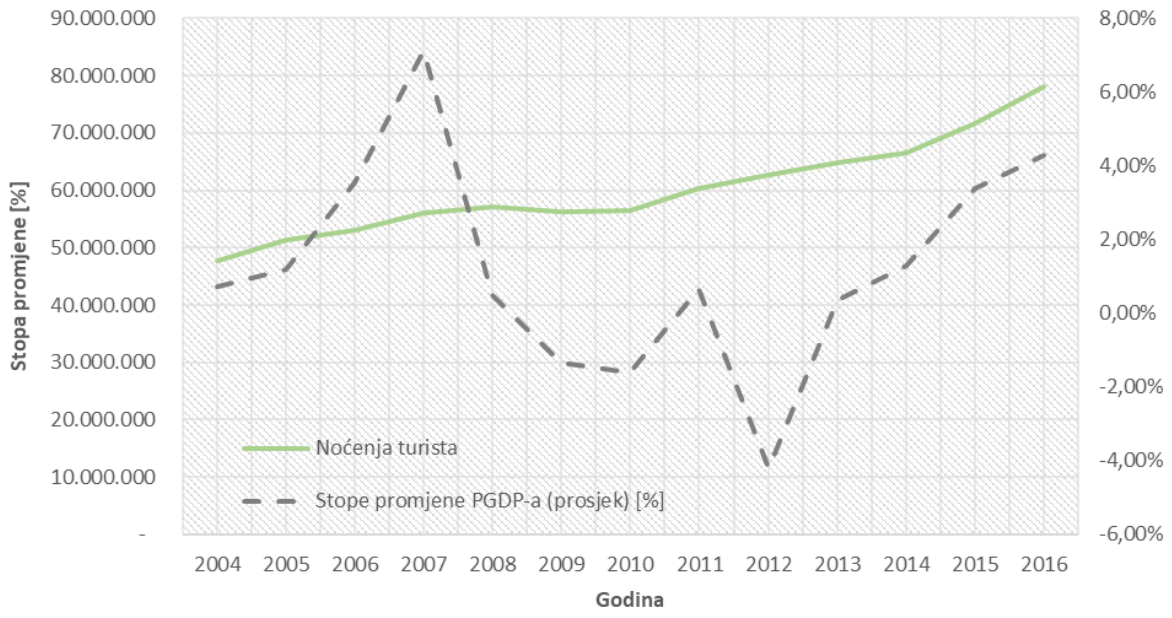

Grafikon 38. Trend analiza noćenja turista (Izvor: [53], autorova obrada)

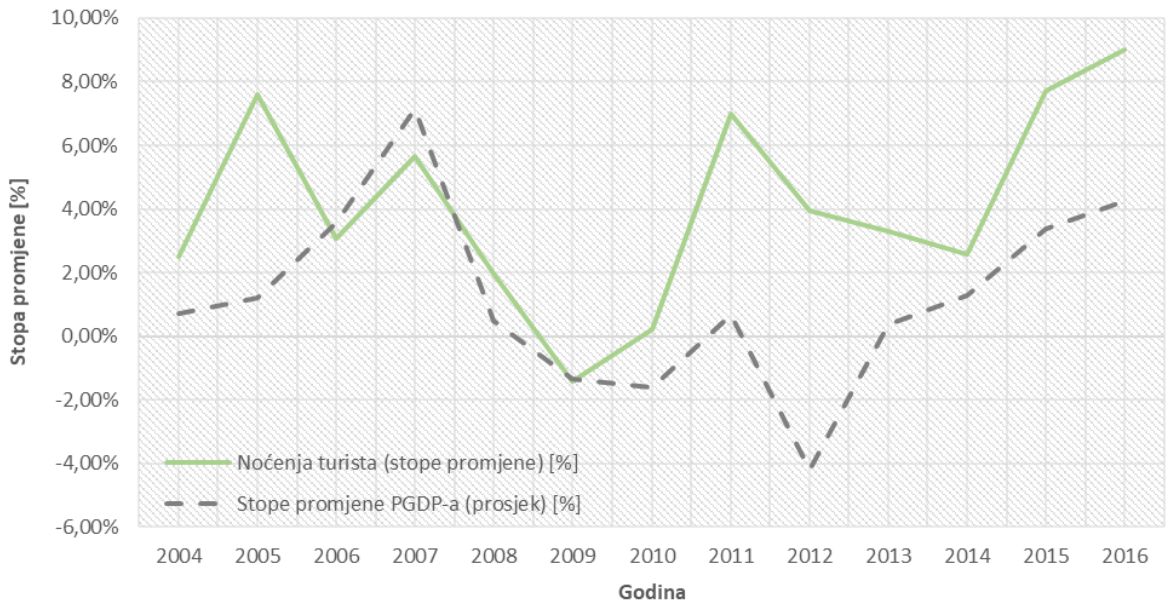

Grafikon 39. Trend analiza noćenja turista, stope promjene (Izvor: [53], autorova obrada)

Pregled broja dolazaka i noćenja te njihovih stopa promjena za statističke regije NUTS 3 nalazi se u prilogu 3.

2.3. Demografija

Za potrebe razvoja modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu, analizirana su četiri pokazatelja iz kategorije demografije. S ciljem lakše deskripcije i interpretacije, pokazatelji su prema svojim karakteristikama svrstani u sljedeće dvije grupe:

- populacija
- aktivno stanovništvo.

Populacija, kao i aktivno stanovništvo, procijenjeni su na temelju rezultata trenda analize podataka o populaciji i aktivnome stanovništvu Državnoga zavoda za statistiku iz 2001. i 2011. godine [53].

Detaljan je prikaz rezultata analize u nastavku poglavlja.

2.3.1. Populacija

Grafičkom analizom trenda populacije može se utvrditi konstantan pad populacije u analiziranome periodu, što nije u skladu s trendom stopa promjene PGDP-a (grafikon 40). Stope promjene populacije također ne bilježe trend sličan trendu stopa promjene PGDP-a (grafikon 41). Prema analiziranim podacima, stopa promjene populacije u prosjeku godišnje iznosi oko 0,39%.

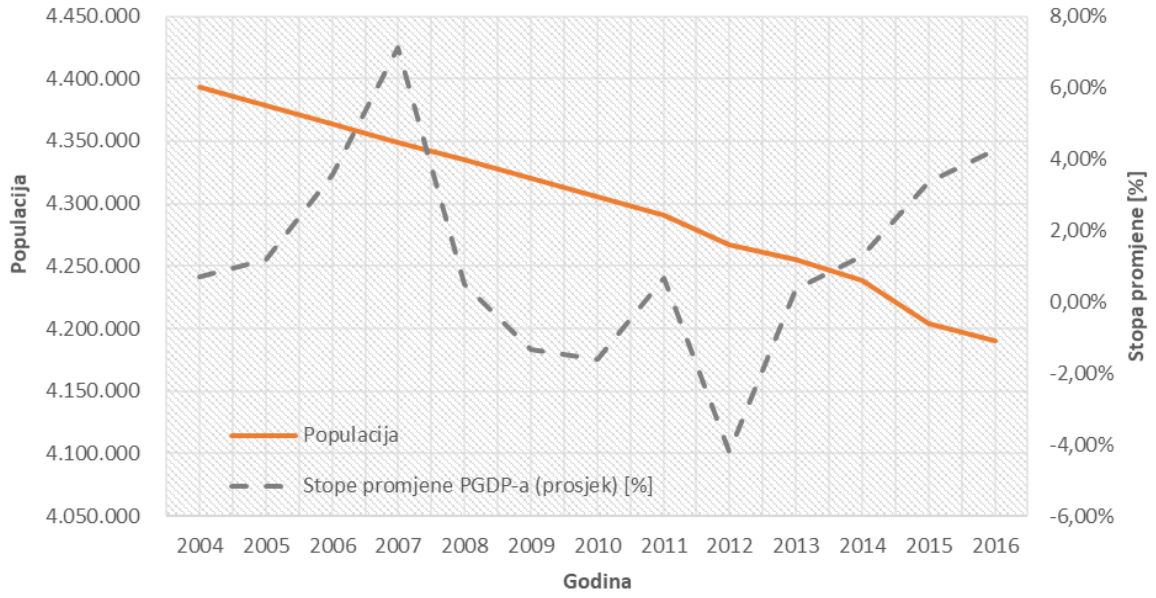

Grafikon 40. Trend analiza populacije (Izvor: [53], autorova obrada)

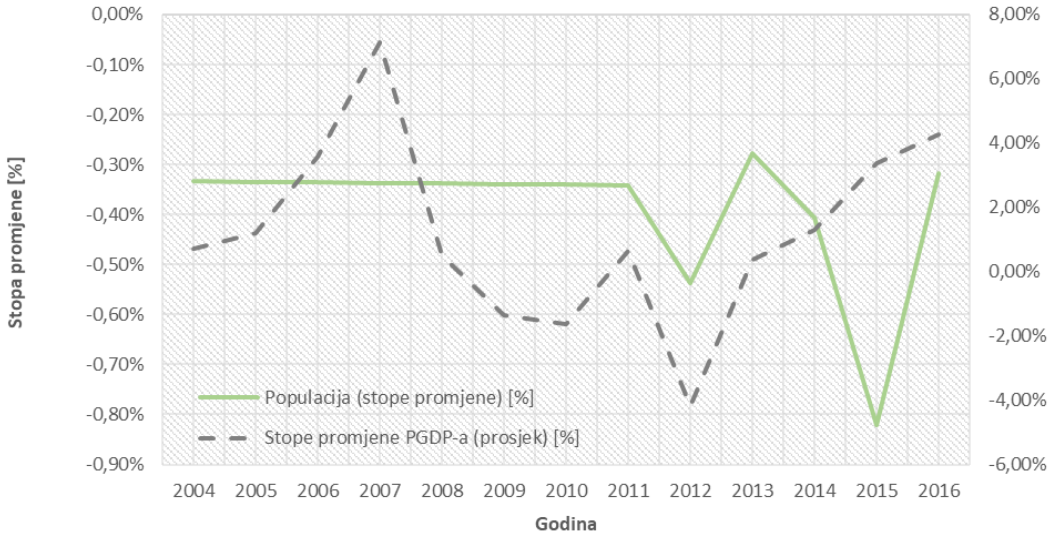

Grafikon 41. Trend analiza populacije, stope promjene (Izvor: [53], autorova obrada)

Pregled populacije te stope promjene populacije za statističke regije NUTS 3 nalazi se u prilogu 4.

2.3.2. Aktivno stanovništvo

Grafičkom analizom trenda aktivnoga stanovništva može se utvrditi gotovo konstantan pad populacije od 2009. godine, što nije u skladu s trendom stopa promjene PGDP-a (grafikon 42). Stope promjene aktivnoga stanovništva u određenoj mjeri prate stope promjene PGDP-a (grafikon 43). Prema analiziranim podacima stopa promjene aktivnoga stanovništava u prosjeku godišnje iznosi oko -0,14%.

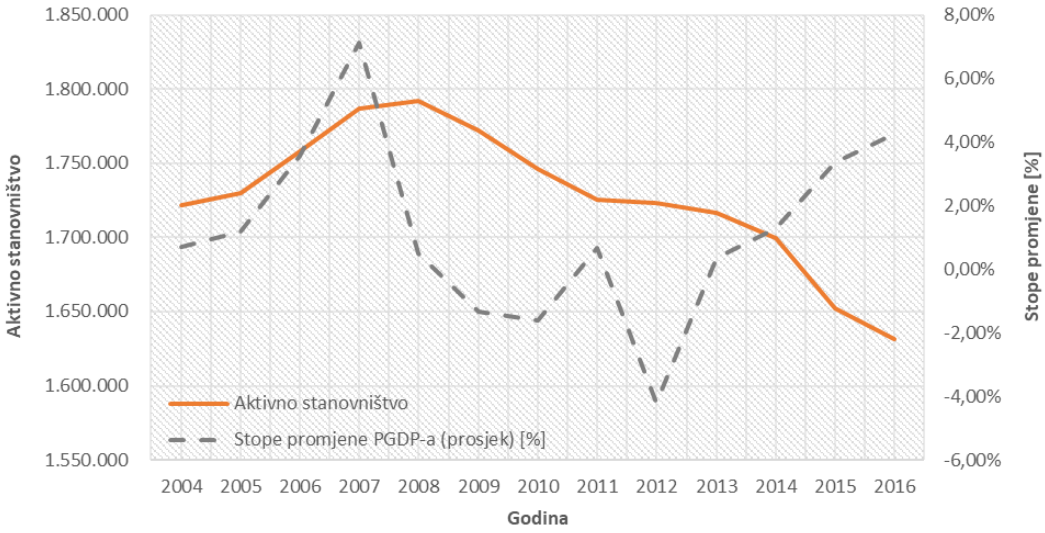

Grafikon 42. Trend analiza aktivnoga stanovništva (Izvor: [53], autorova obrada)

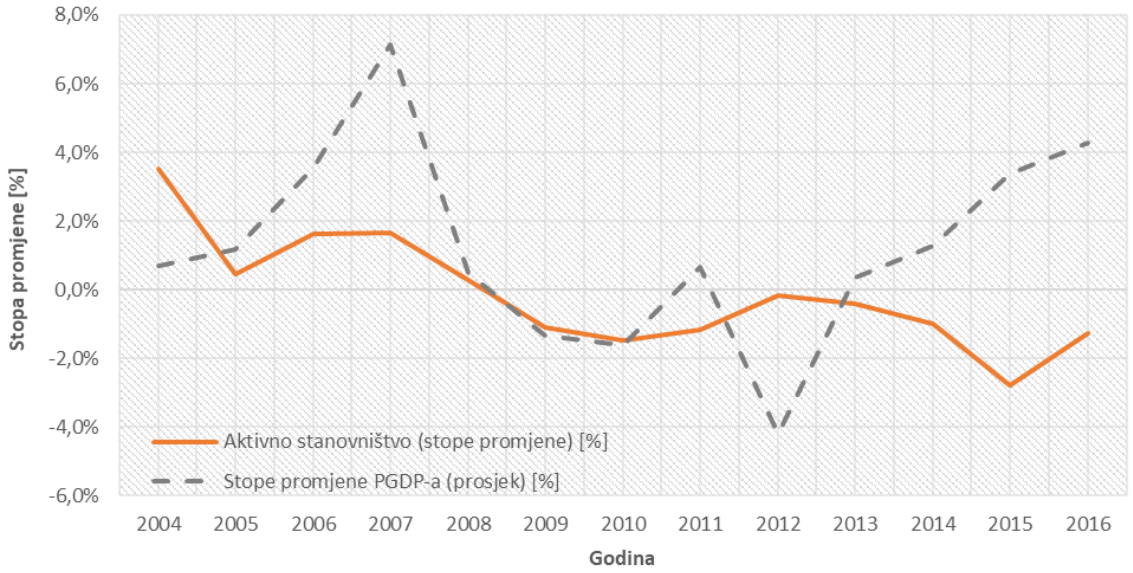

Grafikon 43. Trend analiza aktivnoga stanovništva, stope promjene (Izvor: [53], autorova obrada)

Pregled aktivnoga stanovništva za statističke regije NUTS 3 nalazi se u prilogu 5.

2.4. Utvrđivanje relevantnih pokazatelja

Kako su prethodno analizirani pokazatelji kvantitativni, kao i godišnja stopa promjene intenziteta cestovne prijevozne potražnje, s ciljem utvrđivanja relevantnih pokazatelja provedena je analiza korelacije. S obzirom na to da su utvrđene linearne veze zavisne i nezavisnih varijabli, za potrebe izračuna jačine i smjera veze korišten je Pearsonov koeficijent korelacije [51]. Statističke analize rađene su pomoću programskih alata *SPSS Statistics* i *SAS*.

Godišnja stopa promjene intenziteta cestovne prijevozne potražnje izračunata je kao prosječna vrijednost na razini godine, kategorije prometnice i sl., a u ovisnosti o potrebnoj analizi. Prije korištenja prosječnih vrijednosti ispitano je odstupanje prosječnih od medijalnih vrijednosti godišnjih stopa promjene intenziteta cestovne prijevozne potražnje. Analizom je utvrđeno da Pearsonov koeficijent korelacije između prosječnih i medijalnih vrijednosti godišnjih stopa promjene intenziteta cestovne prijevozne potražnje prema godinama za PGDP iznosi 98,89%, za PLDP 96,45%, a za PiDP 97,26%. Dobiveni rezultati potvrđuju da nema statistički značajne razlike između prosječnih i medijalni vrijednosti godišnjih stopa promjene intenziteta cestovne prijevozne potražnje. Shodno dobivenim rezultatima, u daljnjim analizama korelacije i izračunima potrebnima za izradu prognostičkih modela i modela vrednovanja

korištena je prosječna vrijednost godišnje stope promjene intenziteta cestovne prijevozne potražnje.

Za potrebe utvrđivanja jačine i smjera korelacije, kao zavisna varijabla korištena je prosječna godišnja stopa promjene intenziteta cestovne prijevozne potražnje po analiziranim godinama, a kao nezavisna potencijalno utjecajni gospodarski, demografski i prometni pokazatelji. Potencijalno utjecajni pokazatelji odabrani su na temelju rezultata prethodno provedene deskriptivne statistike i grafičke analize (v. poglavlja 2.1., 2.2. i 2.3.). Ispitivanjem veze između potencijalno utjecajnih gospodarskih, demografskih te prometnih pokazatelja i prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje, utvrđeno je sljedeće:

- kretanje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje po analiziranim godinama statistički se značajno razlikuje, što pokazuje mogućnost prognoziranja/predviđanja/vrednovanja kretanja intenziteta prijevozne potražnje *(postojanje varijabiliteta)*,
- kretanje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje PGDP-a, PLDP-a i PiDP-a u analiziranome se periodu statistički značajno ne razlikuje,
- kretanje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje po kategorijama prometnice statistički se značajno razlikuje *(kada je u pitanju PGDP i PiDP, utvrđena je statistički značajna razlika između autocesta te državnih i županijskih cesta, dok između državnih i županijskih cesta nije utvrđena statistička značajna razlika, a kada je u pitanju PLDP, utvrđena je statistički značajna razlika između svih kategorija prometnica),* dobiveni rezultati pokazuju da su autoceste u Republici Hrvatskoj u funkciji tranzitnoga i turističkoga prometa, odnosno ne odražavaju u potpunosti gospodarsko stanje u zemlji *(promjene intenziteta značajno su veće na autocestama)*,
- kretanje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje po prostornim jedinicama (NUTS 3, NUTS 2 i FR) potvrđuju razlike Jadranske i Kontinentalne Hrvatske, pri čemu se Središnja i Istočna Hrvatska također razlikuju *(važno je naglasiti da, ukoliko se sagledava PiDP, nije utvrđena statistički značajna razlika po prostornim jedinicama, što je općenito u skladu s gospodarskim i demografskim trendovima koji su na razini Republike Hrvatske slični, a ukoliko se izuzme turistička aktivnost jer se godišnja stopa promjene BDP-a statistički značajno ne razlikuje prema NUTS 3),*

- kretanje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje ima statistički značajnu i pozitivnu korelaciju s godišnjim stopama promjena BDP-a Republike Hrvatske kao i BDP-a EA12, ali ne i BDP-a na razini cijele Europske unije,
- kretanje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje ima statistički značajnu i pozitivnu korelaciju s godišnjim stopama promjene obujma industrijske proizvodnje, što je u skladu s rezultatima statističke značajne korelacije s BDP-om,
- analizom korelacije prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje i indeksa potrošačkih cijena nije utvrđena statistički značajna korelacija, ali je smjer korelacije negativan kada su u pitanju godišnje stope promjene indeksa potrošačkih cijena,
- kada su u pitanju plaće, utvrđena je statistički značajna korelacija godišnjih stopa promjene realnoga rasta neto plaće i prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje, što pokazuje značajan utjecaj kupovne moći na stupanj motorizacije, kao i intenzitet korištenja osobnih automobila,
- sukladno prethodnoj argumentaciji, kretanje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje ima statistički značajnu korelaciju s godišnjom stopom promjene broja registriranih cestovnih motornih i osobnih vozila (stupanj motorizacije), a predmetna veza ujedno bilježi i najveću vrijednost Pearsonovoga koeficijenta korelacije u odnosu na sve analizirane pokazatelje (81%),
- stopa registrirane nezaposlenosti nije zabilježila statistički značajnu korelaciju s prosječnim godišnjim stopama promjene intenziteta cestovne prijevozne potražnje,
- cijena goriva, kao i njene stope promjene, u očekivanoj su negativnoj korelaciji s prosječnim godišnjim stopama promjene intenziteta cestovne prijevozne potražnje koja se nije pokazala kao statistički značajna,
- godišnje stope promjene dolazaka turista (posebice domaćih) imaju statističku značajnu korelaciju s prosječnim godišnjim stopama promjene intenziteta cestovne prijevozne potražnje, kao i godišnje stope promjene noćenja domaćih turista *(predmetno potvrđuje i činjenica da su dolasci i noćenja domaćih turista u korelaciji s BDP-om države)*,
- populacija je zabilježila negativnu korelaciju s prosječnim godišnjim stopama promjene intenziteta cestovne prijevozne potražnje koja se nije pokazala kao statistički značajna

(predmetno je očekivano s obzirom na konstantan trend pada populacije u Republici Hrvatskoj u analiziranome periodu, što nije slučaj s intenzitetom cestovne prijevozne potražnje),

- cestovni prijevoz robe (godišnje stope promjene prevezenoga tereta) ima statistički značajnu korelaciju s prosječnim godišnjim stopama promjene intenziteta cestovne prijevozne potražnje,
- željeznički prijevoz robe bilježi negativnu korelaciju koja nije statistički značajna, što se može smatrati kao posljedica nerazvijenoga željezničkog sustava *(značajno manja količina prevezene robe u odnosu na cestu).*

Prikaz rezultata Pearsonovoga koeficijenta korelacije i statističke značajnosti nalazi se u tablici 2, a rezultati su ispitivanja razlike sredine prikazani u poglavlju 2.3. *Promet*. Rasipanje korelacijske matrice za statistički značajne koeficijente korelacije prema tablici 2 prikazani su grafikonom 44. Korišteni je interval pouzdanosti 0,95. Crveno označene vrijednosti u tablici imaju statističku značajnost <0,01, dok narančasto označene vrijednosti imaju statističku značajnost 0,01 – 0,05.

Tablica 2. Analiza koeficijenata korelacije relevantnih pokazatelja

Pokazatelj	**Opis**	**Prosječna godišnja stopa promjene (N=13)**		
		PGDP	**PLDP**	**PiDP**
BDP (tržišne cijene, realne stope rasta)	Pearsonov koeficijent	0,729008	0,5247	0,670476
	Razina značajnosti	0,0047	0,0656	0,0121
BDP EU (stope promjene)	Pearsonov koeficijent	0,446807	0,278182	0,413533
	Razina značajnosti	0,1259	0,3574	0,1601
BDP EA12 (stope promjene)	Pearsonov koeficijent	0,660675	0,443652	0,621279
	Razina značajnosti	0,0140	0,1289	0,0234
Obujam industrijske proizvodnje (stope promjene)	Pearsonov koeficijent	0,792024	0,617611	0,701953
	Razina značajnosti	<0,0012	0,0245	0,0075
Indeks potrošačkih cijena (stope promjene)	Pearsonov koeficijent	-0,2461	-0,46805	-0,19123
	Razina značajnosti	0,4176	0,1067	0,5314
Indeks potrošačkih cijena bez energije i hrane (stope promjene)	Pearsonov koeficijent	0,190301	0,108887	0,248496
	Razina značajnosti	0,5335	0,7233	0,4130
Nominalni rast neto plaće (stope promjene)	Pearsonov koeficijent	0,405701	0,304653	0,395496

Pokazatelj	Opis	Prosječna godišnja stopa promjene (N=13)		
		PGDP	PLDP	PiDP
	Razina značajnosti	0,1690	0,3115	0,1810
Realni rast neto plaće (stope promjene)	Pearsonov koeficijent	0,716118	0,818189	0,649988
	Razina značajnosti	0,0059	0,0006	0,0162
Cijena goriva (prosječna cijena)	Pearsonov koeficijent	-0,21616	-0,32144	-0,18773
	Razina značajnosti	0,4781	0,2842	0,5391
Cijena goriva (stope promjene)	Pearsonov koeficijent	-0,26346	-0,51486	-0,25882
	Razina značajnosti	0,3845	0,0718	0,3932
Stopa registrirane nezaposlenosti	Pearsonov koeficijent	0,297837	0,279153	0,266816
	Razina značajnosti	0,3230	0,3557	0,3782
Dolasci turista (stope promjene)	Pearsonov koeficijent	0,612594	0,38134	0,590552
	Razina značajnosti	0,0260	0,1986	0,0336
Dolasci turista (domaći, stope promjene)	Pearsonov koeficijent	0,781783	0,661828	0,743382
	Razina značajnosti	0,00016	0,0137	0,0036
Dolasci turista (strani, stope promjene)	Pearsonov koeficijent	0,507623	0,266399	0,491549
	Razina značajnosti	0,0766	0,3790	0,0880
Noćenja turista (stope promjene)	Pearsonov koeficijent	0,524886	0,37686	0,449845
	Razina značajnosti	0,0655	0,2043	0,1230
Noćenja turista (domaći, stope promjene)	Pearsonov koeficijent	0,803133	0,67616	0,758028
	Razina značajnosti	0,0009	0,0112	0,0027
Noćenja turista (strani, stope promjene)	Pearsonov koeficijent	0,406913	0,274315	0,330478
	Razina značajnosti	0,1676	0,3644	0,2701
Populacija (ukupno)	Pearsonov koeficijent	-0,01209	-0,16602	0,016728
	Razina značajnosti	0,9687	0,5878	0,9567
Populacija (stope promjene)	Pearsonov koeficijent	0	-0,25277	0,043634
	Razina značajnosti	1,0000	0,4047	0,8874
Aktivno stanovništvo (stope promjene)	Pearsonov koeficijent	0,180969	-0,07522	0,249195
	Razina značajnosti	0,5541	0,8071	0,4116
Broj registriranih cestovnih motornih vozila (stope promjene)	Pearsonov koeficijent	0,787546	0,636169	0,727551
	Razina značajnosti	0,0014	0,0194	0,0048
Broj registriranih osobnih vozila (stope promjene)	Pearsonov koeficijent	0,811358	0,689157	0,745597
	Razina značajnosti	0,0008	0,0092	0,0034

Pokazatelj	Opis	Prosječna godišnja stopa promjene (N=13)		
		PGDP	PLDP	PiDP
Cestovni prijevoz robe (stope promjene)	Pearsonov koeficijent	0,740768	0,512293	0,69087
	Razina značajnosti	0,0038	0,0735	0,0089
Željeznički prijevoz robe (stope promjene)	Pearsonov koeficijent	-0,14779	-0,0891	-0,21274
	Razina značajnosti	0,6299	0,7722	0,4853

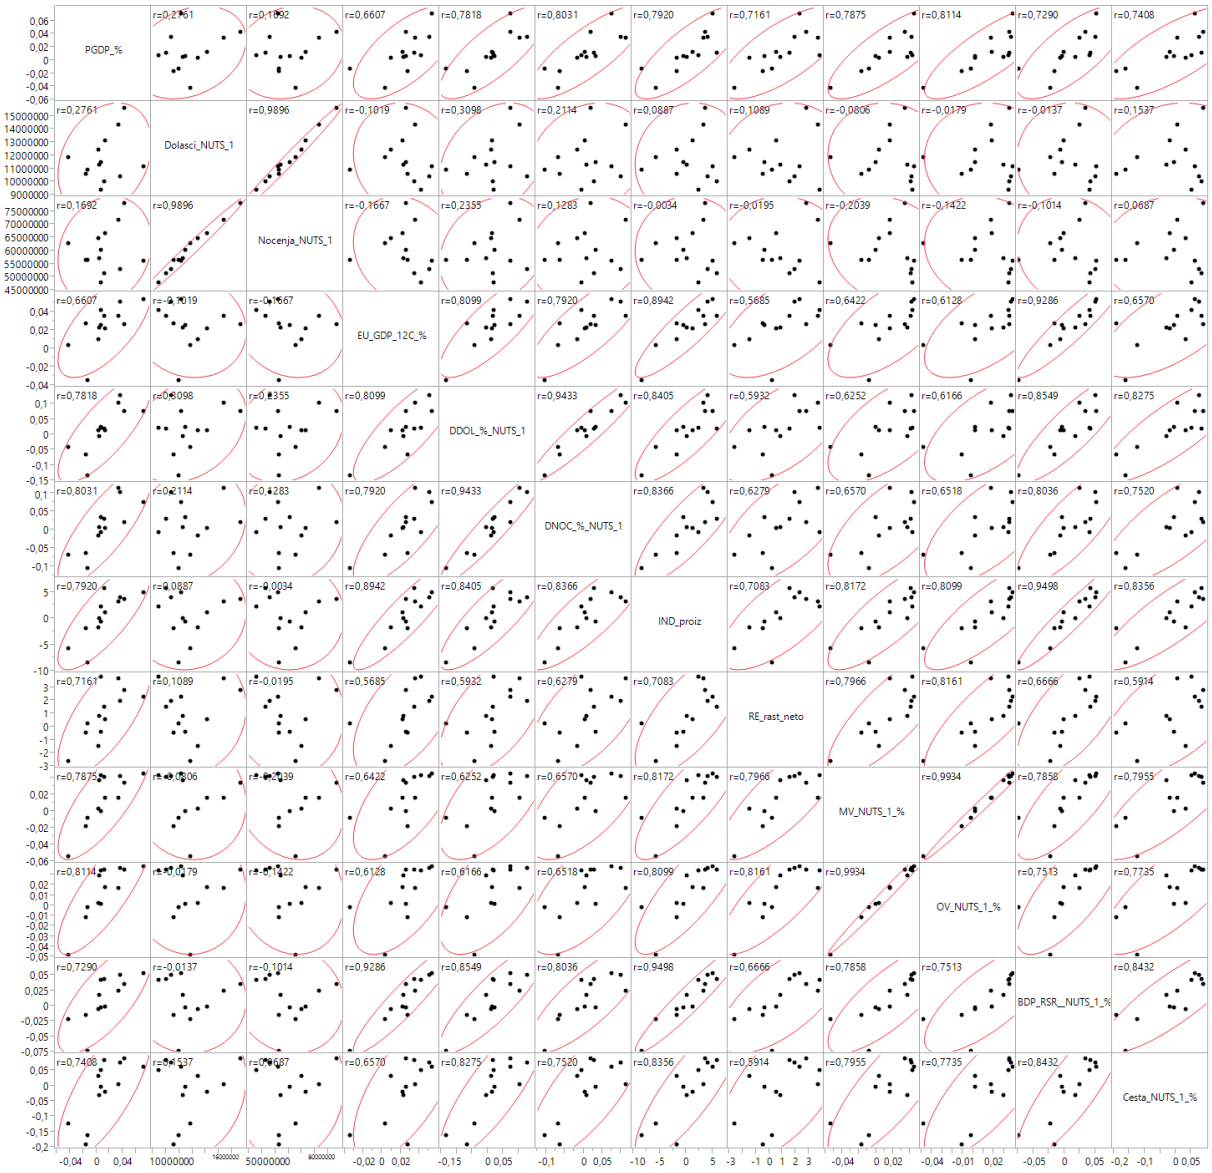

Grafikon 44. Rasipanja korelacijske matrice (PGDP)

3. MODEL PROGNOZIRANJA PRIJEVOZNE POTRAŽNJE U CESTOVNOME PROMETU

Sve veća potreba za mobilnošću ljudi i dobara, kao i sve brži razvoj prometa općenito, imali su za posljedicu da je njegova učinkovitost postala jedan od osnovnih pokazatelja svakoga uspješnog gospodarstva. Naime, prema istraživanjima, [56] udio eksternih troškova prometa (bez troškova zagušenja) za EU-27 (uključujući Norvešku i Švicarsku, a isključujući Maltu i Cipar) za 2008. godinu iznosi 514 milijardi eura, što čini 4% ukupnoga BDP-a. Pri tome ukupni troškovi zagušenja iznose između 146 i 243 milijuna eura, odnosno oko 1,1-1,8% BDP-a. Važno je napomenuti da cestovni promet čini 93% udjela u ukupnim eksternim troškovima cjelokupnoga prometa. Shodno tome, pravilan gospodarski razvoj podrazumijeva i pravilnu prometnu politiku proizašlu iz pravilnoga prometnog planiranja.

Proces prometnoga planiranja se može podijeliti u tri osnovna koraka:

- dijagnoza
- prognoza i
- terapija [57].

Dijagnoza prikazuje rezultate provedenih analiza i detektira glavne postojeće/potencijalne probleme. Prognozom se dobiva uvid u buduće stanje prometnoga sustava te se tek nakon prognoze pristupa rješavanju (terapija) utvrđenih/postavljenih problema.

S obzirom na to da se infrastrukturni projekti cestovnoga prometnog sustava planiraju za razdoblja od 25 do 30 godina [58], nužna je i izrada prometnih prognoza za takva razdoblja. Izrada takvih dugoročnih prognoza predstavlja kompleksan proces čiji su rezultati vrlo važni jer u velikoj mjeri utječu na dugoročan razvoj i uspostavljanje učinkovitoga i održivoga prometnog sustava.

Shodno navedenome te u skladu sa zaključcima analize dosadašnjih istraživanja i spoznaja proizašlih iz istraživanja provedenih u sklopu ovoga rada, utvrđeno je da prosječne godišnje stope promjene intenziteta cestovne prijevozne potražnje ovise o gospodarskim, demografskim i prometnim pokazateljima. Na temelju utvrđenih relevantnih pokazatelja i njihovih veza s promjenom intenziteta prijevozne potražnje, pristupilo se izradi modela za prognoziranje prijevozne potražnje u cestovnome prometu koji predstavlja podlogu za izradu modela vrednovanja prognoza prijevozne potražnje.

3.1. Odabir prognostičkoga modela i metodologija izrade

Prognostički modeli uglavnom se rade na osnovu spoznaja iz protekloga vremena (kvalitativnih i kvantitativnih) te se, shodno tome, prognostičke metode u osnovi dijele na:

- kvalitativne i
- kvantitativne.

Kvalitativne metode baziraju se na tumačenju subjektivnih pojava i uvelike ovise o samome planeru te njegovome iskustvu i shvaćanju [59]. Za razliku od kvalitativnih, kvantitativne metode zasnivaju se na matematičkim analizama s ciljem utvrđivanja veza i sl.

S obzirom na složenost procesa prognoziranja prijevozne potražnje kao posljedice brojnih uzročnih čimbenika te s ciljem izbjegavanja pristranosti planera koja se pokazala kao čest problem u prometnome planiranju [27], [28] za potrebe ovoga rada odabrano je korištenje kvantitativne metode prognoziranja. Naime, do optimistične pristranosti nerijetko dolazi upravo zbog pogleda iznutra (engl. *inside view*) s obzirom na to da su planeri tijekom prognoziranja uglavnom usredotočeni na planirane mjere, a ne ishode već izvedenih sličnih mjera. Kvantitativne metode prognoziranja dijele se na:

- vremenske serije i projekcije te
- uzročne modele [60].

Vremenske serije i projekcije zasnivaju se na obrascima i promjenama uzoraka povijesnih podataka, a uzročni se modeli zasnivaju na utvrđenim odnosima između analiziranih elementa sustava [60]. Kao i kod vremenskih serija, i kod uzročnih modela koriste se povijesni podaci za utvrđivanje odnosa između analiziranih elemenata, a jedna je od glavnih prednosti što omogućavaju uzročno-posljedičnu analizu[4]. Uzročni modeli također su povoljniji za srednjoročne i dugoročne prognoze u odnosu na vremenske serije.

Budući da se vremenske serije uglavnom koriste za kratkoročna prognoziranja te zato što nisu pogodne za prognoziranje naglih promjena trendova, za potrebe ovoga rada odabrano je korištenje uzročnih modela. Uzročni modeli pogodniji su za ispitivanje različitih scenarija, što je vrlo bitno u složenim procesima poput prognoziranja prijevozne potražnje jer uzročni čimbenici mogu brzo mijenjati svoj trend (npr. gospodarska kriza uzrokovana pandemijom

[4] Takozvana *što ako analiza*.

virusa COVID-19). Također, ekonomska isplativost i financijska održivost prometnih infrastrukturnih projekata analizira se za razdoblje od 25 do 30 godina te je, shodno tome, potrebno imati i dugoročne prognoze čiji rezultati neće imati za posljedicu neuspješnost projekta.

Sukladno navedenim prednostima zbog kojih je odabrano korištenje kvantitativnih uzročnih modela, pristupilo se odabiru modela za izradu prognoza prijevozne potražnje u cestovnome prometu, a u konačnici i izrade modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu. Tijekom odabira statističkoga modela potrebno je obratiti pažnju na uzorak, karakteristike zavisne i nezavisnih varijabli (tip i distribucija), odnos između zavisne i nezavisnih varijabli, kao i odnos između nezavisnih varijabli (jakost i smjer) te samu svrhu planiranoga modela. Analizom navedenih pokazatelja utvrđeno je da je planirani uzorak za izradu modela 26, zavisne su i nezavisne varijable kvantitativne te su normalno distribuirane, odnos je između zavisne i nezavisnih varijabli linearan te statistički značajan, a svrha je modela vrednovanje prognoza prijevozne potražnje u cestovnome prometu temeljeno na vjerojatnosti pojavljivanja određena scenarija. Utvrđivanje odnosa između zavisne i nezavisnih varijabli prikazano je u poglavlju 2., rezultati su analize distribucija prikazani u poglavlju 4.

Poštujući polazne pretpostavke za odabir statističkoga modela, analizu dosadašnjih istraživanja, postavljene hipoteze i cilj rada te uzimajući u obzir da su zavisne i nezavisne varijable kvantitativne (kontinuirane), za izradu je modela odabrana višestruka linearna regresija. Višestruka linearna regresija u skladu je s ciljem rada jer omogućava izvođenje *što ako* analize važne kod kreiranja scenarija, a samim time i zaključaka modela vrednovanja.

Polazne su pretpostavke kod modela višestruke linearne regresije:

- veza zavisne varijable i skupa nezavisnih varijabli je linearna;
- ne postoji jaka veza između nezavisnih varijabli;
- greške (*Residuals*) su međusobno nezavisne;
- greške su distribuirane po normalnoj razdiobi;
- greške imaju očekivanu vrijednost nula i iste varijance ($Var(e_i)=\sigma^2$).

Izrada modela prognoze prijevozne potražnje provedena je kroz četiri faze, a na temelju javno dostupnih statističkih podatka o gospodarskim, demografskim i prometnim pokazateljima. Sadržaji pojedinih faza su sljedeći:

- u prvoj fazi provedeno je prikupljanje podataka,
- u drugoj su se fazi podaci interpretirali,

- u trećoj fazi provedeno je utvrđivanje postojanja veze te njezinoga smjera i jakosti između analiziranih pokazatelja,
- u četvrtoj je fazi, na temelju spoznaja proizašlih u drugoj i trećoj fazi, izrađen prognostički model.

S obzirom na postignuta saznanja o razlici godišnjih stopa promjene intenziteta cestovne prijevozne potražnje za PGDP. PLDP i PiDP, prognostički model, kao i model vrednovanja, rađen je samo za PGDP.

Shematski prikaz procesa izrade prognostičkoga modela nalazi se na slici 1.

Slika 1. Proces izrade prognostičkoga modela

Model je razvijen na temelju 26 prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje dobivenih iz razdoblja od 2003. do 2016. godine te vrijednosti nezavisnih varijabli za predmetno razdoblje. Pri tome se 13 prosječnih vrijednosti odnosi na autoceste te 13 na državne ceste. S obzirom na to da između državnih i županijskih cesta nije utvrđena statistički značajna razlika, a s ciljem objektivnijih rezultata, podaci prikupljeni sa županijskih cesta nisu uzeti u obzir tijekom izrade modela. Prikaz korištenih ulaznih podataka nalazi se u prilogu 7.

Zavisna varijabla u modelu predstavlja prosječnu godišnju stopu promjene intenziteta cestovne prijevozne potražnje (PGDP), dok su kao nezavisne (prediktorske) varijable korišteni utvrđeni relevantni gospodarski, demografski i prometni pokazatelji (v. 2.4. *Utvrđivanje relevantnih pokazatelja*).

3.2. Model prognoze prijevozne potražnje u cestovnome prometu

Za izradu prognostičkoga modela prijevozne potražnje u cestovnome prometu temeljenoga na višestrukoj linearnoj regresiji korištena je *stepwise* procedura [51]. Prema predmetnoj proceduri u model prvo ulazi varijabla koja najviše doprinosi kvaliteti modela dok se u svakomu sljedećem koraku uključuje samo ona varijabla koja dodatno pridonosi kvaliteti (značajnosti) modela. Predmetni postupak ponavlja se dok god u bazi postoji varijabla koja pridonosi kvaliteti (značajnosti) modela. Važno je napomenuti da je uz *stepwise* proceduru korištena i procedura *potpunoga regresijskog modela*[5] s ciljem kvalitetnijega odabira i interpretacije odabranih varijabli. Korištena je razina značajnosti 0,05 (5%).

Tijekom procesa utvrđivanja relevantnih pokazatelja (tablica 2, grafikon 44), kao i izrade modela prema prethodno opisanoj proceduri, utvrđeni su sljedeći statistički značajni parametri za izradu modela:

- realne stope rasta bruto domaćega proizvoda (godišnje promjene, %),
- realni rast neto plaća (godišnje promjene, %)
- dolasci turista (godišnje promjene, %)

[5] Kod procedure *potpunoga regresijskog modela* (još se naziva i *enter* procedurom) sve odabrane varijable ulaze i ostaju u modelu bez obzira na to doprinose li kvaliteti (značajnosti) modela u cijelosti ili ne. Na taj način može se lakše interpretirati važnost (značajnost) pojedine analizirane varijable.

- broj registriranih cestovnih motornih vozila (godišnje promjene, %) te
- kategorija prometnice (autocesta, državna cesta).

S obzirom na to da je utvrđena statistički značajna razlika prosječnih godišnjih stopa promjene PGPD-a prema kategoriji prometnice, za potrebe modela korištena je kategorija prometnice kao kategorijska varijabla. Pri tome vrijednost nula označava autocestu, a vrijednost jedan označava državnu cestu.

Kao što je u sklopu ovoga rada utvrđeno, između prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) i godišnjih stopa promjene broja registriranih cestovnih motornih vozila zabilježena je najveća vrijednost koeficijenta korelacije u iznosu od 88%. Nakon toga najveća korelacija zabilježena je s realnim rastom neto plaće i realnim rastom BDP-a (82%), dok su na posljednjemu mjestu dolasci turista (godišnje stope promjene) s korelacijom od 64%. Sve korelacije imaju pozitivnu vezu sa zavisnom varijablom. Prikaz dobivenih rezultata korelacije i pripadajuće statističke značajnosti nalazi se u tablici 3.

Tablica 3. Korelacijska matrica

Pokazatelj		Koeficijent korelacije (Pearson)	Razina značajnosti
BDP_RSR_%	PGDP_%	0,8233	0,0005*
Dolasci_%_NUTS_1	PGDP_%	0,6402	0,0184*
Dolasci_%_NUTS_1	BDP_RSR_%	0,6495	0,0163*
Realni_rast_neto_place	PGDP_%	0,8239	0,0005*
Realni_rast_neto_place	BDP_RSR_%	0,6666	0,0128*
Realni_rast_neto_place	Dolasci_%_NUTS_1	0,4624	0,1116
MV_NUTS_1_%	PGDP_%	0,8800	<,0001*
MV_NUTS_1_%	BDP_RSR_%	0,7858	0,0015*
MV_NUTS_1_%	Dolasci_%_NUTS_1	0,4216	0,1514
MV_NUTS_1_%	Realni_rast_neto_place	0,7966	0,0011*

Iz korelacijske matrice prikazane u tablici 3 također je razvidno da, osim između zavisnih i nezavisnih varijabli, i gotovo sve nezavisne varijable imaju međusobno jaku linearnu vezu. Jaka veza nije zabilježena između dolazaka turista (godišnje stope promjene) i realnoga rasta neto plaće te broja registriranih motornih vozila (godišnje stope promjene). Predmetno je

očekivano jer svi analizirani pokazatelji u većoj mjeri odražavaju gospodarsko stanje te je očekivana i postojanost jake veze.

Shodno navedenome, tijekom izrade modela, a s ciljem povećanja točnosti i izbjegavanja problema multikolinearnosti, nisu zajedno korištene one nezavisne varijable koje imaju statistički značajnu vezu te su izrađena tri prognostička modela. Modeli su definirani prema korištenim nezavisnim varijablama, a cilj im je olakšati upotrebu kao i povećati njegovu točnost i razumijevanje rezultata. Shodno tome, tijekom upotrebe modela, a u slučaju nedostatka određenih ulaznih podataka, može se odabrati onaj model za koji u danome trenutku postoje ulazni podaci. Primjerice, podaci poput realnoga rasta BDP-a općenito se češće koriste te prognoziraju u odnosu na realni rast neto plaća i broj registriranih cestovnih motornih vozila. Na ovaj način također se kroz utvrđenu međusobnu vezu između nezavisnih varijabli može predvidjeti i vrijednost nezavisne varijable za koju se nema informacija. Osim toga, uzročni modeli valjani su dok veze između zavisne i nezavisnih varijabli ostanu nepromijenjene.

Prednost izrade i korištenja sva tri modela proizlazi i iz činjenice da je znatno teže utjecati na vezu između realnoga rasta neto plaće i kretanja prijevozne potražnje nego na broj registriranih motornih vozila i kretanje prijevozne potražnje (npr. prometnom politikom razvoja održivih oblika prometovanja ili stimulacije kupovine osobnih vozila može se utjecati na porast ili smanjenje broja vozila, što ne odražava trend razvoja gospodarstva već je samo posljedica mjere prometne politike koju provodi neka država, jedinica lokalne samouprave i sl.). Opis pojedinoga modela nalazi se u tablici 4.

Tablica 4. Prognostički modeli

Model	Nezavisne varijable	Procedura
V1	Broj registriranih motornih vozila (godišnje stope promjene), broj dolazak turista (godišnje stope promjene) i kategorija prometnice (AC ili DC)	*stepwise*
V2	realni rast neto plaća i kategorija prometnice (AC ili DC)	*stepwise*
V3	realni stope rasta bruto domaćega proizvoda i kategorija prometnice (AC ili DC)	*stepwise*

Analizom dobivenih rezultata prognostičkog modela V1 dobiven je statistički značajan model ($p<0,000$, F vrijednost 22,377). Vrijednost R^2 dodavanjem svake nove nezavisne varijable raste do 0,753 dok je korigirani R^2 neznačajno manji i iznosi 0,720. Sve nezavisne varijable u modelu statistički su značajne, odnosno doprinose kvaliteti modela. Parametar kategorije prometnice za državne ceste ima negativan predznak, što pokazuje da su stope rasta

veće na autocestama. Isto potvrđuju i rezultati istraživanja provedenih u sklopu ovoga rada (v. 2.3.). Rezultati prognostičkoga modela V1 prikazani su u tablici 5.

Tablica 5. Rezultati za prognostički model V1

Model	R^2	Korigirani R^2	Standardna pogreška procjene
1	0,493	0,472	0,03105
2	0,697	0,671	0,02453
3	0,753	0,720	0,02264

Model		Zbroj kvadrata	Sredina kvadrata	F vrijednost	Značajnost
1	Model	0,023	0,023	23,374	0,000
	Greška	0,023	0,001		
	Ukupno	0,046			
2	Model	0,032	0,016	26,453	0,000
	Greška	0,014	0,001		
	Ukupno	0,046			
3	Model	0,034	0,011	22,377	0,000
	Greška	0,011	0,001		
	Ukupno	0,046			

Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	Značajnost
		B	Standardna pogreška	Beta		
1	Konstanta	0,008	0,007		1,136	0,267
	MV	1,030	0,213	0,702	4,835	0,000
2	Konstanta	0,027	0,007		3,681	0,001
	MV	1,030	0,168	0,702	6,120	0,000
	cesta=DC	-0,038	0,010	-0,451	-3,931	0,001
3	Konstanta	0,016	0,008		2,023	0,055
	MV	0,868	0,171	0,592	5,070	0,000
	xesta=DC	-0,038	0,009	-0,451	-4,260	0,000
	Dolasci	0,283	0,127	0,261	2,238	0,036

Analizom dobivenih rezultata prognostičkoga modela V2 dobiven je i statistički značajan model ($p<0,000$, F vrijednost 20,105). Vrijednost R^2 dodavanjem svake nove nezavisne varijable raste do 0,636, dok je korigirani R^2 neznačajno manji i iznosi 0,604. Sve

nezavisne varijable u modelu statistički su značajne, odnosno doprinose kvaliteti modela. Parametar kategorije prometnice za državne ceste ima negativan predznak, što pokazuje da su stope rasta veće na autocestama. Rezultati prognostičkog modela V2 prikazani su u tablici 6.

Tablica 6. Rezultati za prognostički model V2

Model	R^2	Korigirani R^2	Standardna pogreška procjene
1	0,433	0,409	0,03286
2	0,636	0,604	0,02688

Model		Zbroj kvadrata	Sredina kvadrata	F vrijednost	Značajnost
1	Model	0,020	0,020	18,294	0,000
	Greška	0,026	0,001		
	Ukupno	0,046			
2	Model	0,029	0,015	20,105	0,000
	Greška	0,017	0,001		
	Ukupno	0,046			

Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	Značajnost
		B	Standardna pogreška	Beta		
1	Konstanta	0,009	0,007		1,234	0,229
	RRNT	0,015	0,003	0,658	4,277	0,000
2	Konstanta	0,028	0,008		3,507	0,002
	RRNT	0,015	0,003	0,658	5,229	0,000
	cesta=DC	-0,038	0,011	-0,451	-3,587	0,002

Slični rezultati prognostičkoga modela V2 dobiveni su i za model V3. Model je statistički značajan ($p<0,000$, F vrijednost 20,051). Vrijednost R^2 dodavanjem svake nove nezavisne varijable raste do 0,636, dok je korigirani R^2 neznačajno manji i iznosi 0,604. Sve nezavisne varijable u modelu statistički su značajne, odnosno doprinose kvaliteti modela. Parametar kategorije prometnice za državne ceste ima negativan predznak, što pokazuje da su stope rasta veće na autocestama. Rezultati prognostičkoga modela V3 prikazani su u tablici 7.

Tablica 7. Rezultati za prognostički model V3

Model	R^2	Korigirani R^2	Standardna pogreška procjene
1	0,432	0,408	0,03288
2	0,636	0,604	0,02690

Model		Zbroj kvadrata	Sredina kvadrata	F vrijednost	Značajnost
1	Model	0,020	0,020	18,247	0,000
	Greška	0,026	0,001		
	Ukupno	0,046			
2	Model	0,029	0,015	20,051	0,000
	Greška	0,017	0,001		
	Ukupno	0,046			

Model		Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	Značajnost
		B	Standardna pogreška	Beta		
1	Konstanta	0,015	0,007		2,166	0,040
	BDP_RSR	0,796	0,186	0,657	4,272	0,000
2	Konstanta	0,034	0,008		4,389	0,000
	BDP_RSR	0,796	0,152	0,657	5,221	0,000
	cesta=DC	-0,038	0,011	-0,451	-3,584	0,002

S obzirom na to da su svi parametri unutar svih modela, kao i svi modeli, statistički značajni, provedena je provjera narušenosti polaznih pretpostavki o valjanosti izrađenih modela višestruke linearne regresije. Provjera narušenosti polaznih pretpostavki provedena je na temelju:

- analize distribucije pogrešaka i
- analize veze između regresijskih standardiziranih pogrešaka i predviđenih vrijednosti.

Analizom distribucije pogrešaka utvrđeno je da su pogreške distribuirane po normalnoj distribuciji kod sva tri modela. Uz grafičku analizu Q-Q[6] grafikona, provedeni su i testovi normalnosti, čiji su rezultati prikazani tablicom 8.

Tablica 8. Rezultati testa normalnosti pogrešaka prognostičkih modela

Model	Kolmogorov-Smirnov			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
Greške V1	0,107	26	0,200	0,975	26	0,766
Greške V2	0,092	26	0,200	0,988	26	0,987
Greške V3	0,132	26	0,200	0,959	26	0,379

Analizom veze između standardiziranih grešaka i predviđenih vrijednosti, utvrđeno je da su pogreške slučajne i nezavisne te da je varijanca konstantna, što dokazuje da polazne pretpostavke nisu narušene. Testiranje je temeljeno na grafičkoj analizi te je ispitan Pearsonov koeficijent korelacije između apsolutnih vrijednosti standardiziranih grešaka i predviđenih vrijednosti koji za niti jedan model nije pokazao statistički značajnu vezu. Grafička analiza veza između regresijskih standardiziranih pogrešaka i predviđenih vrijednosti za pojedine modele prikazana je grafikonima 45-47.

[6] *Quantile-Quantile Plot* – grafička metoda za uspoređivanje distribucije uzorka *x* s nekom teorijskom distribucijom.

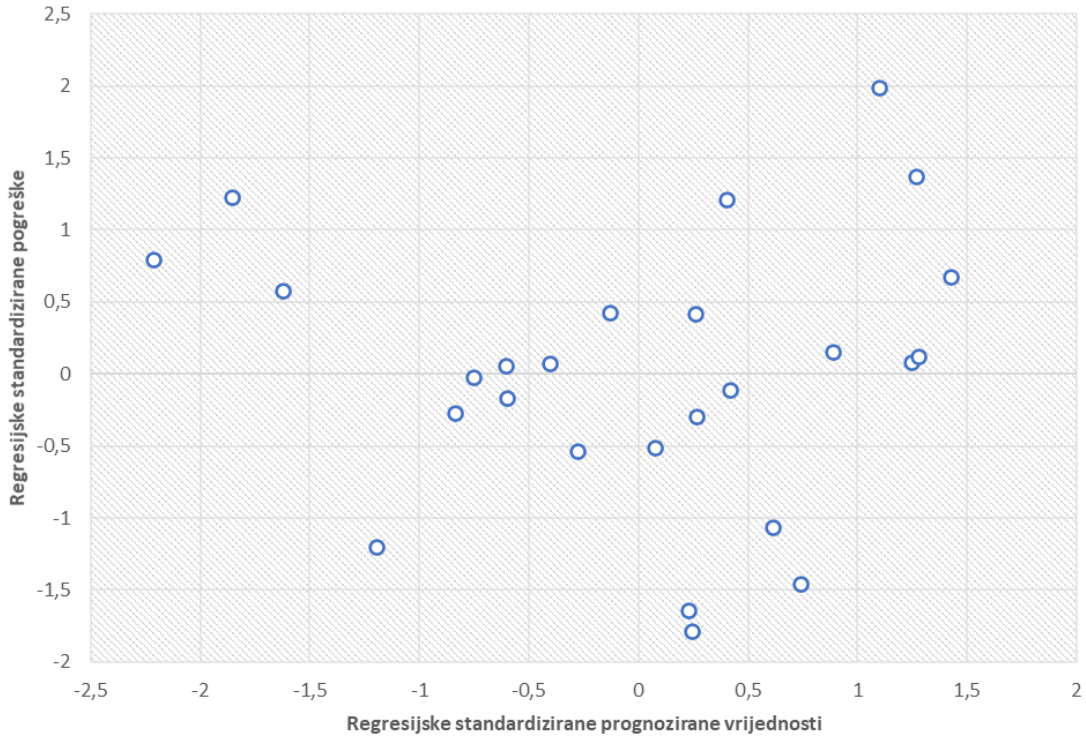

,

Grafikon 45. Odnos regresijskih standardiziranih pogrešaka i prognoziranih vrijednosti – V1

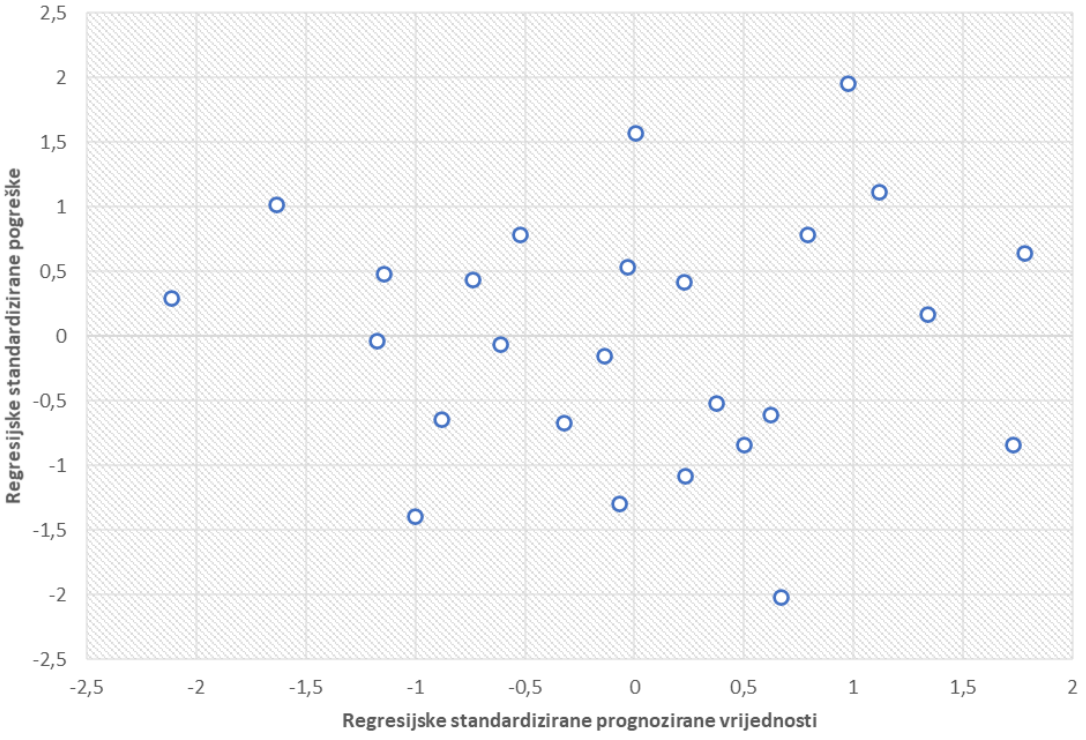

Grafikon 46. Odnos regresijskih standardiziranih pogrešaka i prognoziranih vrijednosti – V2

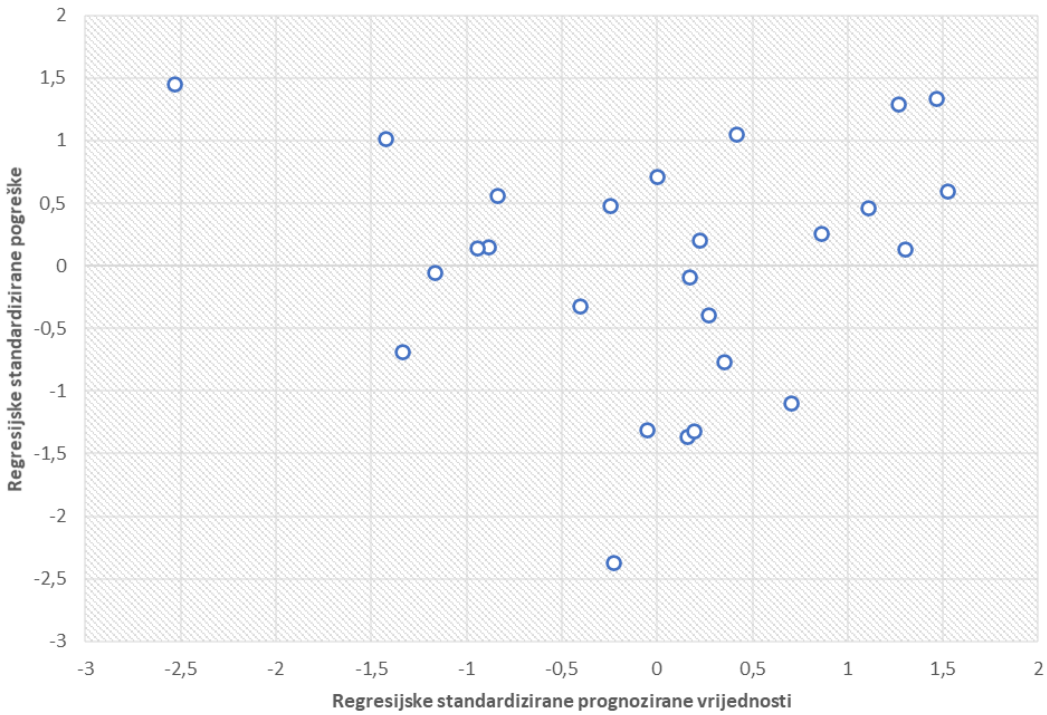

Grafikon 47. Odnos regresijskih standardiziranih pogrešaka i prognoziranih vrijednosti – V3

Uzimajući u obzir značajnost modela, kao i nenarušavanje polaznih pretpostavki višestruke linearne regresije, modeli su za prognoziranje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) sljedeći:

V1 $$PGDP_{\%} = 0{,}016 + 0{,}868MV - 0{,}038KAT + 0{,}2836DOL \quad (1)$$

V2 $$PGDP_{\%} = 0{,}028 + 0{,}015RRNT - 0{,}038KAT \quad (2)$$

V3 $$PGDP_{\%} = 0{,}034 + 0{,}796BDP_RSR - 0{,}038KAT \quad (3)$$

gdje je:

$PGDP_{\%}$	prosječna godišnja stopa promjene PGDP-a
MV	prosječna godišnja stopa promjene broja registriranih motornih cestovnih vozila
KAT	kategorija prometnice (0=autocesta, 1=DC ili ZC)
DOL	prosječna godišnja stopa promjene broja turističkih dolazaka
$RRNT$	realni rast neto plaće [%]
BDP_RSR	realni rast BDP-a

4. MODEL VREDNOVANJA PROGNOZA PRIJEVOZNE POTRAŽNJE U CESTOVNOM PROMETU

Izrađeni su prognostički modeli prikazani u 3. poglavlju po svojoj prirodi deterministički. Prema tome rezultat modela određen je utvrđenim odnosima između zavisne i nezavisnih varijabli te njihovim vrijednostima, a kao takav daje rezultat za jedan određeni scenarij. Predmetna činjenica ujedno predstavlja i osnovni nedostatak dobivenoga modela. S ciljem povećanja kvalitete dobivenih rezultata kroz lakšu i objektivniju eksploraciju, izrađeni su modeli vrednovanja prognoza prijevozne potražnje u cestovnome prometu.

Modeli vrednovanja prognoza prijevozne potražnje u cestovnome prometu kreirani su na način da su nezavisne varijable izrađenih modela za prognoziranje prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) prikazane preko utvrđenih distribucija tih varijabli u analiziranome razdoblju. Na taj se način u model uključuje slučajna komponenta te je on po svojoj prirodi stohastički model. Za razliku od determinističkoga modela, kod stohastičkoga modela svaki je rezultat slučajna varijabla jer ovisi o slučajnim ulaznim varijablama. Shodno tome, svaki rezultat predstavlja distribuciju rezultata, a prema distribucijama ulaznih scenarija. Za potrebe stohastičke simulacije korištena je *Monte Carlo metoda*[7] [61]. Shematski prikaz procesa izrade modela vrednovanja nalazi se na slici 2.

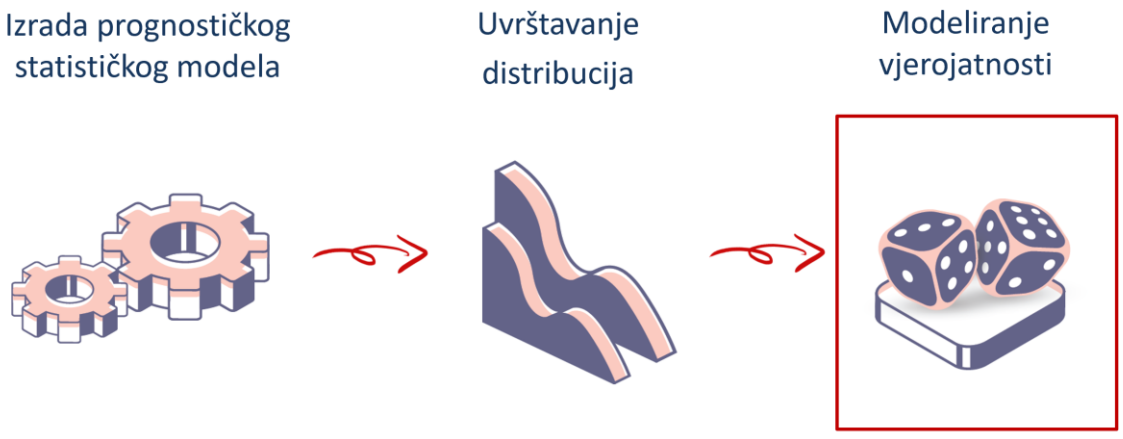

Slika 2. Proces izrade modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu

[7] *Monte Carlo simulacije* stohastičke su simulacijske metode koje na temelju slučajnih brojeva i velikoga broja ponavljanja izračuna predviđaju rezultate složenih sustava.

Izradom modela na ovaj način omogućuje se predviđanje distribucije prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP), a u skladu s korištenim nezavisnim varijablama pojedinoga modela. Na taj način omogućuje se kvalitetniji uvid u buduće potencijalne promjene prijevozne potražnje u cestovnome prometu, a shodno tome i donošenje objektivnijih i točnijih rezultata i/ili odluka. Isto tako, s obzirom na to da je stohastički model temeljen na determinističkome modelu u određenoj mjeri, smanjuje se negativan utjecaj *black box* efekta[8] jer su prethodno utvrđeni odnosi između zavisne i nezavisnih varijabli.

Rezultati analize utvrđivanja distribucija korištenih nezavisnih varijabli te modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu prikazani su u nastavku poglavlja.

4.1. Distribucije

Utvrđivanje distribucija nezavisnih varijabli provedeno je za analizirano razdoblje (2003.-2016. godina), pri čemu je utvrđeno da su korištene nezavisne varijable normalno distribuirane. Test normaliteta temelji se na grafičkoj analizi (histogrami[9] i *Q-Q plot*) te rezultatima Kolmogorov-Smirnovljevoga i Shapiro-Wilkovoga testa koji ne opovrgavaju nultu hipotezu da su podaci normalno distribuirani. Korištena je razina značajnosti 0,05. Prikaz dobivenih rezultata nalazi se u tablici 9 te grafikonima 48 - 51.

Tablica 9. Testovi normaliteta nezavisnih varijabli

Nezavisna varijabla	Kolmogorov-Smirnov			Shapiro-Wilk		
	Statistic	df	Značajnost	Statistic	df	Značajnost.
prosječna godišnja stopa promjene broja turističkih dolazaka	0,170	13	0,200	0,893	13	0,106
realni rast neto plaće	0,077	13	0,200	0,975	13	0,948
prosječna godišnja stopa promjene broja registriranih motornih cestovnih vozila	0,202	13	0,149	0,880	13	0,071
realni rast BDP-a	0,130	13	0,200	0,914	13	0,208

[8] *Black box* efekt opisuje sustav u kojem su poznati ulazni podaci i rezultati, ali ne i postupak koji dovodi do njih, odnosno nije poznato kako točno ulazni podaci djeluju na dobiveni rezultat.

[9] Histogrami predstavljaju jednostavni prikaz frekvencija (ili relativnih frekvencija) podataka u uzorku, što može biti vrlo korisno za predviđanje distribucije uzorka.

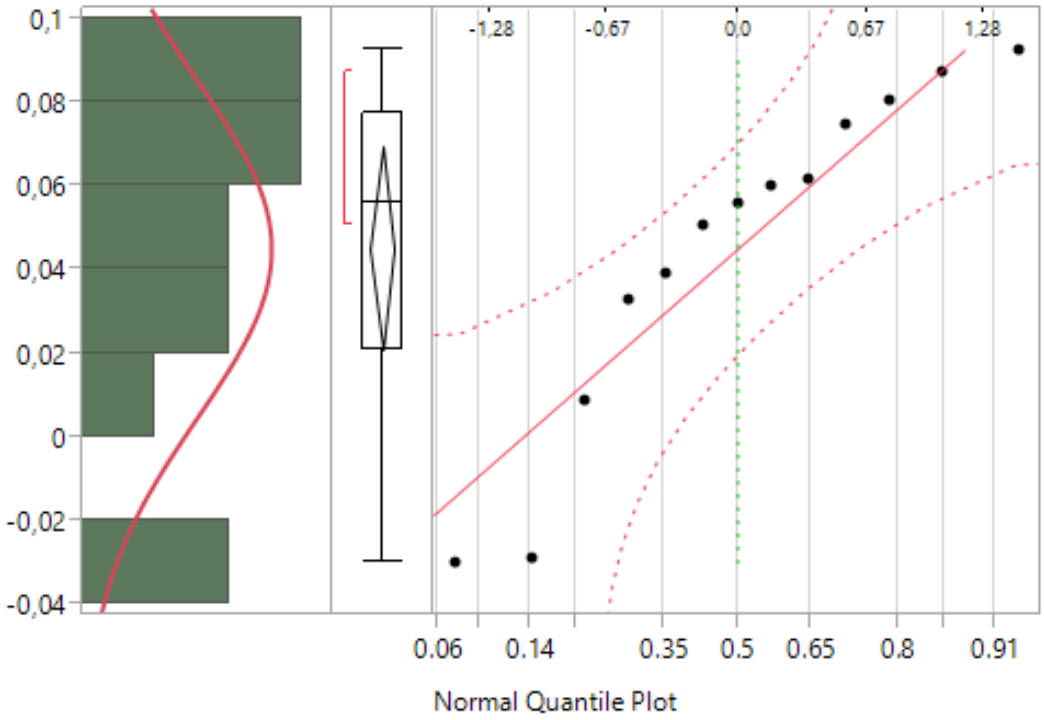

Grafikon 48. Histogram i Q-Q grafikon prosječne godišnje stope promjene broja turističkih dolazaka

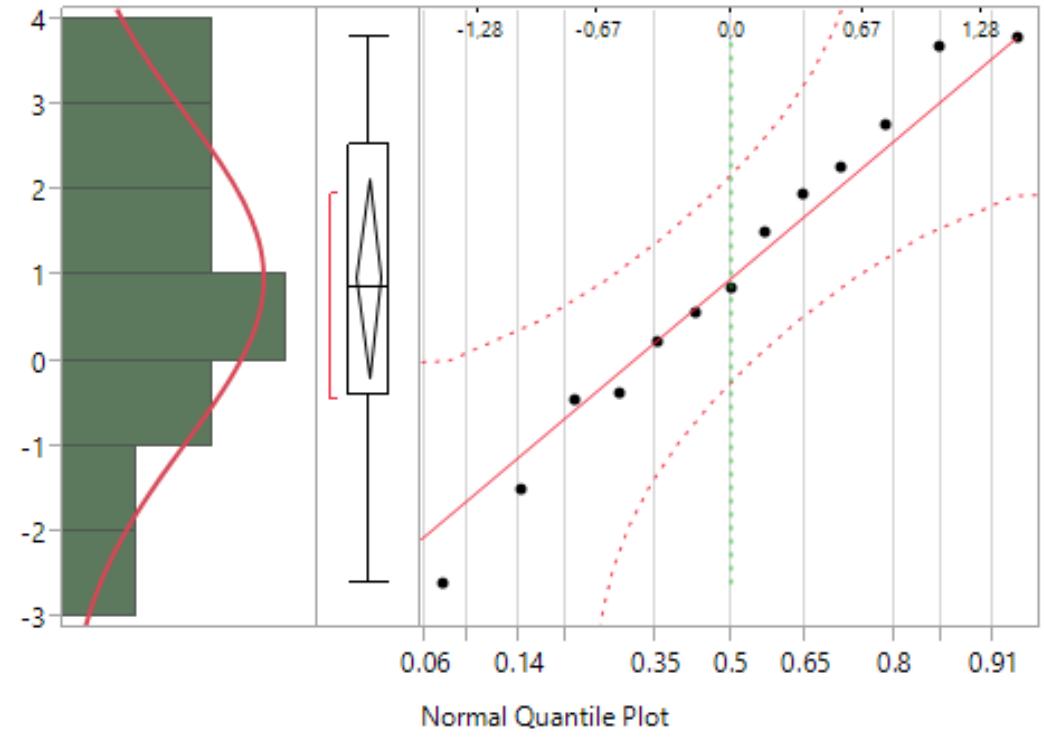

Grafikon 49. Histogram i Q-Q grafikon realnoga rasta neto plaće

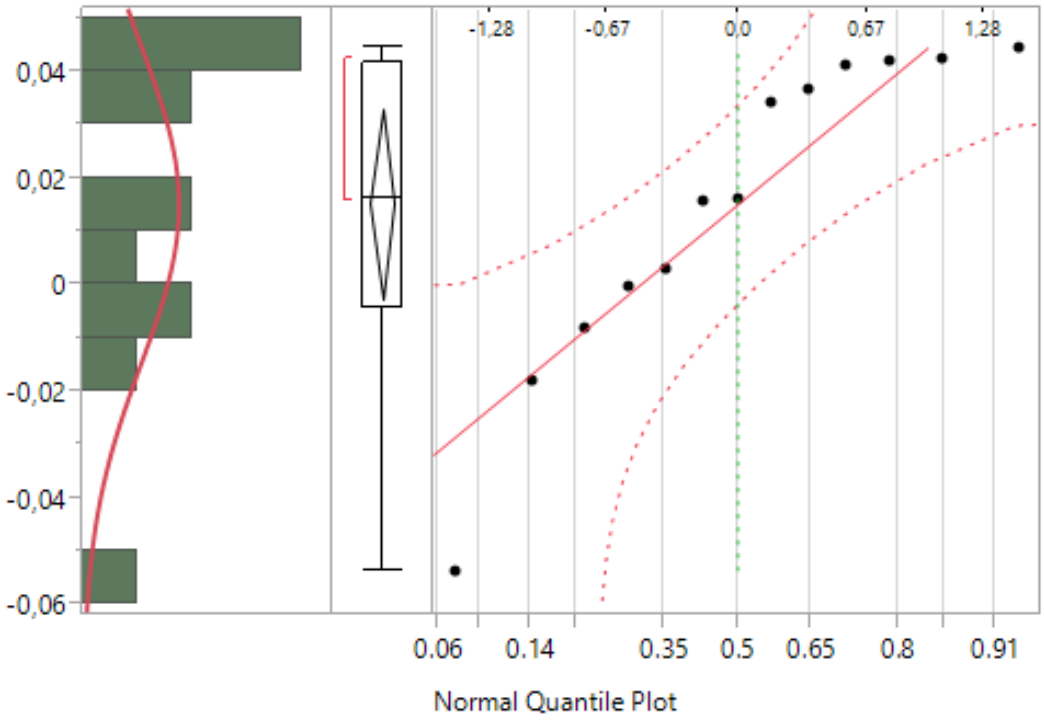

Grafikon 50. Histogram i Q-Q grafikon prosječne godišnje stope promjene broja registriranih motornih cestovnih vozila

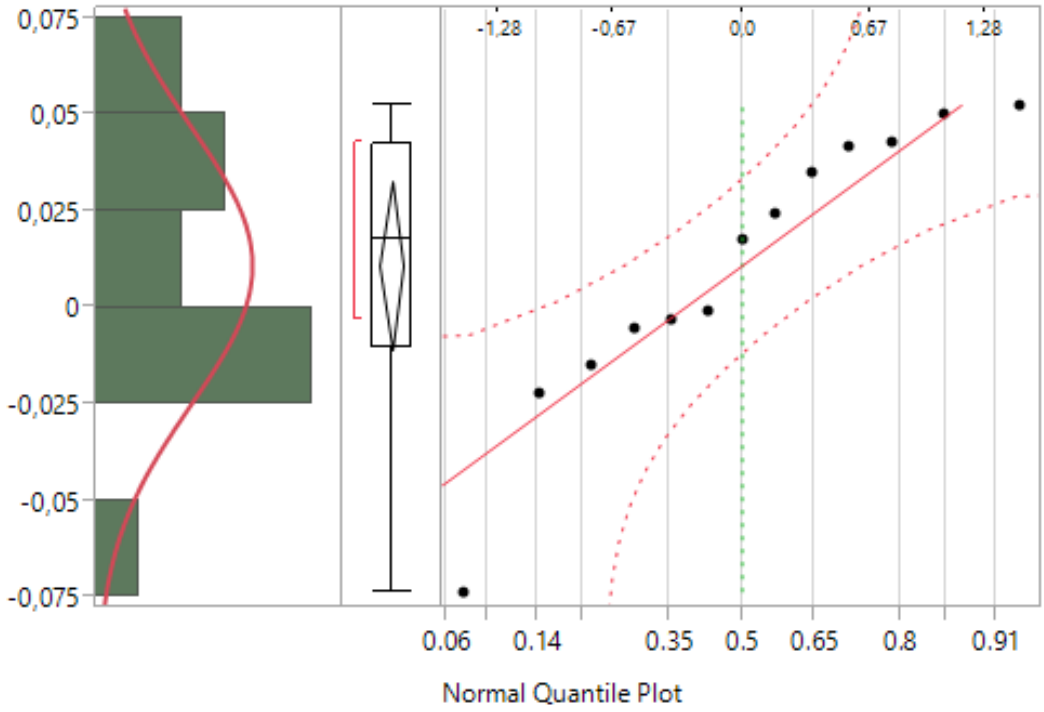

Grafikon 51. Histogram i Q-Q grafikon realnoga rasta BDP-a

Za potrebe određivanja parametara utvrđenih distribucija provedena je deskriptivna statistička analiza predmetnih varijabli, čije su vrijednosti prikazane u tablici 10. Normalnost

distribucije potvrđuju i slične srednje i medijalne vrijednosti. Negativna vrijednost Skewness pokazuje nesimetričnost distribucija svih varijabli, kao što je vidljivo iz prikazanih histograma.

Tablica 10. Rezultati deskriptivne statistike nezavisnih varijabli

Varijabla	Deskriptivna statistika		Vrijednost	Std. greška
Prosječne godišnje stope promjene broja turističkih dolazaka	Srednja vrijednost		0,0450	0,01117
	95% interval pouzdanosti (sredina)	Donja granica	0,0207	
		Gornja granica	0,0694	
	Medijan		0,0559	
	Varijanca		0,002	
	Standardna devijacija		0,04027	
	Minimalna vrijednost		-0,03	
	Maksimalna vrijednost		0,09	
	Raspon		0,12	
	Interkvartilni raspon		0,06	
	Skewness		-0,931	0,616
	Kurtosis		-0,021	1,191
Realni rast neto plaće	Srednja vrijednost		0,9756	0,53624
	95% interval pouzdanosti (sredina)	Donja granica	-0,1927	
		Gornja granica	2,1440	
	Medijan		0,8500	
	Varijanca		03,738	
	Standardna devijacija		1,93345	
	Minimalna vrijednost		-2,60	
	Maksimalna vrijednost		3,79	
	Raspon		6,39	
	Interkvartilni raspon		2,93	
	Skewness		-0,214	0,616
	Kurtosis		-0,582	1,191
Prosječne godišnje stope promjene broja registriranih motornih cestovnih vozila	Srednja vrijednost		0,0152	0,00825
	95% interval pouzdanosti (sredina)	Donja granica	-0,0028	
		Gornja granica	0,0332	
	Medijan		0,0161	
	Varijanca		0,001	
	Standardna devijacija		0,02976	
	Minimalna vrijednost		-0,05	
	Maksimalna vrijednost		0,04	
	Raspon		0,10	
	Interkvartilni raspon		0,05	

Varijabla	Deskriptivna statistika		Vrijednost	Std. greška
	Skewness		-1,043	0,616
	Kurtosis		0,763	1,191
Realni rast BDP-a	Srednja vrijednost		0,0111	0,00999
	95% interval pouzdanosti (sredina)	Donja granica	-0,0107	
		Gornja granica	0,0328	
	Medijan		0,0176	
	Varijanca		0,001	
	Standardna devijacija		0,03603	
	Minimalna vrijednost		-0,07	
	Maksimalna vrijednost		0,05	
	Raspon		0,13	
	Interkvartilni raspon		0,05	
	Skewness		-0,972	0,616
	Kurtosis		1,045	1,191

Sukladno dobivenim rezultatima deskriptivne statistike, rezultati parametara normalnih distribucija nezavisnih varijabli, koji su korišteni za postupak vrednovanja prognoza prijevozne potražnje u cestovnome prometu, prikazani su u tablici 11.

Tablica 11. Parametri normalnih distribucija nezavisnih varijabli

Varijabla	Srednja vrijednost (μ)	Standardna devijacija (σ)
Prosječne godišnje stope promjene broja turističkih dolazaka	0,0450	0,04027
Realni rast neto plaće	0,9756	1,93345
Prosječne godišnje stope promjene broja registriranih motornih cestovnih vozila	0,0152	0,02976
Realni rast BDP-a	0,0111	0,03603

4.2. Modeliranje vjerojatnosti

Modeliranje vjerojatnosti jedna je od često korištenih metoda, a pogotovo kada su u pitanju analize rizika i sl. Jedna od često korištenih metoda modeliranja vjerojatnosti upravo je Monte Carlo metoda. Monte Carlo metoda temelji se na simulaciji, odnosno generiranju slučajnih vrijednosti ulaznih varijabli prema unaprijed definiranoj funkciji distribucije te se na temelju svake promjene vrijednosti ulaznih varijabli izračunava nova izlazna vrijednost. Navedeni postupak provodi se više stotina puta te se kao izlazna vrijednost također dobiva određena distribucija vjerojatnosti izlazne vrijednosti (npr. vjerojatnost određenoga porasta intenziteta prijevozne potražnje) [62].

Sukladno rezultatima analize distribucija, za potrebe modeliranja vjerojatnosti, sve ulazne varijable definirane su prema normalnoj distribuciji s utvrđenim parametrima srednje vrijednosti i standardne devijacije (tablica 11). Za provođenje modeliranja vjerojatnosti korištene su sljedeće procedure/postavke:

- uzorkovanje *Latin Hypercube*
- generator slučajnih brojeva *Mersenne Twister*
- *seed* 1832856990
- broj ponavljanja 20.000

Modeliranje vjerojatnosti provedeno je za sva tri izrađena prognostička modela prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP).

Analizom rezultata modeliranja prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) prema postavljenim ulaznim podacima, vidljivo je da je vjerojatnost pojavljivanja dosadašnjih prosječnih vrijednosti rasta (kada su u pitanju državne ceste, taj rast u prosjeku iznosi oko 0,5%, a za autoceste oko 4,2%) oko 50%. Uzimajući u obzir nestabilne trendove nezavisnih varijabli u analiziranome periodu (učestale promjene trendova), vjerojatnost je od oko 50% očekivana.

Prema rezultatima modeliranja vjerojatnosti za autoceste, utvrđena je prosječna vrijednost godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) oko 4,2% sa standardnom devijacijom oko 2,8%, a u ovisnosti o modelu. Rezultati deskriptivne statistike za modelirane vjerojatnosti prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) prikazani su u tablici 12, dok su percentilne vrijednosti prikazane u tablici 13.

Tablica 12. Rezultati deskriptivne statistike modeliranih vjerojatnosti prognoze - AC

Deskriptivna statistika	V1	V2	V3
Minimalna vrijednost	-0,065918275	-0,088235005	-0,069674669
Maksimalna vrijednost	0,151172111	0,159843911	0,160152388
Srednja vrijednost	0,041954813	0,042632953	0,042795836
Standardna devijacija	0,028121418	0,029004219	0,028678805
Varijanca	0,000790814	0,000841245	0,000822474
Skewness	0,001385969	-0,001613855	0,000219838
Kurtosis	2,994301871	3,003838964	2,997005254
Medijan	0,042110848	0,042633549	0,042795048
Mod	0,043037671	0,044452688	0,043155402

Tablica 13. Percentilne vrijednosti modeliranih vjerojatnosti prognoze - AC

Percentili	V1	V2	V3
1,0%	-0,023764122	-0,024860565	-0,023966403
2,5%	-0,013362441	-0,014217561	-0,013425486
5,0%	-0,004249369	-0,005076877	-0,004387725
10,0%	0,0059702	0,005466199	0,006034602
20,0%	0,018090471	0,018221598	0,018656154
25,0%	0,022864111	0,023071207	0,023447628
50,0%	0,042110848	0,042633549	0,042795048
75,0%	0,060844109	0,062194472	0,06213943
80,0%	0,065545952	0,067039511	0,066929761
90,0%	0,078037517	0,079799777	0,079543627
95,0%	0,088260499	0,090330068	0,089959754
97,5%	0,096905594	0,09946149	0,099007133
99,0%	0,107254612	0,110094295	0,109511071

Ako se detaljnije analiziraju rezultati modela za autoceste, može se pretpostaviti da, ukoliko se planira nastavak prosječnoga rasta intenziteta cestovne prijevozne potražnje u skladu s dosadašnjim trendovima (u obzir su uzeti rezultati modeliranja s vrijednosti porasta 4,2% i

više, a u prosjeku oko 6,5%), nezavisne varijable u prognoziranome razdoblju trebaju pratiti sljedeće trendove:

- broj turističkih dolazaka (stope promjene) treba u prosjeku rasti oko 5,8%,
- broj registriranih cestovnih motornih vozila (stope promjene) treba u prosjeku rasti oko 3,7%,
- realni rast neto plaće treba u prosjeku biti oko 2,5% te
- realni rast BDP-a treba u prosjeku rasti oko 3,9%.

Rezultati kumulativne funkcije distribucije prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) na autocestama prikazani su grafikonima 52-54.

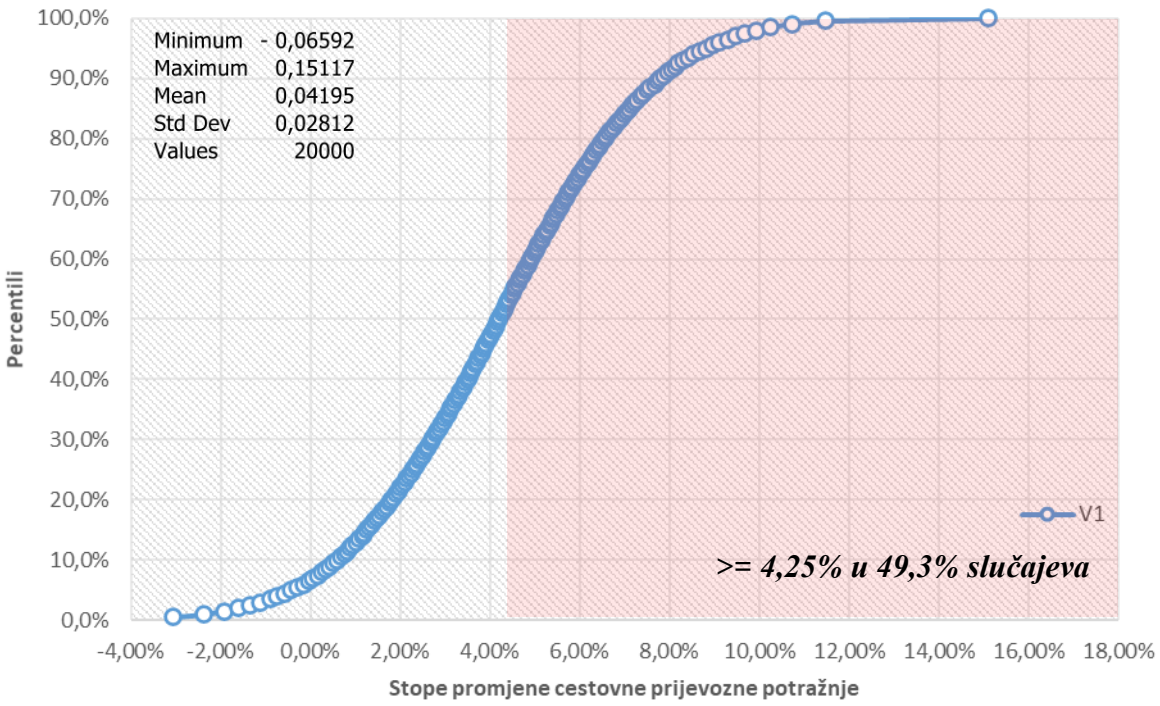

Grafikon 52. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V1, autoceste

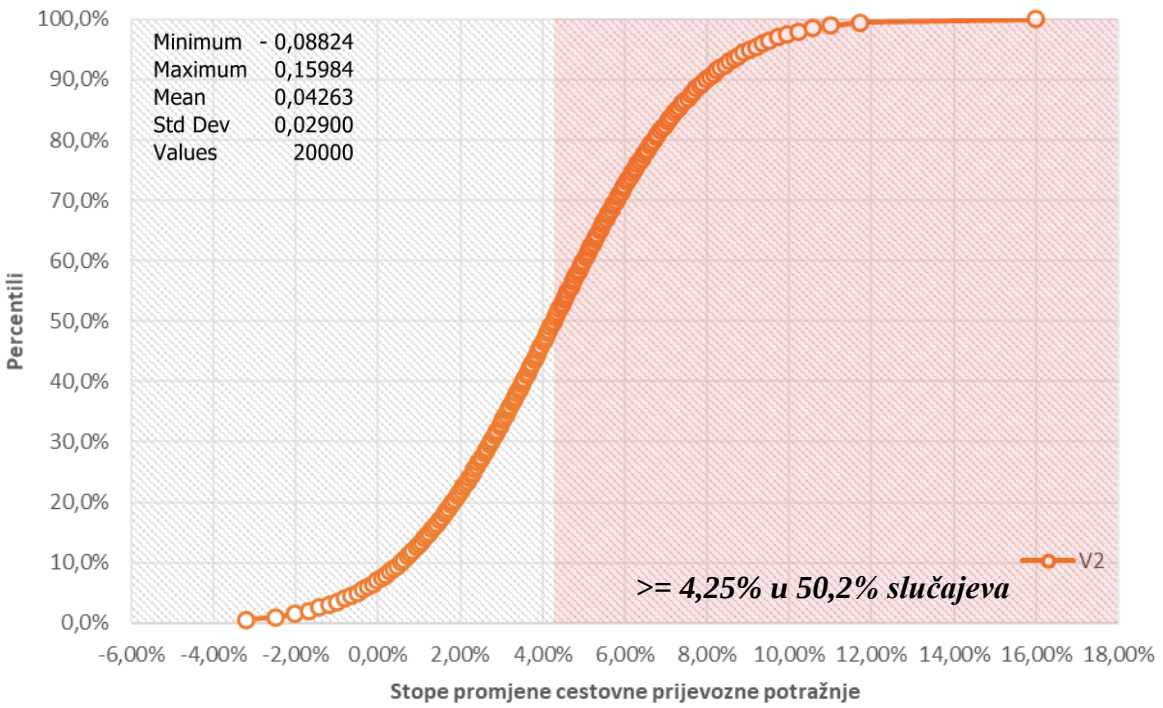

Grafikon 53. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V2, autoceste

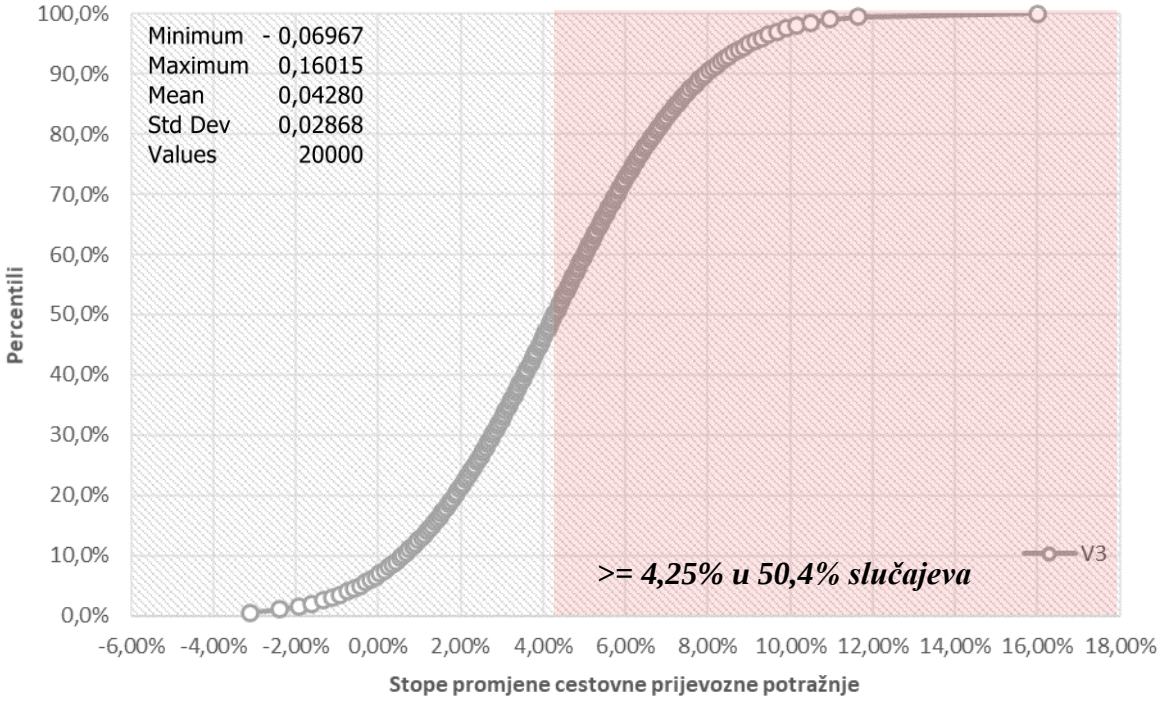

Grafikon 54. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V3, autoceste

Prema rezultatima modeliranja vjerojatnosti za državne ceste utvrđena je prosječna vrijednost godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) oko 0,4% sa standardnom devijacijom oko 2,8%, a u ovisnosti o modelu. Rezultati deskriptivne statistike za modelirane vjerojatnosti prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) prikazani su u tablici 14, dok su percentilne vrijednosti prikazane u tablici *15*.

Tablica 14. Rezultati deskriptivne statistike modeliranih vjerojatnosti prognoze - DC

Deskriptivna statistika	**V1**	**V2**	**V3**
Minimalna vrijednost	-0,115702806	-0,108200432	-0,110489103
Maksimalna vrijednost	0,114207129	0,11767802	0,121933914
Srednja vrijednost	0,003955488	0,004634022	0,004795646
Standardna devijacija	0,028302977	0,028998756	0,02868114
Varijanca	0,000801059	0,000840928	0,000822608
Skewness	0,001000352	8,10323E-05	-0,000153068
Kurtosis	2,999150784	2,993527435	3,000188814
Medijan	0,003922622	0,004630782	0,004793707
Mod	-0,002133862	0,004997485	0,006594217

Tablica 15. Percentilne vrijednosti modeliranih vjerojatnosti prognoze - DC

Percentili	**V1**	**V2**	**V3**
1,0%	-0,061965905	-0,062871867	-0,061936482
2,5%	-0,051422293	-0,052230834	-0,051423334
5,0%	-0,042934655	-0,04307163	-0,042386188
10,0%	-0,032390172	-0,032538277	-0,031964881
20,0%	-0,019894654	-0,019776602	-0,019343943
25,0%	-0,015259084	-0,014931313	-0,014549317
50,0%	0,003922622	0,004630782	0,004793707
75,0%	0,023213175	0,02419446	0,024137104

Percentili	V1	V2	V3
80,0%	0,027770254	0,029040639	0,028931622
90,0%	0,039928573	0,041793481	0,041542554
95,0%	0,050294017	0,052325538	0,051964419
97,5%	0,059698808	0,061452996	0,060993784
99,0%	0,069739457	0,072096595	0,071477581

Ako se detaljnije analiziraju rezultati modela kada su u pitanju državne ceste, može se pretpostaviti da, ukoliko se planira nastavak prosječnoga rasta intenziteta cestovne prijevozne potražnje u skladu s dosadašnjim trendovima (u obzir su uzeti rezultati modeliranja s vrijednosti porasta 0,5% i više, a u prosjeku oko 2,7%), nezavisne varijable u prognoziranome razdoblju trebaju pratiti sljedeće trendove:

- broj turističkih dolazaka (stope promjene) treba u prosjeku rasti oko 5,9%,
- broj registriranih cestovnih motornih vozila (stope promjene) treba u prosjeku rasti oko 3,8%,
- realni rast neto plaće treba u prosjeku biti oko 2,5% te
- realni rast BDP-a treba u prosjeku rasti oko 4,0%.

Analizom rezultata svih modeliranih vjerojatnosti može se uočiti nešto manja osjetljivost trenda cestovne prijevozne potražnje na trend gospodarskih aktivnosti na autocestama u odnosu na državne ceste. Isto potvrđuju i rezultati analize trenda i deskriptivne statistike kretanja prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje po kategorijama prometnice, pri čemu je zabilježena veća standardna devijacija kod autocesta u odnosu na državne ceste. Razlike se mogu objasniti većim udjelom tranzitnoga prometa na autocestama u odnosu na državne ceste, kao i većim udjelom turističkoga prometa, pa shodno tome promet državnih cesta više ovisi o gospodarskim aktivnostima unutar Republike Hrvatske nego što je to slučaj kod autocesta.

Rezultati kumulativne funkcije distribucije prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) na državnim cestama prikazani su grafikonima 55-57.

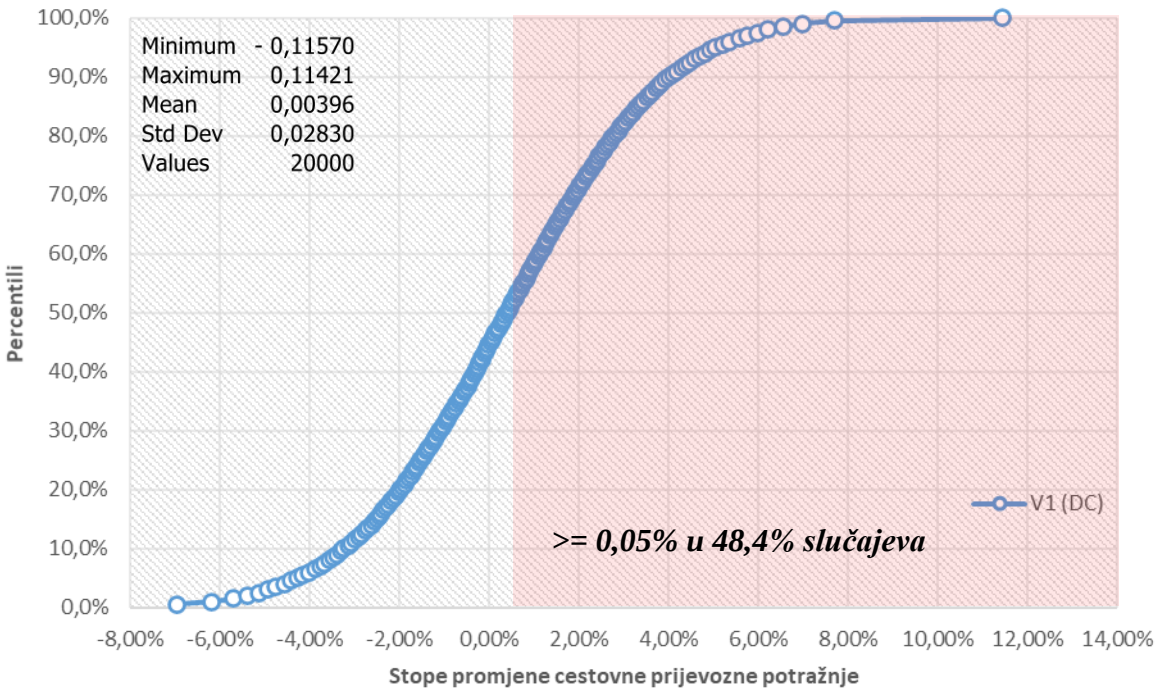

Grafikon 55. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V1, državne ceste

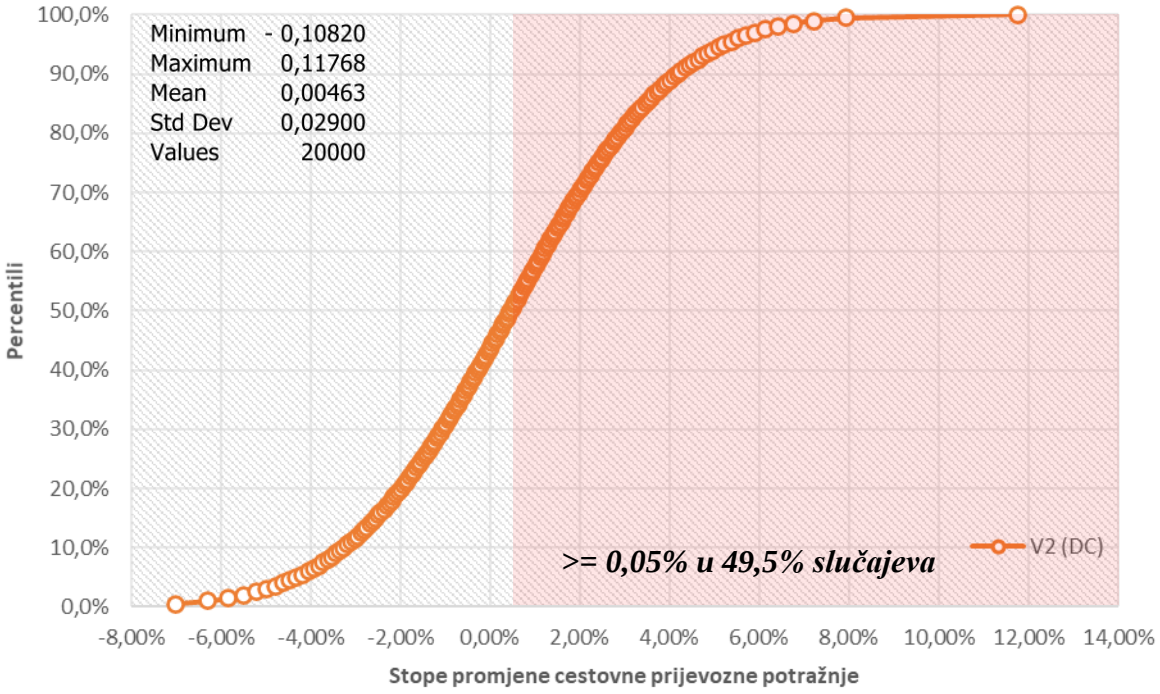

Grafikon 56. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V2, državne ceste

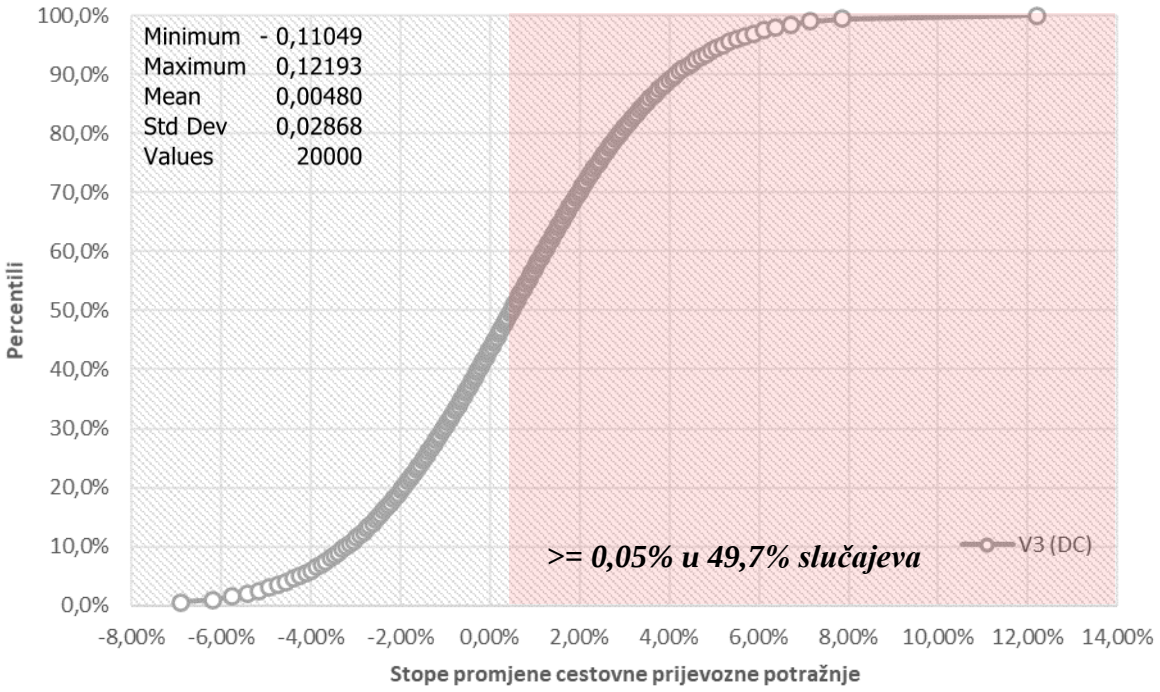

Grafikon 57. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V3, državne ceste

5. TESTIRANJE MODELA

S ciljem utvrđivanja kvalitete izrađenih modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu, provedeno je testiranje uspješnosti modela. Testiranje je provedeno za razdoblje od 2017. do 2019. godine na način da se analizirala uspješnost modela vrednovanja za utvrđivanje vrijednosti nezavisnih varijabli potrebnih za pojavljivanje stvarnoga kretanja cestovne prijevozne potražnje u predmetnome razdoblju (prosječne godišnje stope promjene intenziteta cestovne prijevozne potražnje (PGDP)). Važno je napomenuti da model rađen na temelju podataka za razdoblje od 2003. do 2016. godine te podaci u razdoblju od 2017. do 2019. godine nisu korišteni u procesu izrade modela vrednovanja.

Uz testiranje uspješnosti provedene su i dodatne dvije analize s ciljem testiranja mogućnosti izrađenih modela vrednovanja, kao i njihove kvalitete. Prva dodatna analiza odnosi se na vrednovanje kvalitete modela korištenjem novoutvrđenih distribucija nezavisnih varijabli u razdoblju od 2017. do 2019. godine koja nije korištena pri izradi modela. Cilj predmetne analize utvrđivanje je kvalitete modela vrednovanja u slučaju promjene distribucije nezavisnih varijabli i/ili u slučaju posjedovanja kvalitetnih prognostičkih podataka nezavisnih varijabli. Druga dodatna analiza odnosi se na vjerojatnost pojavljivanja (vrednovanje) utvrđene najčešće korištene prognoze prijevozne potražnje u cestovnome prometu u Republici Hrvatskoj, a s ciljem utvrđivanja točnosti prognoziranja cestovne prijevozne potražnje u Republici Hrvatskoj u odnosu na ostvarene vrijednosti, kao i svjetsku praksu.

5.1. Testiranje modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu

Testiranje uspješnosti modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu provedeno je na temelju vrijednosti zavisne i nezavisnih varijabli za razdoblje od 2017. do 2019. godine. Testiranje uspješnosti modela vrednovanja provedeno je prema sljedećim koracima:

1. utvrđivanje vrijednosti zavisne i nezavisnih varijabli u razdoblju od 2017. do 2019. godine,
2. analiza rezultata (scenarija) modela vrednovanja u kojima je zavisna varijabla jednaka stvarnoj vrijednosti zavisne varijable za analizirano razdoblje uvećana/umanjenja za ±5% *(s obzirom na to da je rezultat modela vrednovanja*

distribucija, analizirana je stvarna vrijednost kretanja prijevozne potražnje u intervalu stvarna vrijednost ±5%),

3. nakon odabira svih mogućih rezultata (scenarija) modela vrednovanja koji daju stvarnu vrijednost zavisne varijable ±5%, provedena je analiza deskriptivne statistike zavisne i nezavisnih varijabli odabranih rezultata (scenarija) modela vrednovanja,
4. izračunata je postotna greška (odstupanja) srednje vrijednosti nezavisnih varijabli odabranih rezultata (scenarija) modela vrednovanja u odnosu na stvarnu vrijednost nezavisnih varijabli u analiziranome razdoblju *(osim izračuna odstupanja za 2017., 2018. i 2019. godinu, provedena je i analiza odstupanja za prosječno kretanje zavisnih i nezavisnih varijabli u razdoblju 2017.-2019.),*
5. interpretacija rezultata.

Prikaz vrijednosti nezavisnih varijabli za predmetno razdoblje nalazi se u tablici 16, dok se prikaz kretanja prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) na autocestama i državnim cestama (zavisna varijabla) za predmetno razdoblje nalazi u tablici 17. Vrijednosti kretanja prosječnih godišnjih stopa promjene cestovne prijevozne potražnje (PGDP) određene su sukladno rezultatima brojanja prometa Hrvatskih cesta d.o.o. za autoceste i državne ceste [50] prema metodologiji korištenoj kao i kod procesa izrade prognostičkoga modela (v. 3. *Model prognoziranja potražnje u cestovnom prometu*).

Tablica 16. Vrijednosti nezavisnih varijabli u razdoblju 2017.-2019. (Izvor: [53], autorova obrada)

Nezavisne varijable / Godina	2017.	2018.	2019.
Dolasci turista	17.430.580	18.666.580	19.566.146
Dolasci turista, stope promjene	0,1178	0,0709	0,0482
Broj registriranih cestovnih motornih vozila	2.056.127	2.148.062	2.275.027
Broj registriranih cestovnih motornih vozila, stope promjene	0,03009	0,04471	0,05911
Realni rast neto plaće [%]	4,08	2,78	2,68
Realna stopa rasta BDP-a [%]	3,139181715	2,694827658	2,93599231

Tablica 17. Vrijednosti kretanja prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) u razdoblju 2017.-2019. (Izvor:[50], autorova obrada)

Godina	Autoceste	Državne ceste
2017.	6,16%	4,11%
2018.	5,45%	2,13%
2019.	4,36%	2,68%
Srednja vrijednost	*5,32%*	*2,97%*

Analizom dobivenih rezultata testiranja uspješnosti modela može se zaključiti sljedeće:

- prosječni je rast cestovne prijevozne potražnje na autocestama u iznosu od 5,32% ±5% za razdoblje od 2017. do 2019. godine prema modelu vrednovanja utvrđen u svega oko 7,00% scenarija, a u ovisnosti o modelu *(predmetno je u skladu s rastom prijevozne potražnje u razdoblju 2003.-2016. godine koji je u prosjeku iznosio oko 4,24%),*
- prosječni je rast cestovne prijevozne potražnje na državnim cestama u iznosu od 2,97% ±5% za razdoblje od 2017. do 2019. godine prema modelu vrednovanja utvrđen u tek oko 2,83% scenarija, a u ovisnosti o modelu *(predmetno je u skladu s rastom prijevozne potražnje u razdoblju 2003.-2016. godine koji je u prosjeku iznosio oko 0,45%),*
- izrađeni je model vrednovanja nešto kvalitetniji za analizu na državnim cestama u odnosu na autoceste, što pokazuju razlike postotnih grešaka *(predmetno je posljedica činjenice da prijevozna potražnja na autocestama jednim većim djelom ovisi i o gospodarskome stanju izvan Republike Hrvatske (PLDP) koje korištene nezavisne varijable ne opisuju kvalitetno kao stanje u Republici Hrvatskoj),*
- izrađeni modeli vrednovanja bilježe niža odstupanja za vrednovanje prognoza u duljemu razdoblju, npr. postotna greška stope promjene registriranih cestovnih motornih vozila za 2017. godinu za model V1 iznosi gotovo 70% za državne ceste dok za srednju vrijednost od 2017. do 2019. godine postotna greška modela iznosi svega oko -9% *(naime, ukoliko se vrednuje prognoza za dulje razdoblje, prosječne se vrijednosti nezavisnih varijabli kao i kretanja prijevozne potražnje stabiliziraju te je točnost modela veća, npr. porast dolazaka turista u 2017. godini je bio gotovo 12%, a u 2019. godini tek oko 5%),*

- kada su u pitanju državne ceste, modeli vrednovanja V1 i V2 bilježe znatno manja odstupanja u odnosu na model V3 *(predmetno je posljedica činjenice da prijevozna potražnja na državnim cestama ovisi o gospodarstvu na nacionalnoj razini koje kvalitetnije opisuje stopa promjene broja registriranih motornih vozila i realni rast neto plaće nego realni rast BDP-a),*
- kada su u pitanju autoceste model vrednovanja V3 bilježi znatno manja odstupanja u odnosu na modele V1 i V2, što je u skladu s prethodno opisanom činjenicom *(kao što je analizom relevantnih pokazatelja utvrđeno, prijevozna potražnja na autocestama ovisi više o gospodarstvu na razini Europske unije, što kvalitetnije opisuju realne stope rasta BDP-a u odnosu na stope promjene broja registriranih motornih vozila i realni rast neto plaće u Republici Hrvatskoj),*
- tijekom vrednovanja predlaže se korištenje svih triju izrađenih modela s ciljem povećanja točnosti procesa vrednovanja, a ovisno o samome cilju vrednovanja, kao i kategoriji prometnice *(npr. model V3, koji ovisi realnome rastu BDP-a, ima veću otpornost na značajnije promjene dolazaka turista, model V2 u većoj mjeri uzima u obzir i inflaciju, dok model V1 ima najveću vrijednost R^2 te uzima u obzir ljetni promet i gospodarstvo kroz kupovnu moć stanovnika)*
- izračunate postotne greške modela u skladu su s rezultatima statističkih pokazatelja kvalitete pojedinih modela.

Prema rezultatima uspješnosti modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu, može se zaključiti da je potvrđena prikladnost primjene modela kao i hipoteza da je temeljem podataka o gospodarskim, demografskim i prometnim pokazateljima moguće provesti vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu. Prikaz prethodno opisanih rezultata uspješnosti nalazi se u tablicama 18 i 19.

Tablica 18. Postotne greške modela vrednovanja (autoceste)

		2017.		2018.		2019.		Prosjek (2017.-2019.)	
	Nezavisna varijabla	Model	Odstupanje	Model	Odstupanje	Model	Odstupanje	Model	Odstupanje
	Dolasci turista								
	Srednja vrijednost	0,056	-52,296%	0,053	-25,448%	0,047	-2,950%	0,051	-35,726%
	Minimalna	-0,066		-0,066		-0,072		-0,068	
	Maksimalna	0,173		0,194		0,174		0,194	
	Medijalna	0,057		0,053		0,047		0,051	
V1									
	Motorna vozila								
	Srednja vrijednost	0,034	13,103%	0,027	-39,529%	0,016	-72,157%	0,026	-41,189%
	Minimalna	-0,005		-0,022		-0,028		-0,022	
	Maksimalna	0,076		0,068		0,057		0,063	
	Medijalna	0,034		0,027		0,016		0,026	
	Realni rast neto plaće								
	Srednja vrijednost	2,233	-45,310%	1,762	-36,491%	1,042	-61,183%	1,679	-47,200%
V2	Minimalna	2,033		1,583		0,896		1,504	
	Maksimalna	2,443		1,946		1,187		1,859	
	Medijalna	2,231		1,761		1,042		1,678	
	Realni rast BDP-a								
	Srednja vrijednost	0,035	10,043%	0,026	-4,733%	0,012	-58,830%	0,024	**-17,519%**
V3	Minimalna	0,031		0,022		0,009		0,021	
	Maksimalna	0,038		0,029		0,015		0,027	
	Medijalna	0,034		0,026		0,012		0,024	

Tablica 19. Postotne greške modela vrednovanja (državne ceste)

		2017.		2018.		2019.		Prosjek (2017.-2019.)	
		Model	Odstupanje	Model	Odstupanje	Model	Odstupanje	Model	Odstupanje
V1	**Dolasci turista**								
	Srednja vrijednost	0,066	-44,218%	0,056	-20,496%	0,059	22,503%	0,058	-26,456%
	Minimalna	-0,042		-0,038		-0,074		-0,081	
	Maksimalna	0,168		0,151		0,166		0,165	
	Medijalna	0,065		0,057		0,059		0,060	
V2	**Motorna vozila**								
	Srednja vrijednost	0,051	69,620%	0,031	-29,602%	0,037	-37,401%	0,041	**-8,915%**
	Minimalna	0,019		-0,001		0,003		0,007	
	Maksimalna	0,086		0,062		0,079		0,087	
	Medijalna	0,051		0,032		0,037		0,040	
V3	**Realni rast neto plaće**								
	Srednja vrijednost	3,401	-16,722%	2,087	-24,788%	2,456	-8,486%	2,648	**-16,733%**
	Minimalna	3,268		2,017		2,367		2,551	
	Maksimalna	3,541		2,159		2,546		2,749	
	Medijalna	3,398		2,087		2,455		2,648	
	Realni rast BDP-a								
	Srednja vrijednost	0,057	80,122%	0,032	17,978%	0,039	31,926%	0,042	44,945%
	Minimalna	0,054		0,030		0,037		0,041	
	Maksimalna	0,059		0,033		0,040		0,044	
	Medijalna	0,057		0,032		0,039		0,042	

5.2. Testiranje kvalitete modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu primjenom drugih distribucija i/ili prognostičkih podataka

Analiza kvalitete modela vrednovanja u slučaju korištenja drugih distribucija nezavisnih varijabli i/ili prognostičkih modela provedena je i za razdoblje 2017.-2019. godine. Naime, ako se promatra razdoblje za koje je rađeno testiranje modela, može se zaključiti da se radi o razdoblju gospodarskoga oporavka nakon značajnijih padova 2009. i 2012. godine te su, shodno tome, parametri distribucija nezavisnih varijabli drukčiji, odnosno većih su vrijednosti u odnosu na razdoblje prema kojemu je model izrađen. Isto potvrđuju i rezultati provedene komparacijske analize prosječnih trendova nezavisnih varijabli modela u razdoblju 2017.-2019. godine u odnosu na razdoblje 2003.-2016. godine koje je korišteno za izradu modela vrednovanja. Analizom je utvrđeno da je u razdoblju 2017.-2019. godine:

- realni rast BDP-a bio u prosjeku veći za 0,5%,
- broj je turističkih dolazaka (godišnje stope promjene) bio u prosjeku veći za 3,4%,
- broj je registriranih cestovnih motornih vozila (godišnje stope promjene) bio u prosjeku veći za 2,9%,
- realni je rast neto plaće bio u prosjeku veći za 2,2%.

Prema tome, za potrebe analize kvalitete modela vrednovanja, a koristeći druge distribucije, definirane su trokutaste umjesto korištenih normalnih distribucija. Trokutaste distribucije su definirane prema stvarno utvrđenim minimalnim, maksimalnim i srednjim vrijednostima kretanja nezavisnih varijabli u razdoblju 2017.-2019. godine. Nakon definiranih distribucija, za potrebe testiranja kvalitete ponovljen je postupak modeliranja vjerojatnosti baziran na Monte Carlo metodi, a prema istim procedurama/postavkama korištenima za izradu samoga modela. Prikaz korištenih distribucija nalazi se u tablici 20.

Tablica 20. Parametri distribucija nezavisnih varijabli

Varijabla	Minimalna	Srednja (Najčešća)	Maksimalna	Distribucija
prosječna godišnja stopa promjene broja turističkih dolazaka	0,0482	0,079	0,1178	Trokutasta
realni rast neto plaće	2,68	3,18	4,08	Trokutasta
prosječna godišnja stopa promjene broja registriranih motornih cestovnih vozila	0,03009	0,04464	0,05911	Trokutasta
realni rast BDP-a	0,02695	0,02923	0,03139	Trokutasta

Prema dobivenim rezultatima utvrđeno je da je očekivana srednja vrijednost rasta prijevozne potražnje na autocestama u razdoblju 2017.-2019. godine od 5,7% do 7,8%, a u ovisnosti o modelu. Kada su u pitanju državne ceste, za razdoblje 2017.-2019. godine utvrđena je očekivana srednja vrijednost rasta prijevozne potražnje od 1,9% do 4,0%, a u ovisnosti o modelu. Shodno dobivenim rezultatima razvidno je i značajno veća vjerojatnost većih porasta prijevozne potražnje u odnosu na vjerojatnosti koje je pokazao model vrednovanja prema utvrđenim normalnim distribucijama nezavisnih varijabli za razdoblje 2003.-2016. godine. Pa tako prema predmetnome modelu vjerojatnost porasta prijevozne potražnje na autocestama za 4,9% i više iznosi 100% prema sva tri modela, dok vjerojatnost porasta prijevozne potražnje na državnim cestama za 2,4% i više iznosi gotovo 100% prema modelima V1 i V2 te 0% prema modelu V3. Prema modelu V3 vjerojatnost 0% za porast prijevozne potražnje na državnim cestama u iznosu od 2,4% posljedica je upravo stabilnijih vrijednosti kretanja realnoga rasta BDP-a u analiziranome razdoblju u odnosu na druge nezavisne varijable, tj. manjih oscilacija.

Prikaz rezultata modela vrednovanja prema novodefiniranim distribucijama nezavisnih varijabli nalazi se u tablicama 21 i 22, dok je prikaz osjetljivosti modela vrednovanja na promjene ulaznih podataka prikazan grafikonima kumulativnih distribucija rezultata 58 i 59.

Tablica 21. Rezultati deskriptivne statistike rezultata modela vrednovanja

Percentili / Model	Autoceste			Državne ceste		
	V1	V2	V3	V1	V2	V3
1,0%	6,335%	6,946%	5,570%	2,530%	3,146%	1,770%
2,5%	6,536%	7,019%	5,585%	2,723%	3,218%	1,785%
5,0%	6,714%	7,101%	5,602%	2,904%	3,301%	1,802%
10,0%	6,937%	7,217%	5,625%	3,139%	3,417%	1,825%
20,0%	7,219%	7,381%	5,659%	3,420%	3,581%	1,859%
25,0%	7,330%	7,448%	5,672%	3,528%	3,648%	1,872%
50,0%	7,785%	7,729%	5,724%	3,988%	3,929%	1,924%
75,0%	8,246%	8,078%	5,776%	4,442%	4,278%	1,976%
80,0%	8,354%	8,167%	5,789%	4,554%	4,367%	1,989%
90,0%	8,648%	8,388%	5,821%	4,846%	4,588%	2,021%
95,0%	8,875%	8,543%	5,844%	5,071%	4,743%	2,044%
97,5%	9,069%	8,654%	5,860%	5,276%	4,854%	2,060%
99,0%	9,279%	8,751%	5,874%	5,499%	4,951%	2,074%
100,0%	9,745%	8,915%	5,897%	6,071%	5,117%	2,098%
Minimalna vrijednost	5,771%	6,825%	5,547%	1,947%	3,025%	1,747%
Maksimalna vrijednost	9,745%	8,915%	5,897%	6,071%	5,117%	2,098%
Srednja vrijednost	7,789%	7,770%	5,724%	3,989%	3,970%	1,924%

Tablica 22. Analiza vjerojatnosti pojavljivanja utvrđenih vrijednosti primjenom modela vrednovanja (AC)

Model	Stvarna vrijednost			Vjerojatnost pojavljivanja (stvarne ili više vrijednosti)		
	2018.	2019.	Srednja vrijednost	2018.	2019.	Srednja vrijednost
V1				100,000%	100,000%	100,000%
V2	5,45%	4,36%	4,90%	100,000%	100,000%	100,000%
V3				100,000%	100,000%	100,000%

Tablica 23. Analiza vjerojatnosti pojavljivanja utvrđenih vrijednosti primjenom modela vrednovanja (DC)

Model	Stvarna vrijednost			Vjerojatnost pojavljivanja (stvarne ili više vrijednosti)		
	2018.	2019.	Srednja vrijednost	2018.	2019.	Srednja vrijednost
V1				99,960%	97,93%	99,495%
V2	2,13%	2,68%	2,41%	100,000%	100,00%	100,000%
V3				0,000%	0,00%	0,000%

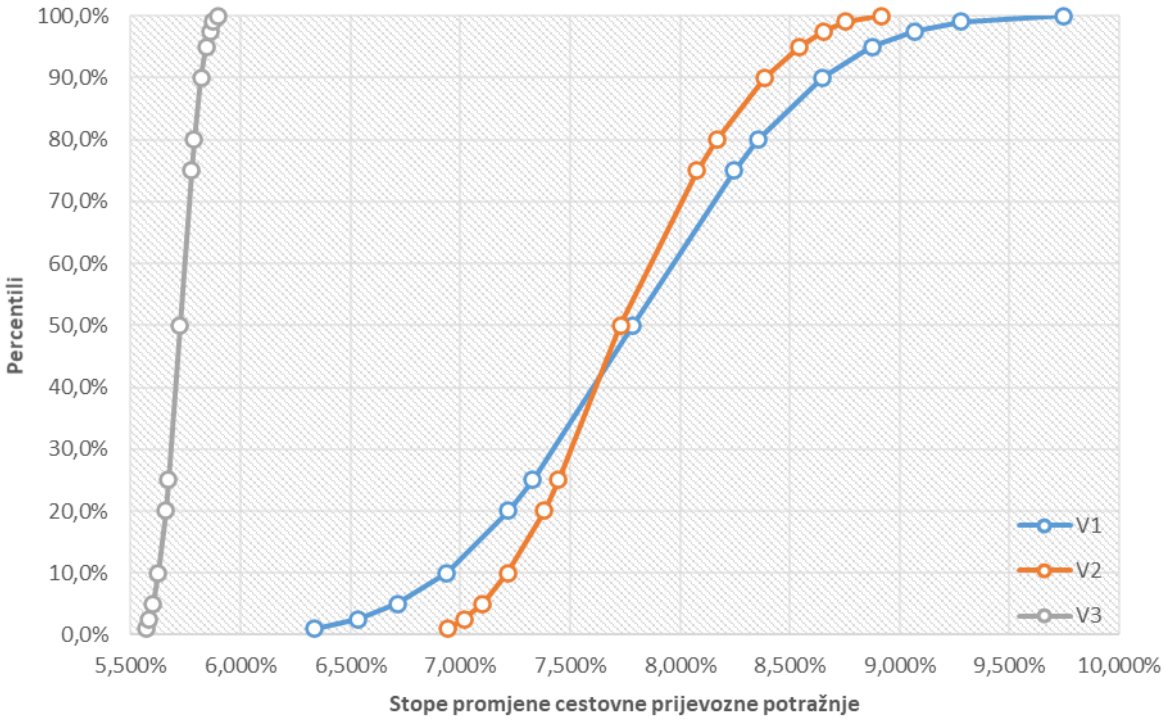

Grafikon 58. Kumulativna distribucija rezultata modela vrednovanja (AC)

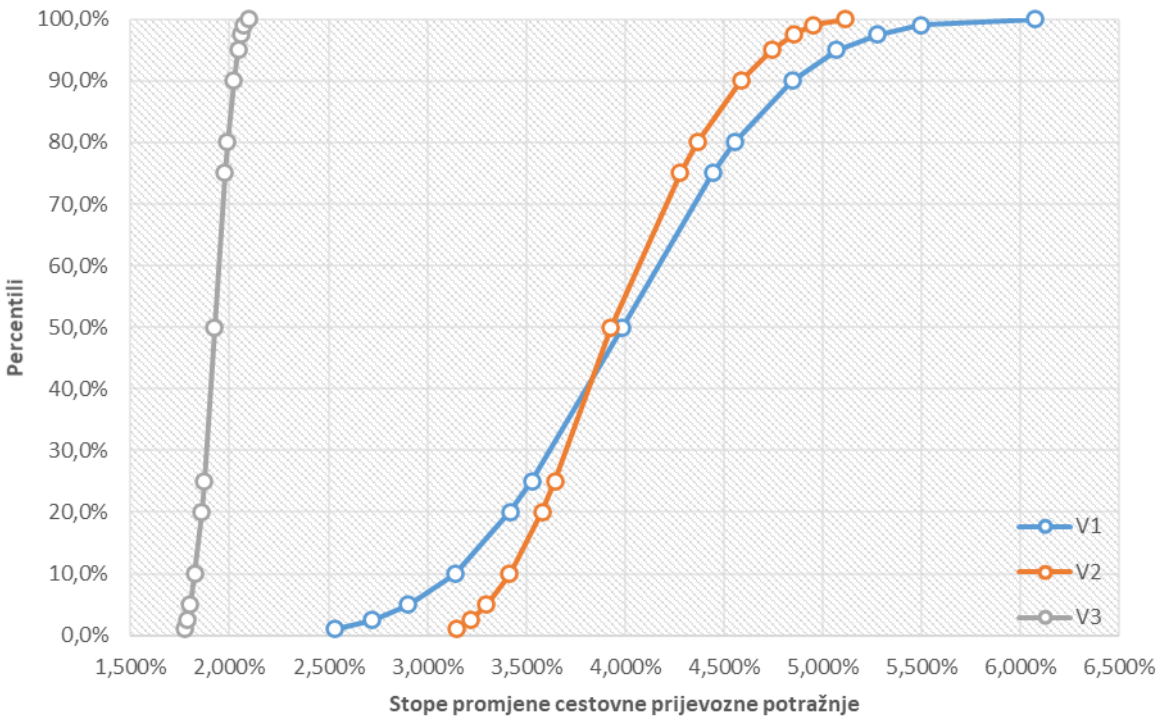

Grafikon 59. Kumulativna distribucija rezultata modela vrednovanja (DC)

Prema dobivenim rezultatima može se zaključiti da se korištenjem kvalitetnijih distribucija/prognostičkih podataka o trendovima nezavisnih varijabli može utjecati na kvalitetu interpretacije rezultata modela vrednovanja te shodno tome provesti kvalitetnije zaključivanje, a napose ako se analiziraju i interpretiraju rezultati sva tri modela kao i trendovi njihovih nezavisnih varijabli.

5.3. Testiranje kvalitete prognoza prijevozne potražnje u Republici Hrvatskoj primjenom modela vrednovanja prognoza prijevozne potražnje

Za potrebe analize točnosti prognoza cestovne prijevozne potražnje u Republici Hrvatskoj primjenom modela vrednovanja prognoza izrađenoga u sklopu ovoga rada, analizirana je točnost 14 prognoza izrađenih u sklopu šest projekata [29]-[36]. Analiza je provedena na način da su:

- utvrđene postotne greške prognoziranih vrijednosti od stvarno utvrđenih vrijednosti te da se
- temeljem modela vrednovanja utvrdila vjerojatnost pojavljivanja prognoziranoga ili većega rezultata prognoze.

Analizom točnosti utvrđeno je da analizirane prognoze u prosjeku odstupaju oko 42% od stvarnih vrijednosti. Ukoliko se odbace velike pogreške, utvrđeno je odstupanje od -42%. Dobiveni rezultati potvrđuju sličan trend netočnosti kao što je to slučaj kod svjetskih istraživanja [40]-[45]. Temeljem analize modela vrednovanja prognoza cestovne prijevozne potražnje (PGDP) utvrđeno je da je u 57% analiziranih slučajeva vjerojatnost pojavljivanja prognozirane vrijednosti manja od 50%, dok je u 86% slučajeva vjerojatnost pojavljivanja prognozirane vrijednosti manja od 85%. Male vjerojatnosti pojavljivanja prognoziranih vrijednosti pokazuju potencijalnu pogrešku te potrebu za dodatnom kontrolom prognoze, što je potvrđeno i izračunom postotne greške prognoza u odnosu na stvarne vrijednosti. Prikaz rezultata nalazi se u tablici 24.

Tablica 24. Analiza točnosti prognoza cestovne prijevozne potražnje u Republici Hrvatskoj (Izvor: [40]-[45], autorova obrada)

Prometnica	Razdoblje	Prognoza prema projektu	Stvarno kretanje potražnje	Postotna greška (u odnosu na stvarnu vrijednost)	Vjerojatnost prema modelu vrednovanja (V1)
Državna cesta D24	2015.-2045.	1,0%	3,20%	-68,75%	41,58%
Državna cesta DC414 (Pelješki most)	2014.-2020.	3,0%	2,83%	6,01%	17,87%
	2020.-2030.	1,3%	--	--	37,54%
	2030.-2040.	0,5%	--	--	48,45%
	2040.-2046.	0,1%	--	--	53,84%
Brza cesta Požega-Pleternica	2002.-2020.	6,0%	0,93%	545,16%	2,45%
Državna cesta DC403	2014.-2034.	1,9%	2,80%	-32,50%	29,88%
HAC i ARZ (Monetizacija)	2012.-2032.	1,5%	3,67%	-59,13%	82,89%
Prometni model RH*					
AC	2013.-2020.	1,50%	4,88%	-69,26%	82,89%
	2020.-2030.	1,00%	--	--	87,18%
	2030.-2040.	1,00%	--	--	87,18%
DC	2013.-2020.	1,70%	2,35%	-27,66%	32,33%
	2020.-2030.	0,73%	--	--	45,35%
	2030.-2040.	1,15%	--	--	39,64%

**procjena autora na temelju opterećenja na prometnoj mreži (prosječne godišnje promjene PGDP-a)*

Za potrebe lakše interpretacije vjerojatnosti pojavljivanja određene vrijednosti kretanja prosječnih godišnjih stopa promjene cestovne prijevozne potražnje (PGDP) provedena je i analiza scenarija kretanja nezavisnih varijabli za rast cestovne prijevozne potražnje od 0,5% do 2,5% (srednja vrijednost približno 1,5%). Predmetne vrijednosti izabrane su kao najčešće korištene vrijednosti prognoziranja prosječnih godišnjih stopa promjene cestovne prijevozne potražnje (PGDP) u Republici Hrvatskoj, a prema analiziranoj literaturi [29]-[36].

Kada su u pitanju autoceste, analizom je utvrđeno da za prosječni rast godišnjih stopa promjene cestovne prijevozne potražnje (PGDP) u iznosu od 1,6% trebaju biti zadovoljeni sljedeći prosječni uvjeti:

- rast broja dolazaka turista (godišnje stope promjene) treba u prosjeku biti 3,02%,
- rast broja cestovnih motornih vozila (godišnje stope promjene) treba u prosjeku biti -0,98%,
- realni rast neto plaće treba u prosjeku biti -0,79 te
- realni rast BDP-a treba u prosjeku biti -2,25%.

Negativne vrijednosti pokazatelja stanja razvoja u Republici Hrvatskoj uz povećan broj dolazak turista pokazuju manju osjetljivost prijevozne potražnje na autocestama na gospodarsko stanje u Republici Hrvatskoj, odnosno veću ovisnost o turističkome i tranzitnome prometu. Isto potvrđuju i rezultati utvrđivanja relevantnih pokazatelja gdje je utvrđeno da stope promjene prijevozne potražnje na autocestama ne prate stope promjene prijevozne potražnje na državnim i županijskim cestama.

Kada su u pitanju državne ceste, analizom je utvrđeno da za prosječni rast godišnjih stopa promjene cestovne prijevozne potražnje (PGDP) u iznosu od 1,5% trebaju biti zadovoljeni sljedeći prosječni uvjeti:

- rast broja dolazaka turista (godišnje stope promjene) treba u prosjeku biti 5,15%,
- rast broja cestovnih motornih vozila (godišnje stope promjene) treba u prosjeku biti 2,54%,
- realni rast neto plaće treba u prosjeku biti 1,64 te
- realni rast BDP-a treba u prosjeku biti 2,34%.

Za razliku od autocesta, promjene intenziteta cestovne prijevoze potražnje na državnim cestama u većoj mjeri ovisi o razvoju Republike Hrvatske, što pokazuju pozitivne vrijednosti svih

nezavisnih varijabli. Dobiveni rezultati također i potvrđuju prosječni rast godišnjih stopa promjene cestovne prijevozne potražnje (PGDP) u razdoblju 2003.-2016. godine od svega oko 0,45%. Naime, u predmetnome razdoblju realni rast BDP-a bio je u prosjeku svega oko 1,11%, a realni rast neto plaća svega 0,98%. Shodno tome, i broj cestovnih motornih vozila (stope promjene) rastao je svega oko 1,5%.

Detaljan prikaz rezultata deskriptivne statistike nezavisnih varijabli u slučaju kretanja zavisne varijable u intervalu od 0,5% do 2,5% nalazi se u tablici 25.

Tablica 25. Rezultati deskriptivne statistike nezavisnih varijabli za kretanje zavisne varijable od 0,5% do 2,5% (model vrednovanja)

	Prosječna godišnja stopa promjene broja turističkih dolazaka	**Prosječna godišnja stopa promjene broja registriranih motornih cestovnih vozila**	**Realni rast neto plaće**	**Realni rast BDP-a**
	Autoceste			
Srednja vrijednost	3,02%	-0,98%	-0,79%	-2,25%
Minimalna vrijednost	-11,93%	-6,45%	-1,53%	-3,64%
Maksimalna vrijednost	16,07%	3,71%	-0,20%	-1,13%
	Državne ceste			
Srednja vrijednost	5,15%	2,54%	1,64%	2,34%
Minimalna vrijednost	-10,28%	-2,64%	1,00%	1,13%
Maksimalna vrijednost	18,30%	7,88%	2,33%	3,64%
Stvarne srednje vrijednosti nezavisnih varijabli (2003.-2016.)	*4,50%*	*1,52%*	*0,98%*	*1,10%*

6. ZAKLJUČNA RAZMATRANJA

Prognoziranje cestovne prijevozne potražnje jedan je od osnovnih koraka prometnoga planiranja. O kvaliteti prognoziranja prijevozne potražnje ne samo da ovisi konačno rješenje, već i sama učinkovitost prometnoga sustava. Za pravilno prognoziranje cestovne prijevozne potražnje novoga projekta u obzir je potrebno uzeti početnu potražnju koju će novi projekt privući, induciranu potražnju koju će novi projekt generirati te trend prijevozne potražnje (prognoza) do kraja planskoga razdoblja projekta. Za početnu i induciranu potražnju karakteristično je da se javljaju u samome početku eksploatacije te su one promjenjive, dok se nove funkcije troška putovanja ne stabiliziraju. S druge strane, trend prijevozne potražnje potrebno je analizirati do kraja planskoga razdoblja projekta. Shodno tome, može se zaključiti da na početnu i induciranu potražnju više utječe kvaliteta samoga rješenja i da se radi o već postojećoj potražnji kod koje dolazi do nove redistribucije. Samim time lakše ju je predvidjeti, odnosno vrednovati. Za razliku od početne i inducirane, prognozirana prijevozna potražnja za dulje razdoblje ne ovisi više o samome rješenju već i o nizu gospodarskih, demografskih i prometnih pokazatelja, što značajno povećava složenost njezinoga prognoziranja i/ili predviđanja.

Složenost prognoziranja i/ili predviđanja cestovne prijevozne potražnje potvrđuju brojni autori kroz svoja istraživanja o točnosti prognoza kao i konstantno kreiranje novih metoda i modela za kvalitetnije prognoziranje. No, unatoč postojanju brojnih istraživanja mnogih autora, razvidno je da su nužne značajnije promjene u procesu prognoziranja prijevozne potražnje, što potvrđuje činjenica da se u proteklih 30, a može se pretpostaviti i 70 godina, točnost prognoza nije značajnije povećala. U prosjeku pogreške prognoza prijevozne potražnje kreću se u rasponu od 20 do 35% u ovisnosti o istraživanju. Analizom minimalnih i maksimalnih vrijednosti utvrđeno je ostvarivanje prognozirane prijevozne potražnje od svega 15% pa do nešto više od 150%. Velik raspon između minimalnih i maksimalnih vrijednosti pokazuje visoku standardnu devijaciju, što dovodi do potkapacitiranja ili prekapacitiranja prometnoga sustava. U konačnici i jedan i drugi slučaj rezultira generiranjem neplaniranih ekonomskih i financijskih gubitaka.

Kada se govori o točnosti prognoza cestovne prijevozne potražnje potrebno je prvo analizirati potencijalne uzroke netočnosti. Naime, ako se iz dosadašnjih istraživanja sublimiraju razlozi i pretpostavke takvih pogrešnih rezultata u prognoziranju cestovne prijevozne potražnje, dolazi se do tri osnovna uzroka. Dugo vremena kao prvi uzrok smatrali su se nekvalitetni ulazni podaci korišteni u postupku prognoziranja koji planeru ne osiguravaju mogućnost za donošenje kvalitetnih prognoza (npr. namjena površine, generacija putovanja, distribucija putovanja i sl.).

Također je važno napomenuti da se kod pozivanja na nekvalitetne ulazne podatke kao uzrok netočnih prognoza prognoziranje najčešće baziralo na rezultatima četverostupanjskoga prometnog modela. Nakon određenoga vremena nekolicina autora potvrđuje da se točnost prognoza značajnije ne mijenja bez obzira na značajan tehnološki napredak kao i napredak samih planera u znanstvenome i stručnome smislu. Potaknuti takvim rezultatima, dolazi se do preispitivanja uzroka netočnosti te se postavlja pretpostavka da se ne radi samo o uzrocima tehničke prirode poput nekvalitetnih ulaznih podataka, već i o uzrocima ljudske, odnosno psihološke prirode. Kao uzrok psihološke prirode navodi se optimistična pristranost planera. Kako su analizom točnosti utvrđeni i slučajevi prognoziranja značajno manjih vrijednost od onih stvarnih, razvidno je da nije uvijek u pitanju optimistična pristranost te je zaključeno da je treći najčešći uzrok političko-ekonomske prirode. Naime, politički pritisak te krivi strateški prikaz projekta kroz neutemeljeno povećanje očekivanih koristi projekta također nerijetko dovodi do niske kvalitete prognoziranih vrijednosti. Na uzroke političko-ekonomske prirode posebna se pažnja pojavljuje kod projekata javnog-privatnoga partnerstva. Prema istraživanjima ovoga rada, u Republici Hrvatskoj mogu se pretpostaviti slični uzroci pogrešaka u prognoziranju cestovne prijevozne potražnje kao i nedostatak ikakve stručne kontrole prometnih projekata koji sadrže prognoze. Naime, prema analizama dostupnih projekata može se zaključiti da se prognoziranje ne koristi kao ključan čimbenik u procesu odlučivanja o učinkovitosti i samoj potrebi pojedinoga prometnog projekta, već se uzima kao formalni dio dokumentacije ili se koristi za prikazivanje veće značajnosti pojedinog projekta za društvo nego što to on doista i jest.

Bez obzira na nepobitnu činjenicu o nužnosti i važnosti prognoziranja u cestovnome prometu, kao i niskoj razini točnosti postojećih modela prognoziranja, nisu ustanovljeni egzaktni modeli za vrednovanje kvalitete prognoza prijevozne potražnje u cestovnome prometu. Naime, upravo jedan od osnovnih razloga olakšane manipulacije prognozama (bilo uzrokovane optimističnosti planera ili političko-ekonomskom prirodom) proizlazi iz otežanoga vrednovanja kvalitete rezultata prognoza. Sukladno tome, istraživanje je ovoga rada usmjereno na utvrđivanje veza kretanja godišnjih stopa promjene intenziteta cestovne prijevozne potražnje s gospodarskim, demografskim i prometnim pokazateljima. Na taj način moguće je kroz rezultat prognoze analizirati gospodarske, demografske i prometne trendove te, shodno tome, lakše zaključiti o vjerojatnosti pojavljivanja određenog rezultata, odnosno kvaliteti prognoze.

U ovome doktorskom radu kao prvi je korak provedeno definiranje relevantnih gospodarskih, demografskih i prometnih pokazatelja za modeliranje prijevozne potražnje u cestovnome prometu. Na temelju rezultata deskriptivne statistike, grafičke analize i analize

korelacije utvrđeno je da na trend prijevozne potražnje najveći utjecaj ima broj registriranih cestovnih motornih vozila (godišnje stope promjene), a zatim realni rast neto plaće (godišnje stope promjene), realne stope rasta BDP-a te broj turističkih dolazaka (godišnje stope promjene). Također je utvrđeno da se stope promjene intenziteta cestovne prijevozne potražnje statistički značajno razlikuju za autoceste i državne ceste, kao i da, ukoliko se ne vrednuje turistička aktivnost, nema statistički značajne razlike prema prostornoj raspodjeli u Republici Hrvatskoj. Isto potvrđuje i činjenica da nije utvrđena statistički značajna razlika stopa rasta BDP-a po županijama. Korelacija s populacijom nije se pokazala statistički značajnom te ima negativan smjer, što je očekivano ukoliko se uzme u obzir da populacija u Republici Hrvatskoj bilježi pad već 15-ak godina. S obzirom na to da se većina dosadašnjih prognostičkih modela cestovne prijevozne potražnje temelji na populaciji, može se zaključiti da se veza između populacije i kretanja cestovne prijevozne potražnje promijenila. Naime, radi se o starijim modelima prema kojima posjedovanje osobnoga vozila nije bila stvar potrebe već prestiža, dok se razvojem motorizacije u novijim vremenima posjedovanje barem jednog vozila u kućanstvu podrazumijeva te se nerijetko posjeduje dva i više vozila. Isto tako, ako se analizira populacija Europske unije od 1992. godine, uočava se da je karakteriziraju migracije koje utječu na ukupno povećanje populacije, dok je smrtnost veća od broja novorođenih. Kada je u pitanju trošak goriva, utvrđen je negativan smjer veze s kretanjem prijevozne potražnje, no ne i značajan utjecaj, što također nije u skladu s dosadašnjim modelima. Na temelju utvrđenih veza gospodarskih, demografskih i prometnih pokazatelja s promjenom intenziteta cestovne prijevozne potražnje potvrđena je prva pomoćna hipoteza o utjecaju tih pokazatelja na trend cestovne prijevozne potražnje.

Nakon utvrđenih relevantnih pokazatelja kreiran je model za prognoziranje prijevozne potražnje u cestovnome prometu. Uzimajući u obzir cilj rada te veze između zavisne i nezavisnih varijabli, za izradu modela korištena je višestruka linearna regresija. Kako se gotovo svi utvrđeni relevantni pokazatelji mogu svrstati u kategoriju gospodarstava s ciljem izbjegavanja multikolinearnosti i kvalitetnijih rezultata kreirana su tri modela (V1, V2 i V3). Prvi model kao nezavisnu varijablu koristi broj registriranih cestovnih motornih vozila (godišnje stope promjene), broj turističkih dolazaka (godišnje stope promjene) i kategoriju prometnice (autocesta ili državna cesta), drugi model koristi realni rast neto plaće (godišnje stope promjene) i kategoriju prometnice (autocesta ili državna cesta), a treći model koristi realne stope rasta BDP-a i kategoriju prometnice (autocesta ili državna cesta).

U drugome su koraku, na temelju kreiranih prognostičkih modela prognoziranja prijevozne potražnje u cestovnome prometu, utvrđenih distribucija njihovih nezavisnih varijabli

te primjenom Monte Carlo metode, kreirani modeli vrednovanja rezultata prognoza prijevozne potražnje u cestovnome prometu. Testiranje uspješnosti kreiranih modela vrednovanja provedeno je na način da se analizirala uspješnost modela vrednovanja za utvrđivanje vrijednosti nezavisnih varijabli potrebnih za pojavljivanje stvarnoga kretanja cestovne prijevozne potražnje u razdoblju od 2017. do 2019. godine (prosječne godišnje stope promjene intenziteta cestovne prijevozne potražnje (PGDP)) koji nisu korišteni za izradu modela. Temeljem rezultata uspješnosti utvrđeno je da su odstupanja u skladu s rezultatima statističkih pokazatelja kvalitete pojedinih modela. Rezultati također ukazuju da modeli vrednovanja bilježe manja odstupanja za vrednovanje prognoza u duljemu razdoblju te su nešto kvalitetniji za analizu na državnim cestama u odnosu na autoceste. Na temelju kreiranih modela i rezultata uspješnosti potvrđena je druga pomoćna hipoteza rada da se objedinjavanjem deterministčkih modela kretanja povijesnih gospodarskih, demografskih i prometnih pokazatelja u jedinstveni stohastički model može provesti vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu.

Uz testiranje uspješnosti provedene su i dodatne dvije analize s ciljem testiranja mogućnosti izrađenih modela vrednovanja. Prva dodatna analiza odnosi se na vrednovanje rezultata prognoza koristeći druge utvrđene/prognozirane/predviđene distribucije nezavisnih varijabli u određenome razdoblju prognoze. Cilj predmetne analize utvrđivanje je kvalitete modela vrednovanja u slučaju promijene distribucije nezavisnih varijabli i/ili u slučaju posjedovanja kvalitetnih prognostičkih podataka nezavisnih varijabli. Druga dodatna analiza se odnosi na vjerojatnost pojavljivanja (vrednovanje) utvrđene najčešće korištene prognoze prijevozne potražnje u cestovnome prometu u Republici Hrvatskoj. Svrha te analize utvrđivanje je točnosti prognoziranja cestovne prijevozne potražnje u Republici Hrvatskoj u odnosu na ostvarene vrijednosti, kao i svjetsku praksu. Prema dobivenim rezultatima prve dodatne analize može se zaključiti da se korištenjem kvalitetnijih distribucija/prognostičkih podataka o trendovima nezavisnih varijabli u budućemu razdoblju može značajno utjecati na kvalitetu interpretacije rezultata modela vrednovanja te shodno tome pravilno zaključivanje, a posebice ukoliko se analiziraju i interpretiraju rezultati sva tri modela kao i trendovi nezavisnih varijabli. Druga provedena analiza pokazuje da je prema modelima vrednovanja u 57% analiziranih prognoza vjerojatnost pojavljivanja prognozirane vrijednosti manja od 50%, dok je u 86% analiziranih prognoza vjerojatnost pojavljivanja prognozirane vrijednosti manja od 85%. Prema modelima vrednovanja, male vjerojatnosti pojavljivanja prognoziranih vrijednosti potvrđuju nužnost provođenja detaljnih analiza izrađenih prognoza. Isto potvrđuje i činjenica da

analizirane prognozirane vrijednosti u prosjeku odstupaju 42% od stvarnih vrijednosti. Prema rezultatima uspješnosti modela kao i provedenih testiranja kvalitete, može se zaključiti da je potvrđena prikladnost primjene modela kao i glavna hipoteza rada da je temeljem podataka o gospodarskim, demografskim i prometnim pokazateljima moguće provesti vrednovanje rezultata prognoza prijevozne potražnje u cestovnome prometu.

U odnosu na postojeće modele u svijetu kao i u Republici Hrvatskoj, kreirani model vrednovanja rezultata prognoza prijevozne potražnje u cestovnom prometu omogućuje provođenje analize vjerojatnosti pojavljivanja određenog prognoziranog scenarija cestovne prijevozne potražnje. Naime, dosadašnji modeli prognoziraju trend cestovne prijevozne potražnje bez uvida u vjerojatnost pojavljivanja prognoziranog ishoda. Osim toga, u postupku izrađivanja modela vrednovanja kao i modela prognoziranja utvrđene su promjene u dosad utvrđenoj vezi između populacije i kretanja cestovne prijevozne potražnje. Također je utvrđeno da cijena goriva nema statistički značajan utjecaj na trend cestovne prijevozne potražnje što kod nekolicine dosadašnjih modela prognoziranja cestovne prijevozne potražnje nije slučaj. Uz navedeno, u sklopu rada su izrađene tri varijante modela vrednovanja što smanjuje vjerojatnost pogrešnog zaključivanja te olakšava samu uporabu modela.

Buduća istraživanja trebaju biti usmjerena na mogućnost uvođenja dodatnih parametara koji će imati utjecaj na povećanje točnosti izrađenih modela. Isto tako, kroz istraživanje je utvrđeno da nije isti trend prijevozne potražnje na autocestama i državnim cestama te je potrebno razmotriti parametre koji će kvalitetnije opisati promjene na autocestama. Uz navedeno, a uzimajući u obzir da se kreirani modeli temelje na trendovima prijevozne potražnje izvan urbanih sredina, također je potrebno buduća istraživanja posvetiti prognozama u urbanim sredinama sa značajnije razvijenim javnim prijevozom. Naime, na trendove cestovne prijevozne potražnje u urbanim sredinama prometna politika može imati značajan utjecaj bez obzira na gospodarske pokazatelje, primjerice poticanje će javnog prijevoza također imati značajan utjecaj na trend prijevozne potražnje u cestovnome prometu. Shodno tome, potrebno je istražiti i kvantificirati veze između pojedinih mjera prometne politike i stopa promjene cestovne prijevozne potražnje.

LITERATURA

[1] Prasch RE. *How Markets Work, Supply, Demand and the „Real World“.* Cheltenham, UK: Edward Elgar Publishing Limited; 2008.

[2] Ortuzar JD, Willumsen LG. *Modelling Transport.* 4th ed. UK: John Wiley & Sons, Ltd; 2011.

[3] Ison S, Rye T. *The Implementation and Effectiveness of Transport Demand Management Measures.* Aldershot, UK: Ashgate Publishing Limited; 2008.

[4] Cron FW. Highway Design for Motor Vehicles – An Historical Review, Part 4: The Vehicle Carrying of the Highway. *Public Roads*. 1975.; 39(3): 96-108.

[5] Weiner E. *Urban Transport Planning in the United States: An Historical Overview.* 5th ed. Westport, UK: Praeger Publishers; 1999.

[6] Hogarth R, Makridakis S. Forecasting and Planning: An Evaluation. *Management Science*. 1981.; 27(2): 115-138.

[7] Korte JV. *Osnovi projektovanja gradskog i međugradskog putnog saobraćaja.* Beograd SR: Građevinska knjiga; 1968.

[8] Nevada Department of Transportation. *Traffic Forecasting Guidelines.* Nevada Department od Transportation. 2012.

[9] Nunez A. *Sources of Errors and Biases in Traffic Forecasts for Toll Road Concessions*. PhD thesis. Lyon, F: Lumière University Lyon 2, 2007.

[10] Næss P, Nicolaisen MS, Strand A. Traffic Forecasts Ignoring Induced Demand: a Shaky Fundament for Cost-Benefit Analyses. *European Journal of Transport and Infrastructure Research*. 2012.; 12(3): 291-309.

[11] Mackie P. Cost-Benefit Analysis in Transport: A UK Perspective. *OECD/ITF Joint Transport Research Centre Discussion Papers, 2010., Mexico*. OECD Publishing

[12] American Association of State Highway Officials. *A policy on arterial highways in urban areas.* Washington, USA: American Association of State Highway Officials; 1973.

[13] Goodwin P. Empirical evidence on induced traffic: A review and synthesis. *Transportation*. 1996.; 23(1): 35-54.

[14] Litman T, Colman, SB. Generated Traffic: Implications for Transport Planning. *Institute of Transportation Engineers Journal*. 2001.; 71(4): 38-47.

[15] Nicolaisen MS, Næss P. Vejenes virkelige værdi. *Trafik og Veje*, 2011.; 88(10): 44-46.

[16] Kuzović Lj, Topolnik D, Glavić D. Induced Traffic and its Treatment in the Evaluation of Motorway Projects. *Promet – Traffic & Transportation*. 2010.; 22(6): 459-465.

[17] Putman SH. Urban Land Use and Transportation Models: A State-of-the-Art Summary. *Transportation Research*. 1975.; 9(2-3): 187-202.

[18] Meyer M, Miller E. *Urban Transportation Planning:A Decision-Oriented Approach*, 2nd ed., New York, NY: McGraw–Hill; 2001.

[19] Kriger D, Shiu S, Naylor S. *Estimating Toll Road Demand and Revenue.* Transportation Research Board. Report number: NCHRP synthesis 364, 2006.

[20] National Transportation Systems Center. Expert Forum on Road Pricing and Travel Demand Modeling Proceedings. U.S. Department of Transportation. Report number: DOT-OST/P-001-06, 2006.

[21] Prozzi J, Flanagan K, Loftus-Otway L, Porterfield B, Persad K, Prozzi JA, Walton CM. *Actual vs. Forecasted Toll Usage: A Case Study* Review. Center for Transportation Research, The Univesity of Texas at Austin. Report number: FHWA/TX-10/0-6044-1, 2009.

[22] Hunkin P, McPherson C. *Critical review of transport modelling Tolls.* Sinclair Knight Merz, Report number: V5 – Final Report, 2009.

[23] Fricker JD, Saha SK. *Traffic Volume Forecasting Methods for Rural State Highways.* The Federal Highway Administration. Report number: FHWA/IN/JHRP-86-20, 1987.

[24] Prevedouros P, Halkias BM. Expressway Traffic Demand Forecasts in the Volatile Economic Environment of Greece. *Transportation Research Procedia.* 2006.; 15: 607-619.

[25] Pupovac D. Econometric Model for Forecasting Traffic on Croatian Motorways. *Interdisciplinary Management Research X, 16 – 18 May 2014., Opatija, Croatia.* Osijek, CR: Faculty of Economics in Osijek, Hochschule Pforzheim University; 2014. p. 907-918.

[26] Bain Flyvbjerg B, Skamris Holm MK, Buhl SL. Inaccuracy in Traffic Forecasts. *Transport Reviews*. 2006.; 26(1): 1-24.

[27] Flyvbjerg B. Curbing Optimism Bias and Strategic Misrepresentation in Planning: Reference Class Forecasting in Practice. *European Planning Studies*. 2007.; 16(1): 3-21.

[28] Flyvbjerg B. Policy and Planning for Large-Infrastructure Projects: Problems, Causes, Cures. *Environment and Planning B: Planning and Design.* 2007.; 34(4): 578-579.

[29] Institut IGH d.d. *Brza cesta Varaždin-Ivanec-Krapina, Studija utjecaja na okoliš i glavna ocjena.* Institut IGH d.d. Zagreb, 2012.

[30] IRES Institut za istraživanje i razvoj održivih ekosustava. *Studija o utjecaju zahvata na okoliš – most Tuhovec.* IRES Institut za istraživanje i razvoj održivih ekosustava. Zagreb, 2015.

[31] Inženjerski projektni zavod d.d. *Studija utjecaja na okoliš za zahvat: Državna cesta DC414 – Sparagovići – Doli.* Inženjerski projektni zavod d.d. Zagreb, 2015.

[32] Institut IGH d.d. *Studija utjecaja na okoliš za most kopno-Pelješac s pristupnim cestama.* Institut IGH d.d. Zagreb, 2015.

[33] DVOKUT ECRO d.o.o. *Studija o utjecaju na okoliš brze ceste Platernica-Požega-Brestovc.* DVOKUT ECRO d.o.o. Zagreb, 2018.

[34] Rijekaprojekt d.o.o. *Studija utjecaja na okoliš – Državna cesta DC403 od čvora Škurinje do luke Rijeka.* Rijekaprojekt d.o.o. Zagreb, 2017.

[35] Erste Bank AG, Deloitte, Wolf Theiss Rechtsanwalte GmbH, ASFiNAG International. *Monetizacija javnog duga vezano za društva HAC i ARZ, Nacrt konačnog izvješća u Fazi 1*. Ministarstvo mora, prometa i infrastrukture. Zagreb, 2013. Dostupno na: http://www.mppi.hr/UserDocsImages/Monetizacija%20AC%20FIN-NCR%20MPPI%206-6%2024-10_13.pdf [Pristupljeno 24. 09. 2018.]

[36] PTV Transport Consult GmbH. *National Transport Model for the Republic of Croatia – Model Development Report*. NTM Croatia Consortium. Report number. 2.0 – Final, 2016.

[37] Flyvbjerg B, Bruzelius N, Rothengatter W. *Megaprojects and Risk: An Anatomy of Ambition.* Cambridge, UK: Cambridge University Press; 2003.

[38] http://roadpricing.blogspot.com/2016/08/australian-toll-road-lawsuit-successful.html [Pristupljeno 24. 09. 2018.]

[39] National Audit Office, Department of Transport, Scottish Development Department, Welsh Office. *Road planning*. London: Her Majesty's Stationary Office. 1988.

[40] Bain R, Wilkins M. *The Credit Implications of Traffic Risk in Start-Up Toll facilities*. London, UK: Standard & Poor's; 2002.

[41] Bain R, Plantagie JW. *Traffic Forecasting Risk Study Update 2003.* London, UK: Standard & Poor's; 2003.

[42] Bain R, Plantagie JW. *Traffic Forecasting Risk Study Update 2004.* London, UK: Standard & Poor's; 2004.

[43] Bain R, Polakovic L. *Traffic Forecasting Risk Study Update 2005: Through Ramp-Up and Beyond*, London, UK: Standard & Poor's; 2005.

[44] Flyvbjerg B, Holm MKS, Buhl SL. How (In)accurate Are Demand Forecasts in Public Works Projects, *Journal of the American Planning Association*. 2005.; 71(2): 131-146.

[45] Li Z, Hensher DA. Toll Roads in Australia: An Overview of Characteristics and Accuracy of Demand Forecasts. *Transport Reviews*. 2010; 30(5): 541-569.

[46] Pendyala RM. Modeling Pricing in the Planning Process. *Expert Forum on Road Pricing and Travel Demand Modeling, 14-15 November 2005., Alexandria, Virginia.* Washingtovn, DC, USA: U.S. Department of Transportation; 2005.

[47] Bain R. *Toll Road Traffic & Revenue Forecasts – An Interpreter's Guide, Credit Risk Analysis*. Seville, SA: Publicaciones Digitales; 2009.

[48] Vassallo JM. *Why Traffic Forecasts in PPP Contracts are Often Overestimated?* Research Paper, EIB University Research Sponsorship Programme. Luxembourg, 2007.

[49] https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:02003R1059-20180118&from=EN [Pristupljeno 13. 08. 2020.]

[50] https://hrvatske-ceste.hr/hr/stranice/promet-i-sigurnost/dokumenti/14-brojenje-prometa [Pristupljeno 24. 09. 2019.]

[51] R. Lyman Ott and Michael Longnecker: *An Introduction to Statistical Methods and Data Analysis*, Sixth Edition, 2008.

[52] Ministarstvo mora, prometa i infrastrukture. *Strategija prometnog razvoja Republike Hrvatske za razdoblje od 2017. do 2030. godine*, Ministarstvo mora, prometa i infrastrukture, Republika Hrvatska, Zagreb, 2017.

[53] https://www.dzs.hr/Hrv/system/stat_databases.htm [Pristupljeno 24. 09. 2019.]

[54] https://ec.europa.eu/eurostat/data/database?node_code=hlth [Pristupljeno 24. 09. 2019.]

[55] Ministarstvo zaštite okoliša i energetike. *Energija u Hrvatskoj*, Ministarstvo zaštite okoliša i energetike, Republika Hrvatska, Zagreb, 2017.

[56] Delft, INFRAS, Fraunhofer ISI: *External cost of transport in Europe, Update Study for 2008*, Delft, CE Delft, September 2011.

[57] Korte, J. W.: Grundlagen der Strassenverkehrsplanung in Stadt und Land, Aachen, 1957.

[58] European Commission. Guide to Cost-Benefit Analysis of Investment Projects Economic appraisal tool for Cohesion Policy 2014 – 2020, European Commission, December 2014

[59] Denzin, N. K., & Lincoln, Y. S. (Eds.). *Handbook of qualitative research.* Sage Publications, Inc., 1994

[60] Chamber J. C., Mullick S. K, Smith D. D. *How to Choose the Right Forecasting Technique*. Harvard Business Review, 1971.

[61] Thomopoulos N. T. Essentials of Monte Carlo Simulation: Statistical Methods for Building Simulation Models. 2013th Edition, Springer, 2013

[62] Evans, J. R., David L. O.: *Introduction to Simulation and Risk Analysis*, Upper Saddle River, Prentice Hall, Inc., 1998.

PRILOZI

1. BDP, BDP po stanovniku i stope promjene BDP-a po stanovniku za statističku regiju NUTS 3
2. Ukupno zaposlenih i stope registrirane nezaposlenosti za statističke regije NUTS 3
3. Dolasci, noćenja i njihove stope promjene za statističke regije NUTS 3
4. Populacije te stope promjene populacije za statističke regije NUTS 3
5. Aktivno stanovništvo za statističke regije NUTS 3
6. Broj registriranih cestovnih motornih i osobnih vozila za statističke regije NUTS 3
7. Vrijednosti zavisnih i nezavisnih varijabli korištenih za izradu prognostičkoga modela prijevozne potražnje u cestovnome prometu

Prilog 1. BDP, BDP po stanovniku i stope promjene BDP-a po stanovniku za statističku regiju NUTS 3

	BDP [HRK]												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	77.494.847	86.020.432	94.131.174	101.997.827	111.041.765	105.965.457	111.002.593	111.742.968	110.804.181	110.199.819	110.500.627	113.198.655	115.962.559
Zagrebačka	13.874.754	15.506.160	15.958.051	18.082.801	19.458.139	19.144.010	17.944.416	18.702.033	18.666.508	18.877.677	19.312.630	19.917.445	20.541.202
Krapinsko-zagorska	5.468.029	6.064.181	6.306.570	6.983.680	7.070.088	6.401.103	6.005.177	6.188.012	6.187.764	6.356.022	6.520.453	6.760.633	7.009.660
Varaždinska	8.743.382	9.136.623	9.874.328	10.690.123	11.916.147	11.442.922	10.726.430	10.904.318	10.931.925	11.189.681	11.279.698	11.614.283	11.958.792
Koprivničko-križevačka	6.589.949	6.675.191	7.790.915	8.136.416	8.049.434	8.365.690	7.710.632	8.031.330	7.906.756	7.641.209	7.497.695	7.518.926	7.540.218
Međimurska	5.194.707	5.503.473	6.211.047	6.600.871	7.539.679	7.219.907	6.931.192	7.152.274	7.205.381	7.317.508	7.546.961	7.737.336	7.932.514
Bjelovarsko-bilogorska	5.193.185	5.253.419	5.985.417	6.036.552	7.027.915	6.840.328	6.213.509	6.247.902	6.102.294	6.067.357	6.234.918	6.359.237	6.486.036
Virovitičko-podravska	3.553.649	3.582.585	4.123.548	4.409.069	4.522.831	4.073.490	3.848.878	3.984.292	3.905.514	3.813.751	3.565.886	3.593.049	3.620.420
Požeško-slavonska	3.382.493	3.465.527	3.534.820	3.743.551	4.016.308	3.723.009	3.674.965	3.627.801	3.515.706	3.523.538	3.352.778	3.394.826	3.437.401
Brodsko-posavska	5.846.850	5.765.351	6.301.150	6.808.739	7.540.911	7.035.518	6.809.772	6.948.457	6.920.425	6.949.178	6.690.804	6.864.292	7.042.278
Osječko-baranjska	14.117.918	15.328.772	16.708.811	19.323.873	20.697.689	19.529.011	18.453.156	18.876.644	18.445.786	18.608.473	18.466.406	18.859.295	19.260.544
Vukovarsko-srijemska	6.505.709	6.964.388	8.023.834	8.297.574	9.243.619	8.682.140	8.089.154	8.265.914	7.994.220	8.032.867	7.825.656	8.044.874	8.270.232
Karlovačka	5.818.905	6.180.595	6.920.054	7.699.168	8.040.041	7.338.839	7.141.065	7.368.919	7.250.817	7.374.665	7.234.909	7.441.597	7.654.191
Sisačko-moslavačka	7.645.801	8.259.627	9.446.891	9.087.927	10.331.352	10.260.129	10.264.993	10.542.793	10.353.337	9.920.429	9.297.673	9.438.368	9.581.193
Primorsko-goranska	19.914.721	22.287.095	23.997.309	25.621.704	28.945.151	27.156.013	27.085.693	27.779.233	29.115.569	28.931.992	28.339.303	28.363.686	28.388.090
Ličko-senjska	3.937.518	3.044.436	3.155.756	3.081.584	3.581.605	3.285.361	3.090.577	3.032.074	2.906.548	2.917.882	2.911.733	2.959.032	3.007.099
Zadarska	7.920.979	8.685.122	9.113.360	10.650.740	11.785.750	10.915.021	10.473.365	10.493.075	10.496.662	10.635.900	10.800.664	11.157.786	11.526.716
Šibensko-kninska	4.951.101	5.568.344	5.631.169	6.683.374	6.779.187	5.990.728	6.313.848	6.416.359	6.356.170	6.478.745	6.538.523	6.582.334	6.626.439
Splitsko-dalmatinska	21.675.811	22.623.209	25.039.027	28.865.932	29.770.842	27.920.093	27.722.943	27.543.317	26.959.290	27.163.698	27.336.659	28.250.708	29.195.321
Istarska	16.399.608	16.980.547	18.198.914	20.017.637	20.577.258	20.329.083	20.241.277	20.464.174	19.816.765	20.065.247	20.401.727	20.942.277	21.497.150
Dubrovačko-neretvanska	6.643.274	7.296.070	7.984.848	9.490.498	9.749.291	9.347.899	9.199.204	9.014.040	9.083.520	9.308.754	9.610.682	9.976.403	10.356.041

Prilog 1. Nastavak

	BDP po stanovniku [HRK]												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	99.988	110.726	120.934	130.628	141.756	134.818	140.768	141.309	139.729	138.532	138.397	141.379	144.426
Zagrebačka	45.412	50.354	51.431	57.890	61.927	60.618	56.605	58.837	58.613	59.235	60.679	62.890	65.182
Krapinsko-zagorska	39.922	44.437	46.397	51.689	52.606	47.786	45.009	46.644	46.938	48.537	50.146	52.405	54.765
Varaždinska	48.933	51.229	55.448	60.140	67.195	64.704	60.821	62.013	62.390	64.156	65.060	67.506	70.045
Koprivničko-križevačka	55.088	56.064	65.758	69.039	68.593	71.640	66.404	69.551	68.836	66.832	66.028	66.894	67.772
Međimurska	45.535	48.249	54.475	57.956	66.255	63.436	60.875	62.864	63.417	64.520	66.745	68.706	70.725
Bjelovarsko-bilogorska	40.896	41.676	47.865	48.716	57.212	56.138	51.465	52.314	51.664	51.931	53.990	55.868	57.811
Virovitičko-podravska	39.396	40.076	46.475	50.126	51.846	47.161	45.049	47.064	46.575	45.935	43.457	44.528	45.625
Požeško-slavonska	41.053	42.288	43.406	46.300	50.023	46.788	46.692	46.647	45.830	46.480	44.734	46.119	47.546
Brodsko-posavska	35.761	35.358	38.743	41.997	46.664	43.768	42.688	43.875	44.005	44.593	43.472	45.368	47.347
Osječko-baranjska	44.613	48.633	53.308	62.088	66.903	63.402	60.219	61.949	60.891	61.855	61.926	64.019	66.182
Vukovarsko-srijemska	34.766	37.412	43.323	44.980	50.264	47.477	44.662	46.126	45.013	45.709	45.237	47.446	49.764
Karlovačka	42.448	45.434	51.293	57.551	60.598	55.872	54.963	57.348	57.091	58.734	58.388	60.932	63.585
Sisačko-moslavačka	41.093	44.717	51.606	50.176	57.708	58.016	58.843	61.327	61.112	59.512	56.778	58.777	60.848
Primorsko-goranska	67.133	75.053	80.707	86.065	97.245	91.328	91.221	93.784	98.548	98.181	96.480	97.177	97.880
Ličko-senjska	71.384	55.638	58.342	57.513	67.601	62.892	60.091	59.808	58.225	59.258	59.958	62.058	64.232
Zadarska	49.411	53.527	55.440	64.036	70.233	64.632	61.727	61.574	61.356	62.013	63.048	65.475	67.995
Šibensko-kninska	44.700	50.144	50.538	59.864	60.711	53.824	57.239	58.870	59.071	60.911	62.018	63.095	64.191
Splitsko-dalmatinska	48.681	50.405	55.480	63.712	65.540	61.365	60.910	60.536	59.262	59.706	60.128	62.290	64.529
Istarska	81.257	83.515	88.836	96.976	99.119	97.561	97.071	98.334	95.394	96.584	98.049	100.635	103.290
Dubrovačko-neretvanska	56.017	61.190	66.556	78.597	80.200	76.391	74.976	73.536	74.164	76.083	78.570	81.554	84.651

Prilog 1. Nastavak

	Stope promjene BDP-a po stanovniku [%]												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	8,95%	10,74%	9,22%	8,02%	8,52%	-4,89%	4,41%	0,38%	-1,12%	-0,86%	-0,10%	2,15%	2,15%
Zagrebačka	8,56%	10,88%	2,14%	12,56%	6,97%	-2,11%	-6,62%	3,94%	-0,38%	1,06%	2,44%	3,64%	3,64%
Krapinsko-zagorska	2,49%	11,31%	4,41%	11,41%	1,77%	-9,16%	-5,81%	3,63%	0,63%	3,41%	3,31%	4,50%	4,50%
Varaždinska	-1,52%	4,69%	8,23%	8,46%	11,73%	-3,71%	-6,00%	1,96%	0,61%	2,83%	1,41%	3,76%	3,76%
Koprivničko-križevačka	-0,42%	1,77%	17,29%	4,99%	-0,65%	4,44%	-7,31%	4,74%	-1,03%	-2,91%	-1,20%	1,31%	1,31%
Međimurska	4,39%	5,96%	12,90%	6,39%	14,32%	-4,25%	-4,04%	3,27%	0,88%	1,74%	3,45%	2,94%	2,94%
Bjelovarsko-bilogorska	5,53%	1,91%	14,85%	1,78%	17,44%	-1,88%	-8,32%	1,65%	-1,24%	0,52%	3,96%	3,48%	3,48%
Virovitičko-podravska	2,10%	1,73%	15,97%	7,86%	3,43%	-9,04%	-4,48%	4,47%	-1,04%	-1,37%	-5,39%	2,46%	2,46%
Požeško-slavonska	6,29%	3,01%	2,64%	6,67%	8,04%	-6,47%	-0,21%	-0,10%	-1,75%	1,42%	-3,76%	3,10%	3,10%
Brodsko-posavska	8,07%	-1,13%	9,57%	8,40%	11,11%	-6,20%	-2,47%	2,78%	0,29%	1,34%	-2,51%	4,36%	4,36%
Osječko-baranjska	9,44%	9,01%	9,61%	16,47%	7,75%	-5,23%	-5,02%	2,87%	-1,71%	1,58%	0,11%	3,38%	3,38%
Vukovarsko-srijemska	5,00%	7,61%	15,80%	3,83%	11,75%	-5,55%	-5,93%	3,28%	-2,41%	1,55%	-1,03%	4,88%	4,88%
Karlovačka	1,85%	7,03%	12,89%	12,20%	5,30%	-7,80%	-1,63%	4,34%	-0,45%	2,88%	-0,59%	4,36%	4,36%
Sisačko-moslavačka	3,95%	8,82%	15,41%	-2,77%	15,01%	0,53%	1,43%	4,22%	-0,35%	-2,62%	-4,59%	3,52%	3,52%
Primorsko-goranska	5,24%	11,80%	7,53%	6,64%	12,99%	-6,08%	-0,12%	2,81%	5,08%	-0,37%	-1,73%	0,72%	0,72%
Ličko-senjska	34,72%	-22,06%	4,86%	-1,42%	17,54%	-6,97%	-4,45%	-0,47%	-2,65%	1,77%	1,18%	3,50%	3,50%
Zadarska	5,16%	8,33%	3,58%	15,50%	9,68%	-7,97%	-4,49%	-0,25%	-0,35%	1,07%	1,67%	3,85%	3,85%
Šibensko-kninska	11,78%	12,18%	0,79%	18,45%	1,42%	-11,34%	6,35%	2,85%	0,34%	3,12%	1,82%	1,74%	1,74%
Splitsko-dalmatinska	12,94%	3,54%	10,07%	14,84%	2,87%	-6,37%	-0,74%	-0,61%	-2,10%	0,75%	0,71%	3,59%	3,59%
Istarska	8,65%	2,78%	6,37%	9,16%	2,21%	-1,57%	-0,50%	1,30%	-2,99%	1,25%	1,52%	2,64%	2,64%
Dubrovačko-neretvanska	16,17%	9,23%	8,77%	18,09%	2,04%	-4,75%	-1,85%	-1,92%	0,85%	2,59%	3,27%	3,80%	3,80%

Prilog 2. Ukupno zaposlenih i stope registrirane nezaposlenosti za statističke regije NUTS 3

	Ukupno zaposleni												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	370.565	371.524	388.581	406.711	421.585	424.263	408.864	397.365	398.890	390.469	383.967	389.888	401.642
Zagrebačka	76.685	78.402	81.517	83.409	85.924	85.251	79.734	76.619	75.596	74.351	73.103	76.605	78.909
Krapinsko-zagorska	37.760	36.837	37.456	38.303	38.888	37.258	34.843	34.198	33.510	32.878	32.809	33.326	33.935
Varaždinska	61.184	61.113	62.598	64.621	66.114	63.366	60.422	59.497	59.426	58.070	58.177	59.259	61.123
Koprivničko-križevačka	38.484	37.641	38.426	38.652	38.736	37.087	33.824	33.438	32.494	30.671	29.819	29.818	29.858
Međimurska	37.189	36.257	37.540	39.062	40.240	39.109	36.304	36.432	35.431	35.830	35.200	35.392	36.675
Bjelovarsko-bilogorska	35.890	34.975	35.396	35.950	36.462	34.906	32.041	31.636	31.046	30.462	28.983	28.683	28.441
Virovitičko-podravska	23.901	23.520	23.361	23.857	24.240	23.091	21.628	20.790	19.800	19.515	18.837	18.294	18.734
Požeško-slavonska	21.648	21.700	20.829	20.797	20.967	20.002	18.804	18.105	17.648	16.885	16.754	16.754	17.270
Brodsko-posavska	38.158	37.117	38.486	40.108	41.427	39.619	35.762	34.739	33.906	32.658	31.640	31.973	32.454
Osječko-baranjska	88.028	88.174	91.738	94.569	97.203	94.134	86.733	87.035	86.146	80.960	77.092	76.556	77.229
Vukovarsko-srijemska	41.163	41.723	43.358	45.593	46.683	45.378	42.838	42.332	41.711	40.259	38.101	38.399	38.696
Karlovačka	37.152	37.720	38.749	40.112	41.157	38.913	36.437	35.806	34.893	34.619	34.454	33.786	33.697
Sisačko-moslavačka	44.973	45.051	45.991	47.625	47.919	45.121	42.904	42.472	41.024	39.842	38.421	37.550	36.818
Primorsko-goranska	110.407	111.366	113.908	117.332	118.109	115.793	110.363	106.985	105.738	103.101	99.958	100.844	101.268
Ličko-senjska	15.163	13.668	13.515	13.525	14.117	14.074	13.398	13.008	13.136	12.976	12.897	12.887	12.860
Zadarska	41.883	43.745	44.312	46.520	48.162	47.281	45.036	44.727	44.596	43.443	43.574	44.133	43.808
Šibensko-kninska	26.469	27.460	29.717	29.848	31.308	30.229	28.176	27.628	27.830	27.807	27.552	27.706	27.390
Splitsko-dalmatinska	134.095	134.941	138.692	141.847	146.500	144.901	138.581	136.026	133.598	129.140	128.195	128.528	129.166
Istarska	79.361	80.759	83.867	86.843	89.241	84.550	81.249	78.232	78.481	76.047	75.351	75.363	76.646
Dubrovačko-neretvanska	36.241	36.951	38.366	39.755	41.184	40.685	39.512	38.462	38.261	37.653	37.678	37.082	38.293

Prilog 2. Nastavak

	Stopa registrirane nezaposlenosti [%]												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	9,66%	9,97%	9,15%	7,80%	6,19%	6,30%	8,37%	9,43%	9,50%	10,75%	11,20%	9,62%	8,23%
Zagrebačka	15,19%	15,40%	14,22%	12,90%	10,60%	11,65%	16,31%	18,02%	18,58%	21,45%	21,90%	18,17%	15,15%
Krapinsko-zagorska	13,42%	14,87%	13,96%	12,10%	9,62%	11,67%	16,44%	18,23%	19,75%	21,26%	21,10%	17,75%	14,59%
Varaždinska	15,05%	15,03%	13,60%	11,60%	9,76%	11,19%	14,12%	14,96%	15,35%	16,91%	15,80%	12,35%	9,54%
Koprivničko-križevačka	17,54%	18,51%	16,98%	16,10%	13,98%	14,27%	18,64%	18,68%	20,42%	23,91%	24,40%	19,74%	16,71%
Međimurska	16,83%	17,02%	15,84%	14,00%	11,56%	12,72%	16,60%	16,77%	17,99%	18,67%	18,70%	14,67%	12,08%
Bjelovarsko-bilogorska	24,51%	26,12%	25,95%	24,90%	23,09%	24,98%	29,29%	28,78%	29,01%	30,22%	32,00%	31,05%	27,49%
Virovitičko-podravska	29,78%	30,50%	30,34%	28,70%	25,78%	27,32%	30,43%	32,54%	35,41%	36,22%	38,10%	35,84%	32,73%
Požeško-slavonska	21,44%	21,83%	21,70%	21,10%	19,38%	21,49%	24,42%	26,24%	27,59%	30,47%	31,40%	26,16%	22,83%
Brodsko-posavska	30,09%	30,94%	29,60%	27,60%	24,74%	26,20%	31,90%	33,84%	34,68%	36,96%	38,00%	30,83%	27,10%
Osječko-baranjska	27,78%	28,05%	26,08%	24,20%	22,00%	23,35%	28,18%	28,52%	29,30%	32,07%	34,30%	31,94%	28,80%
Vukovarsko-srijemska	34,22%	33,56%	31,30%	29,40%	27,46%	28,66%	31,82%	32,22%	32,94%	35,84%	38,00%	33,59%	29,67%
Karlovačka	26,46%	27,20%	26,10%	24,10%	21,80%	22,99%	25,98%	25,05%	25,71%	26,19%	25,60%	24,00%	21,16%
Sisačko-moslavačka	29,69%	30,40%	28,88%	26,30%	24,89%	27,40%	30,77%	30,90%	33,16%	34,80%	36,20%	34,38%	32,32%
Primorsko-goranska	14,63%	14,65%	13,37%	12,30%	10,84%	11,59%	14,79%	15,69%	15,63%	16,98%	17,90%	14,92%	12,97%
Ličko-senjska	18,34%	22,52%	22,06%	22,00%	18,84%	18,93%	21,53%	22,28%	20,86%	22,98%	24,60%	23,32%	22,33%
Zadarska	23,72%	22,37%	20,88%	20,10%	17,71%	18,69%	21,13%	21,02%	21,14%	22,53%	22,50%	17,73%	16,02%
Šibensko-kninska	31,48%	28,77%	24,98%	23,50%	19,59%	20,64%	23,28%	23,30%	24,01%	24,85%	25,50%	23,26%	22,54%
Splitsko-dalmatinska	24,24%	23,73%	22,17%	21,40%	19,14%	19,40%	22,74%	24,01%	25,76%	27,94%	28,60%	26,10%	24,11%
Istarska	8,80%	8,81%	8,40%	8,00%	6,74%	8,41%	10,69%	11,52%	10,90%	12,64%	12,90%	9,85%	8,43%
Dubrovačko-neretvanska	21,01%	19,96%	18,32%	17,90%	15,28%	15,54%	17,93%	18,76%	19,03%	20,46%	21,50%	20,54%	18,31%

Prilog 3. Dolasci, noćenja i njihove stope promjene za statističke regije NUTS 3

	Dolasci turista												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	507.836	549.607	603.857	665.398	705.165	633.517	666.106	730.945	767.366	868.855	967.902	1.077.778	1.152.598
Zagrebačka	26.633	29.852	34.719	32.376	35.131	36.942	34.569	34.367	38.764	47.732	53.841	65.653	75.527
Krapinsko-zagorska	39.255	36.436	52.365	61.197	65.145	56.497	54.781	60.121	62.837	75.172	85.367	95.751	124.585
Varaždinska	42.488	46.809	51.345	48.987	46.698	38.612	38.518	38.555	43.217	42.385	45.774	49.614	52.008
Koprivničko-križevačka	10.690	11.514	15.552	18.357	18.042	15.592	12.093	13.531	15.244	15.812	16.764	17.893	18.864
Međimurska	7.865	14.230	21.960	28.909	35.019	32.351	38.302	37.369	38.913	45.179	48.272	56.442	45.880
Bjelovarsko-bilogorska	9.900	11.111	13.478	14.669	14.776	12.719	11.590	13.887	14.383	15.048	16.076	20.336	20.490
Virovitičko-podravska	5.514	6.071	11.473	14.415	14.368	14.395	12.991	13.625	12.207	13.732	12.892	11.308	12.789
Požeško-slavonska	5.798	7.330	6.732	8.356	8.365	9.630	9.014	9.729	8.801	9.835	9.890	10.284	11.654
Brodsko-posavska	17.484	18.277	21.192	22.757	24.847	23.118	18.099	18.526	20.143	23.728	24.295	23.991	26.569
Osječko-baranjska	53.510	62.651	76.313	84.724	89.386	78.382	71.749	77.697	74.373	75.177	74.026	79.588	89.060
Vukovarsko-srijemska	24.650	31.314	31.694	38.355	39.765	33.828	36.582	36.682	33.808	41.148	43.709	51.566	69.818
Karlovačka	158.787	166.208	172.958	160.958	164.883	161.277	163.754	165.450	186.517	195.971	207.876	245.000	278.965
Sisačko-moslavačka	24.934	25.138	26.705	33.164	31.618	29.273	26.991	26.569	24.163	27.224	27.516	29.214	29.579
Primorsko-goranska	2.024.597	2.076.456	2.149.985	2.247.788	2.214.061	2.205.627	2.151.118	2.360.214	2.353.404	2.380.034	2.419.864	2.560.726	2.685.436
Ličko-senjska	278.922	300.060	312.166	359.635	365.709	386.720	403.960	425.675	467.119	493.164	522.857	574.736	621.129
Zadarska	843.290	931.509	977.395	1.072.659	1.102.170	1.049.019	971.092	1.022.464	1.074.192	1.086.788	1.186.908	1.289.862	1.362.206
Šibensko-kninska	650.677	750.840	752.081	820.312	822.879	746.532	634.614	650.059	657.371	716.849	746.177	797.035	817.755
Splitsko-dalmatinska	1.366.950	1.505.266	1.549.257	1.731.039	1.746.311	1.657.945	1.637.656	1.777.700	1.834.876	2.037.977	2.212.903	2.473.538	2.737.304
Istarska	2.515.701	2.505.017	2.575.090	2.719.949	2.729.618	2.755.269	2.627.918	2.895.686	2.985.042	2.980.663	3.059.226	3.369.905	3.763.174
Dubrovačko-neretvanska	796.795	909.374	928.604	978.402	986.851	957.229	982.619	1.046.826	1.122.420	1.241.254	1.346.281	1.443.103	1.598.767

Prilog 3. Nastavak

	Noćenja turista												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	856.355	934.143	1.018.549	1.133.172	1.182.917	1.047.937	1.085.597	1.183.125	1.245.669	1.442.192	1.602.420	1.804.290	2.016.107
Zagrebačka	53.115	59.577	69.764	67.332	69.545	69.809	62.198	66.502	67.703	83.382	93.143	111.629	128.255
Krapinsko-zagorska	114.463	113.082	146.504	173.423	186.709	159.056	145.411	153.046	161.811	177.587	210.253	215.831	283.351
Varaždinska	141.790	152.468	153.845	143.928	137.548	121.017	116.601	118.597	115.008	111.549	117.008	129.882	128.595
Koprivničko-križevačka	22.741	23.876	30.947	35.396	32.519	28.126	20.075	25.351	29.037	28.337	31.568	28.017	39.747
Međimurska	19.312	30.577	50.177	66.249	73.296	67.313	81.526	78.856	89.360	99.182	111.217	127.190	110.039
Bjelovarsko-bilogorska	22.861	26.092	33.794	33.304	36.337	31.835	23.981	30.468	31.924	32.565	36.614	62.864	67.666
Virovitičko-podravska	14.125	16.472	28.971	34.294	38.171	39.219	34.323	32.917	29.262	32.406	31.626	28.909	30.840
Požeško-slavonska	11.239	12.730	14.188	15.746	16.720	19.623	18.786	23.627	19.299	22.376	24.733	24.356	25.917
Brodsko-posavska	34.229	34.001	37.649	40.414	42.231	38.901	31.951	33.127	35.585	43.545	40.668	42.889	46.031
Osječko-baranjska	110.939	143.774	163.363	176.856	188.926	187.422	159.261	173.892	168.122	169.952	150.466	158.226	172.945
Vukovarsko-srijemska	43.517	55.536	66.941	82.703	85.395	78.033	68.383	62.394	60.538	75.606	83.159	94.519	102.201
Karlovačka	275.013	279.551	289.151	272.977	278.808	269.419	282.083	269.291	303.522	324.039	331.126	395.348	466.432
Sisačko-moslavačka	86.229	86.894	80.025	96.833	101.072	100.995	87.385	87.317	82.303	84.498	76.232	82.198	84.290
Primorsko-goranska	10.146.868	10.501.921	10.741.754	11.114.744	11.263.659	11.161.233	10.938.291	11.741.692	11.974.337	12.348.195	12.212.423	13.070.148	13.989.567
Ličko-senjska	1.052.650	1.120.109	1.184.299	1.315.280	1.409.793	1.519.841	1.618.941	1.697.107	1.824.036	1.949.651	2.030.496	2.198.348	2.322.753
Zadarska	4.540.904	5.214.975	5.447.660	6.008.672	6.237.669	6.117.731	6.223.824	6.481.067	6.783.072	6.747.858	7.184.150	7.816.872	8.209.852
Šibensko-kninska	2.755.352	3.458.089	3.749.385	3.920.068	3.978.112	3.799.217	3.783.823	3.975.122	4.139.536	4.513.814	4.552.929	4.822.542	4.988.303
Splitsko-dalmatinska	7.018.491	8.028.642	8.345.964	9.246.960	9.325.458	8.988.416	9.364.032	10.250.215	10.517.880	11.467.965	12.134.612	13.288.805	14.880.891
Istarska	16.532.510	16.649.944	16.968.695	17.613.132	17.965.984	18.130.006	17.731.881	19.095.401	19.877.368	19.445.130	19.545.303	20.966.561	23.128.233
Dubrovačko-neretvanska	3.944.584	4.478.495	4.385.321	4.414.009	4.452.625	4.324.498	4.538.026	4.775.161	5.188.091	5.618.286	5.883.802	6.135.891	6.827.837

Prilog 3. Nastavak

	Dolasci turista (stope promjene) [%]												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	7,52%	8,23%	9,87%	10,19%	5,98%	-10,16%	5,14%	9,73%	4,98%	13,23%	11,40%	11,35%	6,94%
Zagrebačka	24,08%	12,09%	16,30%	-6,75%	8,51%	5,15%	-6,42%	-0,58%	12,79%	23,13%	12,80%	21,94%	15,04%
Krapinsko-zagorska	-5,74%	-7,18%	43,72%	16,87%	6,45%	-13,28%	-3,04%	9,75%	4,52%	19,63%	13,56%	12,16%	30,11%
Varaždinska	-2,18%	10,17%	9,69%	-4,59%	-4,67%	-17,32%	-0,24%	0,10%	12,09%	-1,93%	8,00%	8,39%	4,83%
Koprivničko-križevačka	-10,98%	7,71%	35,07%	18,04%	-1,72%	-13,58%	-22,44%	11,89%	12,66%	3,73%	6,02%	6,73%	5,43%
Međimurska	7,67%	80,93%	54,32%	31,64%	21,14%	-7,62%	18,40%	-2,44%	4,13%	16,10%	6,85%	16,92%	-18,71%
Bjelovarsko-bilogorska	-0,44%	12,23%	21,30%	8,84%	0,73%	-13,92%	-8,88%	19,82%	3,57%	4,62%	6,83%	26,50%	0,76%
Virovitičko-podravska	28,17%	10,10%	88,98%	25,64%	-0,33%	0,19%	-9,75%	4,88%	-10,41%	12,49%	-6,12%	-12,29%	13,10%
Požeško-slavonska	0,71%	26,42%	-8,16%	24,12%	0,11%	15,12%	-6,40%	7,93%	-9,54%	11,75%	0,56%	3,98%	13,32%
Brodsko-posavska	0,84%	4,54%	15,95%	7,38%	9,18%	-6,96%	-21,71%	2,36%	8,73%	17,80%	2,39%	-1,25%	10,75%
Osječko-baranjska	-2,53%	17,08%	21,81%	11,02%	5,50%	-12,31%	-8,46%	8,29%	-4,28%	1,08%	-1,53%	7,51%	11,90%
Vukovarsko-srijemska	14,29%	27,03%	1,21%	21,02%	3,68%	-14,93%	8,14%	0,27%	-7,83%	21,71%	6,22%	17,98%	35,40%
Karlovačka	6,00%	4,67%	4,06%	-6,94%	2,44%	-2,19%	1,54%	1,04%	12,73%	5,07%	6,07%	17,86%	13,86%
Sisačko-moslavačka	4,98%	0,82%	6,23%	24,19%	-4,66%	-7,42%	-7,80%	-1,56%	-9,06%	12,67%	1,07%	6,17%	1,25%
Primorsko-goranska	1,36%	2,56%	3,54%	4,55%	-1,50%	-0,38%	-2,47%	9,72%	-0,29%	1,13%	1,67%	5,82%	4,87%
Ličko-senjska	14,37%	7,58%	4,03%	15,21%	1,69%	5,75%	4,46%	5,38%	9,74%	5,58%	6,02%	9,92%	8,07%
Zadarska	13,79%	10,46%	4,93%	9,75%	2,75%	-4,82%	-7,43%	5,29%	5,06%	1,17%	9,21%	8,67%	5,61%
Šibensko-kninska	1,71%	15,39%	0,17%	9,07%	0,31%	-9,28%	-14,99%	2,43%	1,12%	9,05%	4,09%	6,82%	2,60%
Splitsko-dalmatinska	10,54%	10,12%	2,92%	11,73%	0,88%	-5,06%	-1,22%	8,55%	3,22%	11,07%	8,58%	11,78%	10,66%
Istarska	3,24%	-0,42%	2,80%	5,63%	0,36%	0,94%	-4,62%	10,19%	3,09%	-0,15%	2,64%	10,16%	11,67%
Dubrovačko-neretvanska	14,32%	14,13%	2,11%	5,36%	0,86%	-3,00%	2,65%	6,53%	7,22%	10,59%	8,46%	7,19%	10,79%

Prilog 3. Nastavak

	Noćenja turista (stope promjene) [%]												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	2,56%	9,08%	9,04%	11,25%	4,39%	-11,41%	3,59%	8,98%	5,29%	15,78%	11,11%	12,60%	11,74%
Zagrebačka	26,75%	12,17%	17,10%	-3,49%	3,29%	0,38%	-10,90%	6,92%	1,81%	23,16%	11,71%	19,85%	14,89%
Krapinsko-zagorska	-12,33%	-1,21%	29,56%	18,37%	7,66%	-14,81%	-8,58%	5,25%	5,73%	9,75%	18,39%	2,65%	31,28%
Varaždinska	-4,30%	7,53%	0,90%	-6,45%	-4,43%	-12,02%	-3,65%	1,71%	-3,03%	-3,01%	4,89%	11,00%	-0,99%
Koprivničko-križevačka	-28,22%	4,99%	29,62%	14,38%	-8,13%	-13,51%	-28,62%	26,28%	14,54%	-2,41%	11,40%	-11,25%	41,87%
Međimurska	-8,59%	58,33%	64,10%	32,03%	10,64%	-8,16%	21,11%	-3,28%	13,32%	10,99%	12,13%	14,36%	-13,48%
Bjelovarsko-bilogorska	-9,00%	14,13%	29,52%	-1,45%	9,11%	-12,39%	-24,67%	27,05%	4,78%	2,01%	12,43%	71,69%	7,64%
Virovitičko-podravska	1,40%	16,62%	75,88%	18,37%	11,31%	2,75%	-12,48%	-4,10%	-11,10%	10,74%	-2,41%	-8,59%	6,68%
Požeško-slavonska	3,58%	13,27%	11,45%	10,98%	6,19%	17,36%	-4,27%	25,77%	-18,32%	15,94%	10,53%	-1,52%	6,41%
Brodsko-posavska	-8,70%	-0,67%	10,73%	7,34%	4,50%	-7,89%	-17,87%	3,68%	7,42%	22,37%	-6,61%	5,46%	7,33%
Osječko-baranjska	-3,98%	29,60%	13,62%	8,26%	6,82%	-0,80%	-15,03%	9,19%	-3,32%	1,09%	-11,47%	5,16%	9,30%
Vukovarsko-srijemska	-8,07%	27,62%	20,54%	23,55%	3,26%	-8,62%	-12,37%	-8,76%	-2,97%	24,89%	9,99%	13,66%	8,13%
Karlovačka	9,77%	1,65%	3,43%	-5,59%	2,14%	-3,37%	4,70%	-4,53%	12,71%	6,76%	2,19%	19,40%	17,98%
Sisačko-moslavačka	26,14%	0,77%	-7,91%	21,00%	4,38%	-0,08%	-13,48%	-0,08%	-5,74%	2,67%	-9,78%	7,83%	2,55%
Primorsko-goranska	-0,92%	3,50%	2,28%	3,47%	1,34%	-0,91%	-2,00%	7,34%	1,98%	3,12%	-1,10%	7,02%	7,03%
Ličko-senjska	12,54%	6,41%	5,73%	11,06%	7,19%	7,81%	6,52%	4,83%	7,48%	6,89%	4,15%	8,27%	5,66%
Zadarska	5,44%	14,84%	4,46%	10,30%	3,81%	-1,92%	1,73%	4,13%	4,66%	-0,52%	6,47%	8,81%	5,03%
Šibensko-kninska	-3,21%	25,50%	8,42%	4,55%	1,48%	-4,50%	-0,41%	5,06%	4,14%	9,04%	0,87%	5,92%	3,44%
Splitsko-dalmatinska	5,44%	14,39%	3,95%	10,80%	0,85%	-3,61%	4,18%	9,46%	2,61%	9,03%	5,81%	9,51%	11,98%
Istarska	1,97%	0,71%	1,91%	3,80%	2,00%	0,91%	-2,20%	7,69%	4,10%	-2,17%	0,52%	7,27%	10,31%
Dubrovačko-neretvanska	7,86%	13,54%	-2,08%	0,65%	0,87%	-2,88%	4,94%	5,23%	8,65%	8,29%	4,73%	4,28%	11,28%

Prilog 4. Populacije te stope promjene populacije za statističke regije NUTS 3

	Populacija												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	783.264	784.637	786.010	787.383	788.756	790.129	791.502	792.875	793.057	795.505	798.424	799.565	801.509
Zagrebačka	312.079	312.874	313.669	314.463	315.258	316.052	316.847	317.642	318.235	318.837	318.453	316.506	317.319
Krapinsko-zagorska	139.622	138.685	137.748	136.811	135.875	134.938	134.001	133.064	131.734	130.895	129.967	128.905	127.888
Varaždinska	182.152	181.280	180.407	179.535	178.663	177.790	176.918	176.046	175.150	174.434	173.454	171.879	171.184
Koprivničko-križevačka	121.802	120.914	120.025	119.137	118.248	117.360	116.471	115.582	114.846	114.346	113.688	112.357	111.881
Međimurska	117.222	116.821	116.420	116.019	115.617	115.216	114.815	114.414	113.561	113.417	113.159	112.576	112.202
Bjelovarsko-bilogorska	129.082	127.748	126.413	125.079	123.745	122.411	121.077	119.743	118.083	116.959	115.536	113.746	112.451
Virovitičko-podravska	90.748	89.868	88.987	88.107	87.227	86.346	85.466	84.586	83.820	83.029	82.162	80.610	79.958
Požeško-slavonska	83.491	82.711	81.931	81.151	80.371	79.591	78.811	78.031	76.651	75.801	74.991	73.473	72.556
Brodsko-posavska	171.304	169.483	167.662	165.842	164.021	162.201	160.380	158.559	157.086	155.956	154.082	151.012	149.909
Osječko-baranjska	322.824	320.264	317.703	315.142	312.581	310.021	307.460	304.899	302.751	300.950	298.272	294.233	292.477
Vukovarsko-srijemska	197.373	194.908	192.442	189.977	187.512	185.047	182.582	180.117	177.583	175.932	173.441	169.224	167.481
Karlovačka	137.876	136.572	135.268	133.964	132.661	131.357	130.053	128.749	126.997	125.688	124.127	121.840	120.474
Sisačko-moslavačka	181.664	180.423	179.182	177.941	176.700	175.459	174.218	172.977	169.379	167.036	163.975	160.292	157.500
Primorsko-goranska	302.690	301.752	300.814	299.876	298.937	297.999	297.061	296.123	295.300	294.705	293.811	291.654	291.191
Ličko-senjska	52.881	52.616	52.350	52.085	51.819	51.554	51.288	51.022	49.942	49.364	48.670	47.634	46.912
Zadarska	164.551	165.387	166.222	167.057	167.892	168.728	169.563	170.398	170.955	171.594	171.462	170.168	170.929
Šibensko-kninska	111.820	111.463	111.105	110.748	110.391	110.034	109.677	109.320	107.595	106.540	105.532	104.315	103.038
Splitsko-dalmatinska	461.145	460.302	459.459	458.615	457.772	456.928	456.085	455.242	454.777	454.711	454.627	453.155	453.206
Istarska	206.972	207.182	207.392	207.601	207.811	208.020	208.230	208.440	207.719	207.793	208.201	208.180	208.055
Dubrovačko-neretvanska	122.844	122.836	122.827	122.818	122.809	122.801	122.792	122.783	122.337	122.197	122.355	122.280	122.094

Prilog 4. Nastavak

	Populacija (stopa promjene) [%]												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	0,18%	0,18%	0,17%	0,17%	0,17%	0,17%	0,17%	0,17%	0,02%	0,31%	0,37%	0,14%	0,24%
Zagrebačka	0,26%	0,25%	0,25%	0,25%	0,25%	0,25%	0,25%	0,25%	0,19%	0,19%	-0,12%	-0,61%	0,26%
Krapinsko-zagorska	-0,67%	-0,67%	-0,68%	-0,68%	-0,68%	-0,69%	-0,69%	-0,70%	-1,00%	-0,64%	-0,71%	-0,82%	-0,79%
Varaždinska	-0,48%	-0,48%	-0,48%	-0,48%	-0,49%	-0,49%	-0,49%	-0,49%	-0,51%	-0,41%	-0,56%	-0,91%	-0,40%
Koprivničko-križevačka	-0,72%	-0,73%	-0,73%	-0,74%	-0,75%	-0,75%	-0,76%	-0,76%	-0,64%	-0,44%	-0,58%	-1,17%	-0,42%
Međimurska	-0,34%	-0,34%	-0,34%	-0,34%	-0,35%	-0,35%	-0,35%	-0,35%	-0,75%	-0,13%	-0,23%	-0,52%	-0,33%
Bjelovarsko-bilogorska	-1,02%	-1,03%	-1,04%	-1,06%	-1,07%	-1,08%	-1,09%	-1,10%	-1,39%	-0,95%	-1,22%	-1,55%	-1,14%
Virovitičko-podravska	-0,96%	-0,97%	-0,98%	-0,99%	-1,00%	-1,01%	-1,02%	-1,03%	-0,91%	-0,94%	-1,04%	-1,89%	-0,81%
Požeško-slavonska	-0,93%	-0,93%	-0,94%	-0,95%	-0,96%	-0,97%	-0,98%	-0,99%	-1,77%	-1,11%	-1,07%	-2,02%	-1,25%
Brodsko-posavska	-1,05%	-1,06%	-1,07%	-1,09%	-1,10%	-1,11%	-1,12%	-1,14%	-0,93%	-0,72%	-1,20%	-1,99%	-0,73%
Osječko-baranjska	-0,79%	-0,79%	-0,80%	-0,81%	-0,81%	-0,82%	-0,83%	-0,83%	-0,70%	-0,59%	-0,89%	-1,35%	-0,60%
Vukovarsko-srijemska	-1,23%	-1,25%	-1,26%	-1,28%	-1,30%	-1,31%	-1,33%	-1,35%	-1,41%	-0,93%	-1,42%	-2,43%	-1,03%
Karlovačka	-0,94%	-0,95%	-0,95%	-0,96%	-0,97%	-0,98%	-0,99%	-1,00%	-1,36%	-1,03%	-1,24%	-1,84%	-1,12%
Sisačko-moslavačka	-0,68%	-0,68%	-0,69%	-0,69%	-0,70%	-0,70%	-0,71%	-0,71%	-2,08%	-1,38%	-1,83%	-2,25%	-1,74%
Primorsko-goranska	-0,31%	-0,31%	-0,31%	-0,31%	-0,31%	-0,31%	-0,31%	-0,32%	-0,28%	-0,20%	-0,30%	-0,73%	-0,16%
Ličko-senjska	-0,50%	-0,50%	-0,50%	-0,51%	-0,51%	-0,51%	-0,51%	-0,52%	-2,12%	-1,16%	-1,41%	-2,13%	-1,52%
Zadarska	0,51%	0,51%	0,51%	0,50%	0,50%	0,50%	0,50%	0,49%	0,33%	0,37%	-0,08%	-0,75%	0,45%
Šibensko-kninska	-0,32%	-0,32%	-0,32%	-0,32%	-0,32%	-0,32%	-0,32%	-0,33%	-1,58%	-0,98%	-0,95%	-1,15%	-1,22%
Splitsko-dalmatinska	-0,18%	-0,18%	-0,18%	-0,18%	-0,18%	-0,18%	-0,18%	-0,18%	-0,10%	-0,01%	-0,02%	-0,32%	0,01%
Istarska	0,10%	0,10%	0,10%	0,10%	0,10%	0,10%	0,10%	0,10%	-0,35%	0,04%	0,20%	-0,01%	-0,06%
Dubrovačko-neretvanska	-0,01%	-0,01%	-0,01%	-0,01%	-0,01%	-0,01%	-0,01%	-0,01%	-0,36%	-0,11%	0,13%	-0,06%	-0,15%

Prilog 5. Aktivno stanovništvo za statističke regije NUTS 3

	Aktivno stanovništvo												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	410.192	412.667	427.718	441.045	449.393	452.776	446.191	438.733	440.759	437.524	432.210	431.372	437.650
Zagrebačka	90.424	92.674	95.027	95.769	96.108	96.491	95.276	93.457	92.842	94.660	93.622	93.617	92.996
Krapinsko-zagorska	43.611	43.273	43.532	43.571	43.028	42.181	41.696	41.824	41.758	41.757	41.608	40.517	39.733
Varaždinska	72.025	71.923	72.455	73.121	73.265	71.352	70.353	69.965	70.206	69.892	69.071	67.609	67.566
Koprivničko-križevačka	46.671	46.193	46.287	46.083	45.029	43.258	41.571	41.121	40.834	40.309	39.466	37.154	35.849
Međimurska	44.714	43.694	44.603	45.421	45.500	44.811	43.529	43.772	43.202	44.053	43.312	41.476	41.715
Bjelovarsko-bilogorska	47.543	47.342	47.799	47.864	47.411	46.531	45.314	44.421	43.730	43.652	42.639	41.599	39.224
Virovitičko-podravska	34.038	33.843	33.538	33.466	32.660	31.772	31.087	30.816	30.653	30.599	30.420	28.512	27.849
Požeško-slavonska	27.556	27.761	26.602	26.362	26.006	25.477	24.881	24.546	24.374	24.285	24.422	22.691	22.379
Brodsko-posavska	54.584	53.744	54.669	55.412	55.046	53.687	52.512	52.505	51.906	51.805	51.042	46.227	44.518
Osječko-baranjska	121.888	122.542	124.100	124.783	124.626	122.807	120.767	121.759	121.846	119.181	117.300	112.487	108.474
Vukovarsko-srijemska	62.577	62.801	63.113	64.542	64.352	63.605	62.834	62.458	62.202	62.747	61.453	57.824	55.018
Karlovačka	50.522	51.811	52.434	52.870	52.631	50.531	49.229	47.772	46.966	46.902	46.338	44.455	42.740
Sisačko-moslavačka	63.966	64.724	64.663	64.662	63.798	62.152	61.970	61.465	61.374	61.109	60.257	57.226	54.397
Primorsko-goranska	129.330	130.481	131.493	133.818	132.462	130.967	129.513	126.901	125.326	124.183	121.737	118.534	116.359
Ličko-senjska	18.569	17.640	17.341	17.339	17.394	17.361	17.073	16.737	16.598	16.847	17.102	16.806	16.557
Zadarska	54.909	56.354	56.003	58.253	58.528	58.146	57.098	56.633	56.551	56.076	56.256	53.647	52.164
Šibensko-kninska	38.628	38.552	39.613	39.030	38.935	38.089	36.727	36.022	36.623	37.000	37.004	36.104	35.359
Splitsko-dalmatinska	176.996	176.917	178.197	180.480	181.188	179.775	179.364	178.996	179.958	179.220	179.653	173.911	170.195
Istarska	87.014	88.562	91.554	94.349	95.687	92.314	90.979	88.413	88.080	87.053	86.545	83.599	83.698
Dubrovačko-neretvanska	45.880	46.166	46.973	48.441	48.610	48.172	48.147	47.346	47.255	47.340	47.971	46.670	46.878

Prilog 6. Broj registriranih cestovnih motornih i osobnih vozila za statističke regije NUTS 3

	Broj registriranih cestovnih motornih vozila												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	470.801	490.274	514.268	535.055	555.372	548.304	538.926	534.639	473.371	469.693	474.827	483.533	501.117
Zagrebačka	470.801	490.274	514.268	535.055	555.372	548.304	538.926	534.639	473.371	469.693	474.827	483.533	501.117
Krapinsko-zagorska	48.689	50.918	53.342	56.297	58.870	58.972	57.967	58.044	57.065	57.422	59.137	60.687	63.432
Varaždinska	71.232	74.254	76.844	80.942	84.126	83.844	82.319	81.636	80.483	80.696	81.698	83.110	85.968
Koprivničko-križevačka	48.733	50.489	52.428	54.779	57.186	56.828	55.970	56.629	55.976	55.990	56.302	56.662	58.114
Međimurska	48.506	50.138	50.466	52.693	54.276	53.897	52.797	52.845	52.431	52.496	53.451	54.406	55.934
Bjelovarsko-bilogorska	50.072	51.837	53.056	55.442	57.622	56.855	55.703	55.889	56.372	57.776	59.981	61.486	63.889
Virovitičko-podravska	30.453	31.569	32.978	34.754	36.242	36.169	35.519	35.656	35.369	35.519	35.683	35.840	36.993
Požeško-slavonska	27.978	28.945	29.979	31.380	32.887	33.721	33.319	33.862	34.391	35.393	36.619	36.914	38.144
Brodsko-posavska	51.373	53.357	55.259	57.993	60.396	59.058	56.193	55.308	54.079	53.900	54.499	54.923	56.527
Osječko-baranjska	101.547	104.860	109.702	115.101	119.958	119.534	117.573	118.058	111.702	111.368	112.013	112.684	115.620
Vukovarsko-srijemska	53.859	56.200	58.788	61.579	64.076	63.135	61.142	61.175	60.616	60.422	61.067	61.347	63.078
Karlovačka	51.013	53.227	54.845	56.992	58.968	58.823	57.739	58.071	57.979	58.420	59.174	59.923	61.815
Sisačko-moslavačka	60.321	62.631	65.612	68.834	71.751	71.482	69.592	69.453	68.204	67.924	68.413	68.535	70.306
Primorsko-goranska	143.041	148.216	153.245	158.102	162.182	161.456	159.491	159.819	152.006	152.260	154.273	156.128	160.577
Ličko-senjska	17.785	18.407	18.943	19.870	20.506	20.652	20.730	21.297	21.430	21.739	22.234	22.668	23.575
Zadarska	59.965	63.771	65.870	69.720	72.893	71.689	70.376	70.444	68.910	70.215	72.159	73.966	77.155
Šibensko-kninska	40.553	42.461	44.927	47.332	48.935	48.901	47.270	47.262	46.212	46.690	47.517	48.059	49.883
Splitsko-dalmatinska	181.629	187.893	197.112	206.335	213.658	212.856	210.852	211.987	193.489	196.279	201.389	206.245	215.217
Istarska	115.526	121.227	126.015	130.559	133.751	130.886	127.366	127.657	125.086	125.708	128.186	130.403	134.295
Dubrovačko-neretvanska	47.043	50.297	53.062	56.177	58.281	58.148	58.743	59.674	58.570	59.460	60.916	62.207	64.417

Prilog 6. Nastavak

	Broj registriranih osobnih vozila												
NUTS 3	**2004.**	**2005.**	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**
Grad Zagreb	386.305	400.069	417.215	431.985	446.259	444.067	439.022	437.088	392.937	390.475	394.912	401.340	415.270
Zagrebačka	386.305	400.069	417.215	431.985	446.259	444.067	439.022	437.088	392.937	390.475	394.912	401.340	415.270
Krapinsko-zagorska	36.953	38.503	40.115	42.078	43.858	44.234	43.880	44.028	43.439	43.664	44.944	46.249	48.345
Varaždinska	50.284	52.224	53.910	56.205	58.073	58.148	57.501	57.658	57.241	57.419	58.283	59.444	61.860
Koprivničko-križevačka	32.387	33.315	34.455	35.937	37.388	37.323	36.972	37.237	36.785	36.852	37.334	37.712	39.040
Međimurska	35.093	36.038	36.368	37.747	38.827	38.909	38.433	38.651	38.595	38.777	39.632	40.638	42.063
Bjelovarsko-bilogorska	33.037	34.195	35.033	36.718	37.988	37.556	37.337	37.546	37.822	38.402	39.885	40.962	42.664
Virovitičko-podravska	20.593	21.320	22.015	23.094	23.864	23.995	23.731	23.926	23.717	23.877	24.047	24.358	25.342
Požeško-slavonska	19.947	20.597	21.381	22.400	23.259	23.935	23.772	24.111	24.384	24.841	25.778	26.071	27.153
Brodsko-posavska	38.550	39.863	41.261	43.181	44.557	44.264	42.889	42.547	41.716	41.653	42.344	42.881	44.073
Osječko-baranjska	77.555	80.256	83.367	86.857	89.618	89.945	89.189	89.720	84.994	84.409	85.025	85.906	88.613
Vukovarsko-srijemska	41.642	43.203	44.852	46.777	48.036	47.486	46.454	46.325	45.790	45.504	46.161	46.539	47.998
Karlovačka	38.719	40.099	41.327	42.739	43.834	43.729	43.054	43.229	43.278	43.400	43.939	44.412	45.712
Sisačko-moslavačka	44.508	46.155	48.134	50.404	52.043	52.031	51.065	51.072	50.091	49.894	50.537	50.812	52.384
Primorsko-goranska	116.071	119.194	122.498	125.547	128.017	128.270	127.409	127.612	121.954	122.124	123.986	125.671	129.128
Ličko-senjska	13.007	13.374	13.778	14.404	14.772	15.002	15.147	15.519	15.656	15.851	16.279	16.628	17.238
Zadarska	47.801	50.631	52.016	54.784	56.715	56.216	55.409	55.779	55.229	56.323	58.031	59.485	62.061
Šibensko-kninska	31.778	32.979	34.615	36.141	36.930	37.071	35.975	36.137	35.545	35.919	36.828	37.425	38.986
Splitsko-dalmatinska	144.792	148.471	154.656	160.882	165.244	165.593	164.832	165.837	153.852	155.671	160.042	163.893	170.816
Istarska	91.620	95.209	98.059	100.568	102.328	100.812	98.731	98.958	97.357	97.712	99.747	101.511	104.548
Dubrovačko-neretvanska	36.896	39.004	40.726	42.679	43.670	43.963	44.647	45.298	44.838	45.532	46.761	47.865	49.610

Prilog 7. Vrijednosti zavisnih i nezavisnih varijabli korištenih za izradu prognostičkoga modela prijevozne potražnje u cestovnome prometu

Godina	Prometnica	Stopa promjene PGDP-a	Stopa promjene turističkih dolazaka	Stopa promjene registriranih cestovnih motornih vozila	Realni rast BDP-a	Realni rast neto plaće (godišnja stopa promjene)
2004.	AC	10,146%	6,018%	4,259%	4,160%	3,792%
2004.	DC	-0,794%	6,018%	4,259%	4,160%	3,792%
2005.	AC	7,148%	6,192%	4,119%	4,314%	1,517%
2005.	DC	-0,539%	6,192%	4,119%	4,314%	1,517%
2006.	AC	10,923%	3,900%	4,231%	5,001%	1,942%
2006.	DC	1,480%	3,900%	4,231%	5,001%	1,942%
2007.	AC	9,155%	7,487%	4,457%	5,266%	2,267%
2007.	DC	6,587%	7,487%	4,457%	5,266%	2,267%
2008.	AC	1,793%	0,882%	3,692%	1,760%	0,850%
2008.	DC	0,101%	0,882%	3,692%	1,760%	0,850%
2009.	AC	0,231%	-2,898%	-0,827%	-7,359%	0,233%
2009.	DC	-2,375%	-2,898%	-0,827%	-7,359%	0,233%
2010.	AC	-1,375%	-3,021%	-1,777%	-1,496%	-0,450%
2010.	DC	-1,769%	-3,021%	-1,777%	-1,496%	-0,450%
2011.	AC	3,653%	8,030%	-0,009%	-0,310%	-0,375%
2011.	DC	-0,266%	8,030%	-0,009%	-0,310%	-0,375%
2012.	AC	-4,811%	3,313%	-5,365%	-2,238%	-2,600%
2012.	DC	-4,072%	3,313%	-5,365%	-2,238%	-2,600%
2013.	AC	2,671%	5,058%	0,302%	-0,549%	-1,500%
2013.	DC	-0,499%	5,058%	0,302%	-0,549%	-1,500%
2014.	AC	2,210%	5,587%	1,614%	-0,104%	0,558%
2014.	DC	0,997%	5,587%	1,614%	-0,104%	0,558%
2015.	AC	5,979%	9,254%	1,589%	2,437%	3,675%
2015.	DC	2,811%	9,254%	1,589%	2,437%	3,675%
2016.	AC	7,360%	8,721%	3,437%	3,484%	2,775%
2016.	DC	4,247%	8,721%	3,437%	3,484%	2,775%

POPIS SLIKA

Slika 1. Proces izrade prognostičkoga modela 53

Slika 2. Proces izrade modela vrednovanja prognoza prijevozne potražnje u cestovnome prometu 63

POPIS GRAFIKONA

Grafikon 1. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje tijekom analiziranoga perioda (Tukey-Kramerov test) 13

Grafikon 2. Trend analiza godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (Izvor:[50], autorova obrada) 14

Grafikon 3. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje ovisno o dobu godine (Tukey-Kramerov test) 15

Grafikon 4. Trend prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje PGDP-a (Izvor:[50], autorova obrada) 16

Grafikon 5. Trend prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje PLDP-a (Izvor:[50], autorova obrada) 16

Grafikon 6. Trend prosječnih godišnjih stopa promjena intenziteta cestovne prijevozne potražnje PiDP-a (Izvor:[50], autorova obrada) 17

Grafikon 7. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje ovisno o kategoriji prometnice, PGDP (Tukey-Kramerov test) 18

Grafikon 8. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje ovisno o kategoriji prometnice, PLDP (Tukey-Kramerov test) 18

Grafikon 9. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje ovisno o kategoriji prometnice, PiDP (Tukey-Kramerov test) 19

Grafikon 10. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 3, PGDP (Tukey-Kramerov test)..... 20

Grafikon 11. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 3, PLDP (Tukey-Kramerov test)..... 21

Grafikon 12. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 3, PiDP (Tukey-Kramerov test)..... 21

Grafikon 13. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 2, PGDP (Tukey-Kramerov test)..... 22

Grafikon 14. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 2, PLDP (Tukey-Kramerov test)..... 22

Grafikon 15. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema NUTS 2, PiDP (Tukey-Kramerov test)..... 23

Grafikon 16. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema funkcionalnoj regiji, PGDP (Tukey-Kramerov test)..... 23

Grafikon 17. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema funkcionalnoj regiji, PLDP (Tukey-Kramerov test)..... 24

Grafikon 18. Utvrđivanje statistički značajne razlike kretanja prosječnih godišnjih stopa promjena cestovne prijevozne potražnje prema funkcionalnoj regiji, PiDP (Tukey-Kramerov test)..... 24

Grafikon 19. Trend analiza broja registriranih cestovnih motornih i osobnih vozila (Izvor: [53], autorova obrada)..... 25

Grafikon 20. Trend analiza broja registriranih cestovnih motornih i osobnih vozila, stope promjene (Izvor: [53], autorova obrada)..... 26

Grafikon 21. Trend analiza cestovnoga prijevoza robe (Izvor: [53], autorova obrada) 27

Grafikon 22. Trend analiza željezničkoga prijevoza robe (Izvor: [53], autorova obrada) 27

Grafikon 23. Trend analiza cestovnoga i željezničkoga prijevoza robe, stope promjene (Izvor: [53], autorova obrada) 28

Grafikon 24. Trend analiza BDP-a u Republici Hrvatskoj (Izvor: [53], autorova obrada) 29

Grafikon 25. Trend analiza BDP-a u Europskoj uniji (Izvor: [53], [54], autorova obrada) 31

Grafikon 26. Trend analiza obujma industrijske proizvodnje (Izvor: [53], autorova obrada) . 32

Grafikon 27. Trend analiza indeksa potrošačkih cijena (Izvor: [53], autorova obrada) 33

Grafikon 28. Trend analiza indeksa potrošačkih cijena bez energije i hrane (Izvor: [53], autorova obrada) 33

Grafikon 29. Trend analiza nominalnoga rasta neto plaće (Izvor: [53], autorova obrada) 34

Grafikon 30. Trend analiza realnoga rasta neto plaće (Izvor: [53], autorova obrada) 34

Grafikon 31. Trend analiza troška goriva (Izvor:[55], autorova obrada) 35

Grafikon 32. Trend analiza prosječnoga troška goriva (Izvor:[55], autorova obrada) 36

Grafikon 33. Trend analiza prosječnoga troška goriva, stope promjene (Izvor:[55], autorova obrada) 36

Grafikon 34. Trend analiza broja zaposlenih (Izvor: [53], autorova obrada) 37

Grafikon 35. Trend analiza stope registrirane nezaposlenosti (Izvor: [53], autorova obrada). 38

Grafikon 36. Trend analiza dolazaka turista, stope promjene (Izvor: [53], autorova obrada) . 39

Grafikon 37. Trend analiza dolazaka turista (Izvor: [53], autorova obrada) 39

Grafikon 38. Trend analiza noćenja turista (Izvor: [53], autorova obrada) 40

Grafikon 39. Trend analiza noćenja turista, stope promjene (Izvor: [53], autorova obrada) ... 40

Grafikon 40. Trend analiza populacije (Izvor: [53], autorova obrada) 41

Grafikon 41. Trend analiza populacije, stope promjene (Izvor: [53], autorova obrada) 42

Grafikon 42. Trend analiza aktivnoga stanovništva (Izvor: [53], autorova obrada) 42

Grafikon 43. Trend analiza aktivnoga stanovništva, stope promjene (Izvor: [53], autorova obrada) 43

Grafikon 44. Rasipanja korelacijske matrice (PGDP) 49

Grafikon 45. Odnos regresijskih standardiziranih pogrešaka i prognoziranih vrijednosti – V1 61

Grafikon 46. Odnos regresijskih standardiziranih pogrešaka i prognoziranih vrijednosti – V2 61

Grafikon 47. Odnos regresijskih standardiziranih pogrešaka i prognoziranih vrijednosti – V3 62

Grafikon 48. Histogram i Q-Q grafikon prosječne godišnje stope promjene broja turističkih dolazaka 65

Grafikon 49. Histogram i Q-Q grafikon realnoga rasta neto plaće 65

Grafikon 50. Histogram i Q-Q grafikon prosječne godišnje stope promjene broja registriranih motornih cestovnih vozila 66

Grafikon 51. Histogram i Q-Q grafikon realnoga rasta BDP-a 66

Grafikon 52. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V1, autoceste 71

Grafikon 53. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V2, autoceste 72

Grafikon 54. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V3, autoceste 72

Grafikon 55. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V1, državne ceste 75

Grafikon 56. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V2, državne ceste 75

Grafikon 57. Kumulativna funkcija distribucije prosječnih godišnjih stopa intenziteta cestovne prijevozne potražnje (PGDP) – V3, državne ceste 76

Grafikon 58. Kumulativna distribucija rezultata modela vrednovanja (AC) 86

Grafikon 59. Kumulativna distribucija rezultata modela vrednovanja (DC) 87

POPIS TABLICA

Tablica 1. Analizirani pokazatelji prema kategorijama 10

Tablica 2. Analiza koeficijenata korelacije relevantnih pokazatelja 46

Tablica 3. Korelacijska matrica 55

Tablica 4. Prognostički modeli 56

Tablica 5. Rezultati za prognostički model V1 57

Tablica 6. Rezultati za prognostički model V2 58

Tablica 7. Rezultati za prognostički model V3 59

Tablica 8. Rezultati testa normalnosti pogrešaka prognostičkih modela 60

Tablica 9. Testovi normaliteta nezavisnih varijabli 64

Tablica 10. Rezultati deskriptivne statistike nezavisnih varijabli 67

Tablica 11. Parametri normalnih distribucija nezavisnih varijabli 68

Tablica 12. Rezultati deskriptivne statistike modeliranih vjerojatnosti prognoze - AC 70

Tablica 13. Percentilne vrijednosti modeliranih vjerojatnosti prognoze - AC 70

Tablica 14. Rezultati deskriptivne statistike modeliranih vjerojatnosti prognoze - DC 73

Tablica 15. Percentilne vrijednosti modeliranih vjerojatnosti prognoze - DC 73

Tablica 16. Vrijednosti nezavisnih varijabli u razdoblju 2017.-2019. (Izvor: [53], autorova obrada) 78

Tablica 17. Vrijednosti kretanja prosječnih godišnjih stopa promjene intenziteta cestovne prijevozne potražnje (PGDP) u razdoblju 2017.-2019. (Izvor:[50], autorova obrada) 79

Tablica 18. Postotne greške modela vrednovanja (autoceste) 81

Tablica 19. Postotne greške modela vrednovanja (državne ceste) 82

Tablica 20. Parametri distribucija nezavisnih varijabli 84

Tablica 21. Rezultati deskriptivne statistike rezultata modela vrednovanja 85

Tablica 22. Analiza vjerojatnosti pojavljivanja utvrđenih vrijednosti primjenom modela vrednovanja (AC) 85

Tablica 23. Analiza vjerojatnosti pojavljivanja utvrđenih vrijednosti primjenom modela vrednovanja (DC) 86

Tablica 24. Analiza točnosti prognoza cestovne prijevozne potražnje u Republici Hrvatskoj (Izvor: [40]-[45], autorova obrada) 88

Tablica 25. Rezultati deskriptivne statistike nezavisnih varijabli za kretanje zavisne varijable od 0,5% do 2,5% (model vrednovanja) 90

ŽIVOTOPIS I POPIS JAVNO OBJAVLJENIH RADOVA

Životopis

Marijan Jakovljević rođen je 1988. u Požegi. Diplomirao je 2013. na Sveučilištu u Zagrebu, na Fakultetu prometnih znanosti gdje je 2020. obranio i disertaciju. Od 2014. do 2015. na matičnom fakultetu radi kao istraživač na projektu te se bavi znanstveno-istraživačkim i stručnim radom u području prometnog planiranja i projektiranja te sigurnosti cestovnog prometa. Od 2015. radi kao asistent na Zavodu za prometno planiranje Fakulteta prometnih znanosti gdje sudjeluje u nastavi na kolegijima preddiplomskog i diplomskog studija. Rezultate znanstveno-istraživačkog rada objavio u 16 znanstvenih i stručnih radova te sudjelovao na nizu konferencija u zemlji i inozemstvu. Kao voditelj, istraživač, autor ili suradnik sudjelovao je u preko 120 znanstveno-istraživačkih, razvojnih i stručnih projekta.

Od tehničkih vještina i kompetencija izvrsno poznaje rad u više specijalističkih i drugih programskih alata kao što su MS Office paket, AutoCAD, AutoCAD Map 3D, AutoTURN, programski alati za statističku obradu podataka (SAS, SAS Enterprise Guide, JMP, SPSSS, Statistica, R), programski alati za izradu mikrosimulacija prometnog sustava PTV Vissim i makrosimulacija prometnog sustava PTV Visum te programski alati QuantumGIS i ArcGIS.

Popis javno objavljenih radova

Znanstveni radovi u drugim časopisima

1. Ćosić, Mario; Šimunović, Ljupko; **Jakovljević, Marijan**: *Relationships Between External Factors and Pedestrian Accident Blackspots – A Case Study of the City of Zagreb*, Promet - Traffic & Transportation, 31 (2019), 3; 329-340, doi:10.7307/ptt.v31i3.3119 (međunarodna recenzija, članak, znanstveni)
2. Šoštarić, Marko; **Jakovljević, Marijan**; Ćosić, Mladenka: *Ekonomski učinci sustava dinamičke izmjene usmjerenja prometnih trakova u urbanim područjima*, Suvremeni promet : časopis za pitanja teorije i prakse prometa, 37 (2017), 5-6; 213-217 (međunarodna recenzija, pregledni rad, znanstveni)

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom

1. Ševrović, Marko; **Jakovljević, Marijan**; Uravić, Mateo; Švajda, Marko; Dadić, Ivan: *Koncept održivog razvitka prometnog sustava Bjelovarsko-bilogorske županije*, Radovi Zavoda za znanstvenoistraživački i umjetnički rad u Bjelovaru, 292 (2020), 79-92, doi:10.21857/9e31lhvwgm (međunarodna recenzija, članak, znanstveni)
2. Šoštarić, Marko; Beganović, Dijana; **Jakovljević, Marijan**; Švajda, Marko: *Electric vehicles in the function of modelling paratransit for areas with significant deviation between cycle time - Case study of Jastrebarsko (Croatia)*, Proceedings of the International Scientific Conference "Science and Traffic Development" (ZIRP 2019), Zagreb: Fakultet prometnih znanosti Sveučilišta u Zagrebu, 2019. str. 431-438 (poster, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
3. Šoštarić, Marko; **Jakovljević, Marijan**; Beganović, Dijana; Švajda, Marko: *Odstupanja validacijskih podataka u javnom prijevozu case study-funkcionalna regija Sjeverni Jadran*, CESTE 2019 - Zbornik radova, Rovinj, Hrvatska, 2019. str. 326-336 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), stručni)
4. Šoštarić, Marko; Ševrović, Marko; **Jakovljević, Marijan**; Švajda, Marko: *Učinkovitost parkirne politike gradova RH - case study*, CESTE 2019 – Zbornik radova, Rovinj, Hrvatska, 2019. str. 361-372 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), stručni)
5. Ševrović, Marko; Šoštarić, Marko; **Jakovljević, Marijan**; Uravić, Mateo: *Određivanje smjernica za izradu planova održive mobilnosti – case study: Grad Bjelovar*, CESTE 2019 - Zbornik radova, Rovinj, Hrvatska, 2019. str. 347-360 (poster, podatak o recenziji nije dostupan, cjeloviti rad (in extenso), stručni)
6. Golubić, Jasna; **Jakovljević, Marijan**: *Impact of road traffic on air pollution on analysed intersections in the City of Zagreb*, Transport Problems 2018 – Proceedings, Katowice: Silesian University of Technology, 2018. str. 212-218 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
7. Šoštarić, Marko; **Jakovljević, Marijan**; Buhin, Denis; Lale, Orsat: *Non-motorized Transport Integration - Case Study Zagreb City Centre*, Proceedings of the International Scientific Conference "Science and Traffic Development" (ZIRP 2018), Zagreb: University of Zagreb, Faculty of Transport and Traffic Sciences, 2018. str. 301-309 (pozvano predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

8. Šoštarić, Marko; **Jakovljević, Marijan**; Lale, Orsat: *Park & Ride terminal kao rješenje prometnog problema grada Dubrovnika*, Zbornik radova s 37. skupa o prometnim sustavima s međunarodnim sudjelovanjem "Automatizacija u prometu 2017", Zagreb: KoREMA, 2017. str. 48-51 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
9. Šoštarić, Marko; Lale, Orsat; **Jakovljević, Marijan**: *Mogućnosti unaprjeđenja prometne povezanosti zračne luke Dubrovnik s gradom Dubrovnikom*, Peti BiH kongres o cestama/The Fifth B&H Congress on Roads, Sarajevo: Udruženje konzultanata inženjera Bosne i Hercegovine, 2016. str. 237-244 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), ostalo)
10. Šoštarić, Marko; Ćosić, Mladenka; **Jakovljević, Marijan**: *Ekološki aspekti sustava dinamičke promjene usmjerenja prometnih traka u gradovima*, KoREMA - Automatizacija u prometu 2016, Zagreb, 2016. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)
11. Škorić, Josip; Majstorović, Željko; Ščukanec, Anđelko; Šoštarić, Marko; **Jakovljević, Marijan:** *Provođenje RSIA smjernice europske direktive i njen utjecaj na izradu prostorno planske dokumentacije*, 6. Kongres o cestama, Zagreb, Hrvatsko društvo za ceste VIA VITA, 2015. str. 412-417 (predavanje, domaća recenzija, cjeloviti rad (in extenso), ostalo)
12. Majstorović, Željko; Ščukanec; Anđelko; Tollazzi, Tomaž; Šoštarić, Marko; **Jakovljević, Marijan**: *Procjena sigurnosti prometa u fazi planiranja i projektiranja cesta prema europskoj direktivi o sigurnosti cestovne infrastrukture*, Zbornik radova s Osmog hrvatskog savjetovanja o održavanju cesta, Umag: GIU Hrvatski cestar, 2014. str. 47-52 (predavanje, domaća recenzija, cjeloviti rad (in extenso), stručni)
13. Šoštarić, Marko; Ševrović, Marko; **Jakovljević, Marijan**: *Park & Ride System in the Function od Sustainable Mobility at Tourist Destinations in Croatia*, Development Possibilities of Croatian Transport System - Anniversary of EU Membership (ZIRP 2014), Zagreb: Faculty of Transport and Traffic Sciences, 2014. str. 97-106 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

Druge vrste radova

1. Brčić, Davor; Šimunović, Ljupko; Slavulj, Marko; Ševrović, Marko; Šoštarić, Marko; Ćosić, Mario; Šojat, Dino; **Jakovljević, Marijan**: *Indikatori mobilnosti u konceptu "Smart City"*, 2017. (podatak o recenziji nije dostupan, izvješće)

2. Novačko, Luka; Vujić, Miroslav; Ivanjko, Edouard; Gregurić, Martin; **Jakovljević, Marijan**: *Implementation of PTV software at Faculty of Transport and Traffic Sciences, University of Zagreb*, PTV User Group Meeting, Zagreb, Hrvatska, 2016. (predavanje, pp prezentacija, stručni)