ANALIZA PROMETNOG OPTEREĆENJA I PROGNOZA PROMETA NA CESTOVNOJ MREŽI PRIMORSKO – GORANSKE ŽUPANIJE DO 2030. GODINE

Stipić, Matej

Master's thesis / Specijalistički diplomski stručni

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **The Polytechnic of Rijeka / Veleučilište u Rijeci**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:125:924898

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Polytechnic of Rijeka Digital Repository - DR PolyRi

zir.nsk.hr

Image not found or type unknown

VELEUČILIŠTE U RIJECI

Matej Stipić

ANALIZA PROMETNOG OPTEREĆENJA I PROGNOZA PROMETA NA CESTOVNOJ MREŽI PRIMORSKO – GORANSKE ŽUPANIJE DO 2030. GODINE

(specijalistički završni rad)

Rijeka, 2018.

VELEUČILIŠTE U RIJECI

Prometni odjel

Specijalistički diplomski stručni studij Promet

ANALIZA PROMETNOG OPTEREĆENJA I PROGNOZA PROMETA NA CESTOVNOJ MREŽI PRIMORSKO - GORANSKE ŽUPANIJE DO 2030. GODINE

(specijalistički završni rad)

MENTOR

dr. sc. Drago Pupavac

STUDENT

Matej Stipić

MBS: 2429000124/16

Rijeka, lipanj 2018.

VELEUČILIŠTE U RIJECI

Prometni odjel

Rijeka, 3.04.2018.

ZADATAK
za specijalistički završni rad

Pristupniku Stipić Mateju MBS: 2429000124/16

Studentu specijalističkog diplomskog stručnog studija Promet izdaje se zadatak specijalističkog završnog rada – tema specijalističkog završnog rada pod nazivom:

ANALIZA PROMETNOG OPTEREĆENJA I PROGNOZA PROMETA NA CESTOVNOJ MREŽI PRIMORSKO – GORANSKE ŽUPANIJE DO 2030. GODINE

Sadržaj zadatka: U radu istražiti i analizirati postojeće stanje prometnog opterećenja na cestovnoj mreži Primorsko-goranske županije, elaborirati strukturu i kapacitete cestovne prometne mreže te temeljem prikupljenih podataka sačiniti prognozu prometa do 2030. godine i izdvojiti politike i projekte kojima bi se postiglo usklađivanje prometne ponude i potražnje na cestovnoj prometnoj mreži Primorsko - goranske županije.

Preporuka

Rad obraditi sukladno odredbama Pravilnika o završnom radu Veleučilišta u Rijeci.

Zadano: 3.04.2018. **Predati do: 15.06.2018.**

Mentor: **Pročelnik odjela:**

Drago Pupavac **Dr.sc. Ivica Barišić, prof.v.šk.**

Zadatak primio dana: 3.04.2018.

Matej Stipić

Dostavlja se:
- **mentoru**
- **pristupniku**

I Z J A V A

Izjavljujem da sam specijalistički završni rad pod naslovom Analiza prometnog opterećenja i prognoza prometa na cestovnoj mreži Primorsko - goranske županije do 2030. godine izradio samostalno pod nadzorom i uz stručnu pomoć mentora dr.sc. Drage Pupavca.

Ime i prezime

(potpis studenta)

SAŽETAK

Temeljni cilj ovoga rada jest analizirati prometno opterećenje na cestovnoj mreži Primorsko - goranske županije do 2030. godine. Da bi se cilj rada i ostvario najprije su prikupljeni podatci iz sekundarnih izvora o samoj županiji, prostornom obuhvatu i stanovništvu kao bi se upoznalo samo područje obuhvata. Potom su analizirana gospodarska kretanja za protekla razdoblja kako bi se elaboriralo samo područje obuhvata. Prikupljeni su i prezentirani podaci o gospodarskim kretanjima te podaci o prosječnom dnevnom i prosječnom ljetnom godišnjem prometu na odabranim cestovnim prometnicama na području Primorsko-goranske županije. Analiza prometnog opterećenja na cestovnoj mreži Primorsko-goranske županije temelji se na metodama deskriptivne statistike. Prognoziranje prometnog opterećenja na području cestovne mreže Primorsko-goranske županije izvršeno je pomoću metoda stope rasta i metode regresije. Potom je komparativnom metodom odabrana statistički prikladnija metoda.

Ključne riječi: analiza prometa, prognoza prometa, promet, prometno opterećenje, Primorsko - goranska županija

Sadržaj

1. UVOD 1

1.1. Problem i predmet završnog rada 1

1.2. Svrha i cilj završnog rada 1

1.3. Struktura završnog rada 1

2. PODRUČJE OBUHVATA 3

3. GOSPODARSKA KRETANJA U PRIMORSKO – GORANSKOJ ŽUPANIJI 6

4. ODREĐIVANJE VRIJEDNOSTI PGDP-a I PLDP-a NA CESTOVNOJ MREŽI 9

4.1. Ulazni parametri za analizu i prognozu prometa cestovne mreže 9

4.2. Promet u mirovanju - postojeće stanje 10

4.3. Zakonitosti razvitka 14

4.4. Prikupljeni podatci PGDP-a i PLDP-a na izabranim autocestama u Primorsko-goranskoj županiji 16

4.5. Prikupljeni podatci PGDP-a i PLDP-a na izabranim državnim cestama u Primorsko-goranskoj županiji 19

4.6. Prikupljeni podatci PGDP-a i PLDP-a u centru Grada Rijeke 23

5. PROGNOZA PROMETNOG OPTEREĆENJA NA IZABRANIM LOKALNIM I ŽUPANIJSKIM PROMETNICAMA DO 2030. GODINE 25

5.1. Prognoza prometnog opterećenja na izabranim autocestama u Primorsko-goranskoj županiji 25

5.1.1. Prognoza prometnog opterećenja na autocesti A6 – PGDP i PLDP 25

5.1.2. Prognoza prometnog opterećenja na autocesti A7 – PGDP i PLDP 29

5.2. Prognoza prometnog opterećenja na izabranim državnim cestama u Primorsko-goranskoj županiji 33

5.2.2. Prognoza prometnog opterećenja na državnoj cesti D8 – PGDP i PLDP 39

5.2.3. Prognoza prometnog opterećenja na državnoj cesti D32 – PGDP i PLDP 44

5.3. Prognoza prometnog opterećenja u centru Grada Rijeke 48

6. ZAKLJUČAK 53
LITERATURA 54
POPIS SLIKA 55
POPIS GRAFIKONA 55
POPIS TABLICA 56

1. UVOD

Neosporiva je činjenica da je prometni sustavi u svakom društvu danas neophodan da bi bez njega mogli optimalno funkcionirati svi ostali sustavi, od onih globalnih na makro razini do mikro sustava. Navedeno vrijedi i za sve segmente Primorsko - goranske županije koja svojim geoprometnim položajem zauzima važno prometno mjesto.

Prometni sustav područja grada Rijeke i Primorsko - goranske županije (u daljnjem tekstu PGŽ) nameće specifičan prostorno - prometni model kakav ne nalazimo u Hrvatskoj i jedino njegovim izvedivim i opravdanim rješenjem moguće je očekivati bolji prometni, ekološki i gospodarski suživot i razvoj Primorsko - goranske županije i Grada Rijeke na ograničenom priobalnom prostoru.

1.1. Problem i predmet završnog rada

Predmet završnog rada je analizirati postojeće stanje prijevoza putnika i tereta na području Primorsko - goranske županije, te izraditi prognozu prometa na cestovnoj mreži Primorsko - goranske županije do 2030. godine.

1.2. Svrha i cilj završnog rada

Svrha ovog završnog rada je ukazati na važnost razvoja prometa na području Primorsko - goranske županije u vidu povećanja konkurentnosti i gospodarskog razvoja PGŽ-a. Cilj istraživanja je dati uvid u strukturu i kapacitete cestovne mreže, politikama koje provodi te ulaganjima i projektima kojima bi se potaknuo veći razvoj i konkurentnost prometa Primorsko - goranske županije.

1.3. Struktura završnog rada

Završni rad sastoj i se od šest glavnih poglavlja i nekoliko pod poglavlja, koja su raspoređena u radu kao slijedi:

Prvo poglavlje Uvod predstavlja kratki uvod u samu temu završnog rada i ukratko opisuje ono o čemu se govori kroz cijeli rad.

U drugom poglavlju Područje obuhvata detaljno je opisano područje obuhvata rada odnosno područje Primorsko - goranske županije sa bitnim parametrima koji se odnose na samu temu završnog rada i koji su direktno povezani sa njom.

Kroz treće poglavlje Gospodarska kretanja u PGŽ-u predstavljena su bitna gospodarska kretanja u izabranoj županiji, što je bitan element samog završnog rada i na što se nadovezuju ostali podatci u radu.

Četvrto poglavlje Određivanje vrijednosti PGDP-a i PLDP-a na mreži predstavlja važan element završnog rada, jer su u njemu predočeni prikupljeni svi podatci temeljem kojih se izrađuje daljnja prognoza prometa u PGŽ-u.

U petom poglavlju Prognoza prometnog opterećenja na izabranim lokalnim i županijskim prometnicama do 2030. godine izrađena je detaljna prognoza prometa na izabranim prometnicama koja se bazira na prethodno prikupljenim podatcima i vrijednostima što je i navedeno u samom radu.

Zaključak kao posljednje i šesto poglavlje u radu sažima sve ono što je napisano u završnom radu i daje sažeto mišljenje autora na samu temu završnog rada te potencijalna, moguća poboljšanja.

2. PODRUČJE OBUHVATA

Područje obuhvata prometne studije predstavlja administrativno područje Primorsko - goranske županije. Primorsko - goranska županija na sjeveru graniči s Republikom Slovenijom, na zapadu s Istarskom županijom, na istoku sa Karlovačkom i Ličko-senjskom županijom, a na jugoistoku u Kvarnerskim vratima ima morsku granicu sa Zadarskom županijom. Županiji pripada i dio obalnoga mora s državnom granicom udaljenom 22 km jugozapadno od otoka Suska. Površina kopnenog dijela županije iznosi 3 588 km, a površina akvatorija 1 344 km. Za razliku od susjednih županija, obuhvaća veći broj stalno naseljenih otoka: Krk, Cres, Rab i Lošinj. Grad Rijeka sa 12 8624 stanovnika poslovno je, upravno-administrativno, gospodarsko-kulturno središte županije.

PGŽ ustrojeno je kao jedinica područne (regionalne) samouprave na čijem se području nalazi 36 jedinica lokalne samouprave, od toga 14 gradova. (Institut IGH d.d, 2010., 7.) Za potrebe ovog završnog rada razmatrani su prostor i podaci šireg riječkog područja: Grad Rijeka, Grad Opatija, Grad Kastav, Grad Bakar, Općina Viškovo, Općina Kostrena i područje otoka Krka.

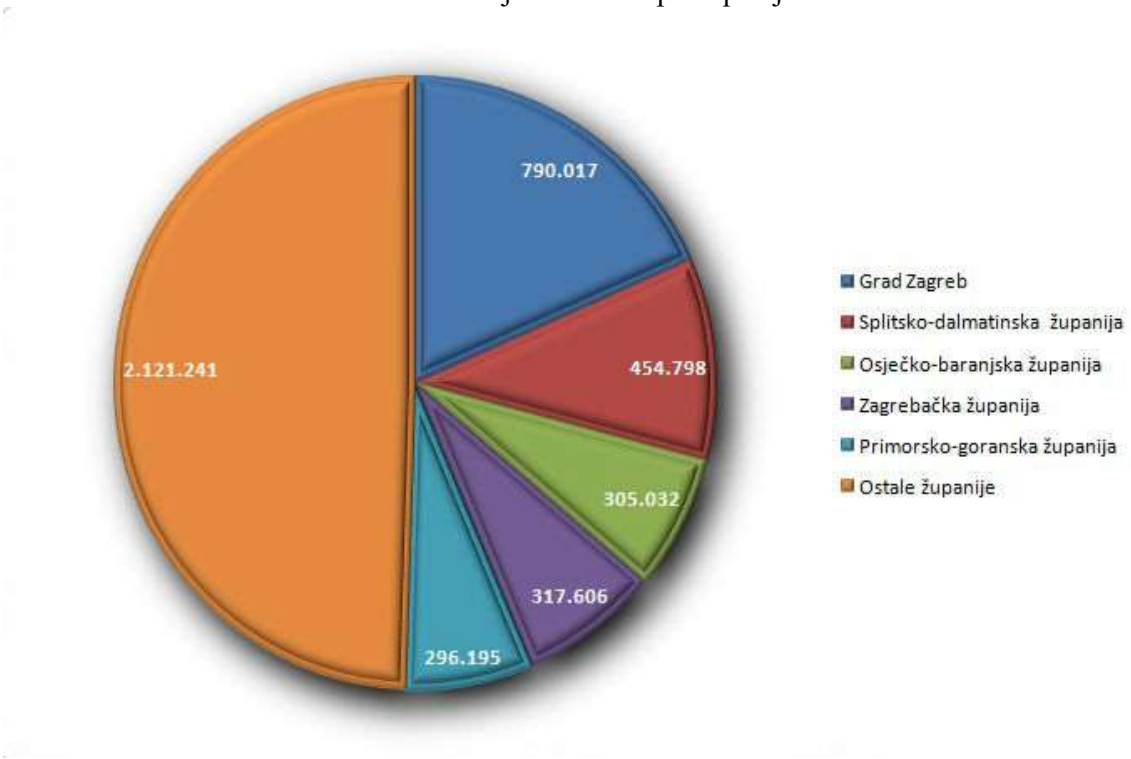
Slika 1.: Područje primorsko - goranske županije



Izvor: http://gkr.hr/O-nama/Za-knjiznicare/Narodne-knjiznice/Narodne-knjiznice-Primorsko-goranske-zupanije (20. 4. 2018.)

Prema rezultatima Popisa stanovništva iz 2011. godine Primorsko - goranska županija ima ukupno 296 195 stanovnika i s udjelom od 6,9 % peta je po veličini u Republici Hrvatskoj (4 284 889). Prema posljednjem Popisu stanovništva broj stanovnika se smanjio za 3,1% u odnosu na Popis stanovništva iz 2001. godine. (Institut IGH d.d, 2010., 9.)

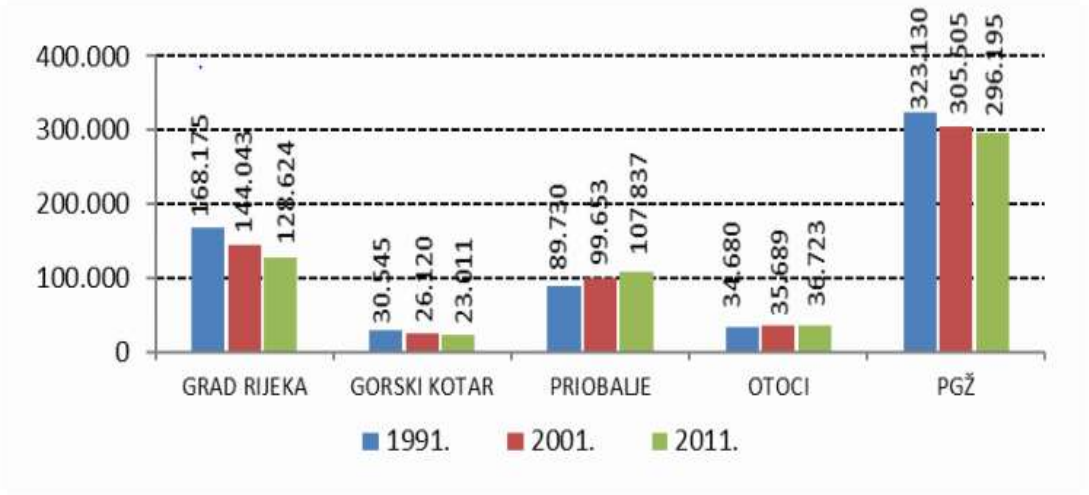
Grafikon 1.: Broj stanovnika po županijama



Izvor: Lajić, I. 2001., 15.

Grad Rijeka - sjedište Primorsko - goranske županije sa 128 624 stanovnika treći je grad po veličini u Hrvatskoj. Najmanji grad u Primorsko - goranskoj županiji po ukupnom broju stanovnika je Grad Cres s 2 879 stanovnika, a najmanja općina je Općina Brod Moravice s 866 stanovnika. (Institut IGH d.d, 2010., 9.)

Grafikon 2.: Ukupan broj stanovništava u PGŽ 1991., 2001. i 2011. godine



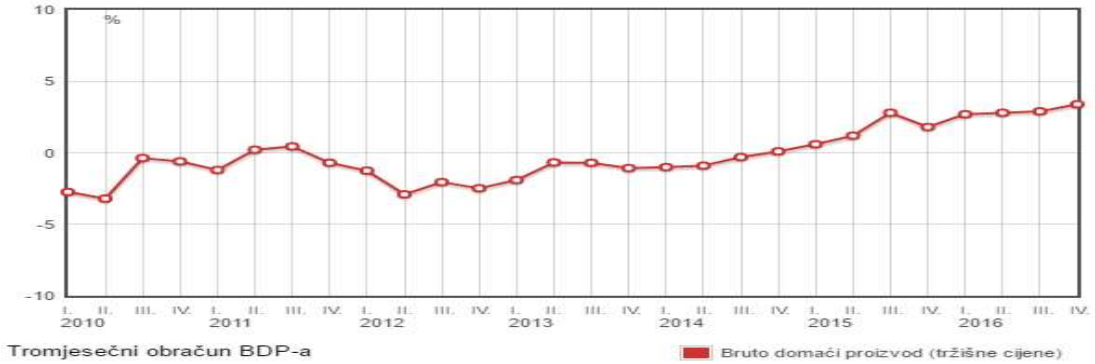
Izvor: Lajić, I. 2001., 18.

3. GOSPODARSKA KRETANJA U PRIMORSKO – GORANSKOJ ŽUPANIJI

Primorsko - goranska županija ubraja se u ekonomski najrazvijenije županije u Republici Hrvatskoj, promatrajući ukupno ostvaren BDP, BDP po stanovniku, kao i udio bruto dodane vrijednosti Županije u ostvarenom BDV-u Republike Hrvatske. Prostor za razvoj cjelokupnog gospodarstva, a isto tako omogućiti njezin održivi razvoj (prerađivačka industrija, turizam, poljoprivreda, šumarstvo i ribarstvo).

Prema podacima Državnog zavoda za statistiku, na području Primorsko - goranske županije je u 2012. godini ostvaren BDP u iznosu od 3.873 mil. eura, što je 8,81% ukupno ostvarenog BDP-a u Republici Hrvatskoj. Iste godine, sve županije Jadranske Hrvatske zajedno su ostvarile BDP u iznosu od 13,929 mil. eura, ili 31,69% ukupno ostvarenog BDP-a u Republici Hrvatskoj. Udio BDP-a Primorsko - goranske županije u ostvarenom BDP-u na razini Jadranske Hrvatske iznosio je 20,80%. Usporede li se podaci s ostalim županijama, Primorsko - goranska županija nalazi se na drugom mjestu po ukupno ostvarenom BDP-u u Republici Hrvatskoj, odmah iza Grada Zagreba (14,675 mil. eura). U razdoblju od 2008. do 2012., ostvareni BDP na razini PGŽ, Jadranske Hrvatske i RH bio je najviši u 2008. godini (PGŽ-3.898 mil. eura; Jadr. Hrv. -15.192 mil. eura; RH-47.543 mil. eura), nakon kojeg je, zbog vrhunca gospodarske krize, došlo do pada BDP-a. BDP RH i BDP Jadranske Hrvatske u razdoblju nakon 2008. godine trajno pada, dok je BDP PGŽ u prvim godinama nakon vrhunca krize padao, da bi u 2011. i 2012. godini ostvario rast (0,79% i 0,27%) u odnosu na prethodnu godinu. U zadnja tri kvartalna razdoblja, BDP ostvaruje uravnotežen rast od 3 %.(Institut IGH d.d, 2010., 12.)

Grafikon 3.: Kretanje BDP-a u PGŽ od 2010. do 2016. godine

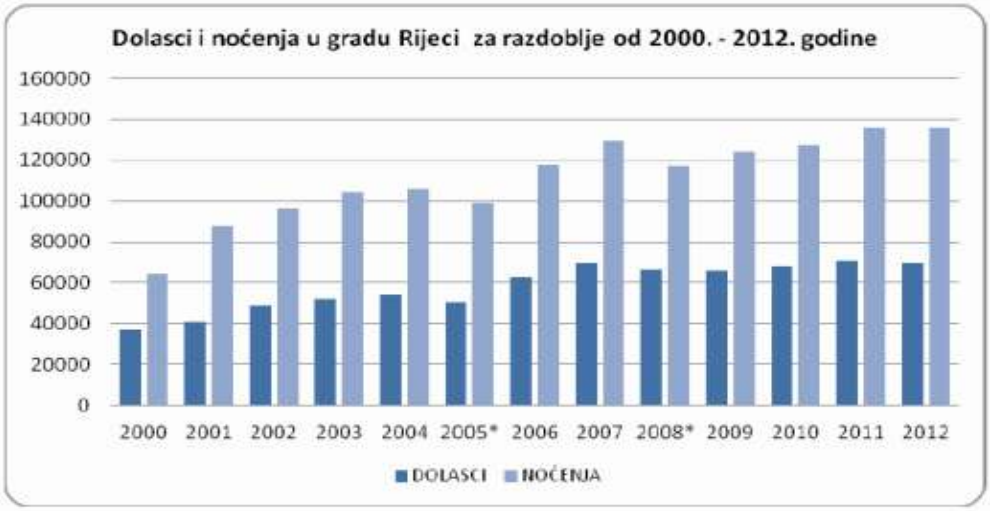


Izvor: www.dsz.hr (20. 4. 2018.)

U proteklih dvadesetak godina ekonomska se struktura riječkoga gospodarstva veoma promijenila, posebice uloga pojedinih sektora gospodarstva. Okosnica gospodarskog razvoja Rijeke oduvijek je bila luka i sve prateće djelatnosti koje su dio uslužnog sektora. Usporedno s tim, u proizvodnji je težište na brodogradnji i stoga je bitno unaprijediti tehnološki i tržišni proboj 3. maja d.d. koji će se u nastavku razvijati u suradnji s Uljanikom d.d.

U strukturi riječkoga gospodarstva primjećuje se i pozitivan trend razvoja turizma, o čemu govore podaci o turističkom prometu na području Grada Rijeke za razdoblje od 2000. do 2012. godine. (Institut IGH d.d, 2010., 12.)

Grafikon 4.: Dolasci i noćenja u gradu Rijeci za razdoblje od 2000. do 2012. godine



Izvor: http://www.visitrijeka.hr/Korisne_informacije/TIC (20. 4. 2018.)

U gospodarstvu PGŽ-a, usprkos snažnom razvoju prerađivačke industrije te visokoj orijentiranosti na izvoz, djelatnosti brodogradnje, drvne i farmaceutske industrije, još uvijek postoji mjesta za njihov daljnji razvoj, kao i za razvoj sinergije između njih i drugih grana prerađivačke industrije. Primjerice, uvoz izrađenih metalnih proizvoda značajno bi se smanjio kada bi se na razini Županije poticala specijalizacija metaloprerađivačke industrije na izradu proizvoda za županijska ali i ostala hrvatska brodogradilišta. Na razini PGŽ nužno je poticati specijalizaciju pojedinih industrija prema onim granama koje čine okosnicu i predvodnicu u razvoju gospodarstva Županije, čime će se smanjiti uvozna ovisnost Županije te potaknuti vlastita proizvodnja. Potrebno je uložiti napore u poboljšanje poslovnog okruženja koje će

aktivno pridonijeti jačanju poduzetničkih aktivnosti i širenju njihovog spektra. Poticanjem diversifikacije ostvariti će se pozitivni učinci na povećanje ponude proizvoda i usluga i postići veća otpornost sustava na iznenadne, nepredvidive tržišne promjene. Specijalizacijom za proizvodnju onih proizvoda za koje postoje razvijeni temeljni čimbenici proizvodnje PGŽ neće imati odgovarajuću konkurenciju iz uvoza.

Značaj djelatnosti prometa i veza za gospodarstvo Primorsko - goranske županije veći je od istoga u bilo kojoj drugoj županiji u Hrvatskoj, a također i u odnosu na cjelokupnu Republiku Hrvatsku, što pokazuju podaci iz 2006. godine o udjelu djelatnosti prometa i veza u ukupnom broju zaposlenih Primorsko - goranske županije i Republike Hrvatske (u Primorsko - goranskoj županiji 12,2%, Republici Hrvatskoj u 9,1%), u ukupnom prihodu (Primorsko - goranska županija 9,4%, Republika Hrvatska 8,1%) , te broju poduzetnika (Primorsko - goranska županija 7,7%, Republika Hrvatska 5,5%), a isto potvrđuju i podaci koji se odnose na prijevozne i pretovarne učinke. Svjetska banka kreditira veliki investicijski projekt „Rijeka Gateway“ za obnovu luke i putničkog terminala (plan 55 mln. USD, a utrošeno 37,3 mln. USD), novi kontejnerski terminal, cestovne infrastrukture i sl. (100 mln. USD). Investicija se izvršava po planu, a rok dovršenja bila je 2010. g. Pored toga djelatnost prijevoza iz tekućeg poslovanja investira 6% ukupnog prihoda i to najviše u opremu 66,6% (44% strana, a 12,6% domaća).

Ukupni promet roba u lukama Primorsko - goranske županije iznosio je 12,6 mln.. t (od toga međunarodni 87,6%). Luka Rijeka je svoj rekordni promet kontejnerima iz 2005. g. od 76.000 TEU u 2006. g. do konca godine 2006. g. povećala na 95.000 TEU (porast 25,0%), a kod suhih tereta na 5,01 mln. t (porast 3,5%). Za cijelu 2007. g. planiran je porast prometa kontejnerima za 20%, a u veljači 2007. već je ostvareno povećanje 10,8% (najviše u međunarodnom prometu 14%) u odnosu na 2006. g. Nagli porast kontejnerskog prometa uzrokovati će zagušenje postojećeg kontejnerskog terminala jer bi promet već iduće godine mogao doseći maksimalni projektirani kapacitet (150.000 TEU) te će trebati poduzeti hitne kratkoročne mjere za smanjenje zagušenja kao i one dugoročne (izgradnja novog terminala na zapadu Rijeke i izgradnja nizinske pruge). (Institut IGH d.d, 2010., 17.)

4. ODREĐIVANJE VRIJEDNOSTI PGDP-a I PLDP-a NA CESTOVNOJ MREŽI

U svrhu ocjene prometa na području Primorsko - goranske županije i Grada Rijeke u određenom vremenskom presjeku, načinjene su prognoze tokova na razmatranim dionicama cestovne mreže. Do elemenata za ocjenu svakoga stupnja razvitka mreže u razmatranome prostoru dolazi se primjenom iste prometne potražnje u danome vremenskom presjeku.

4.1. Ulazni parametri za analizu i prognozu prometa cestovne mreže

Ulazni parametri za projektiranje pojedinih kategorije cestovne mreže (projektna brzina, računska brzina, granični građevinsko-tehnički elementi, slobodni profil itd.) su određeni kroz rezultate prostorno - prometnih analiza o samoj mreži i važećoj zakonskoj regulativi.

Projektna brzina, (Institut IGH d.d, 2010., 22.) kao osnova za ostale elemente projekta, ovisno o kategoriji prometnice je za:

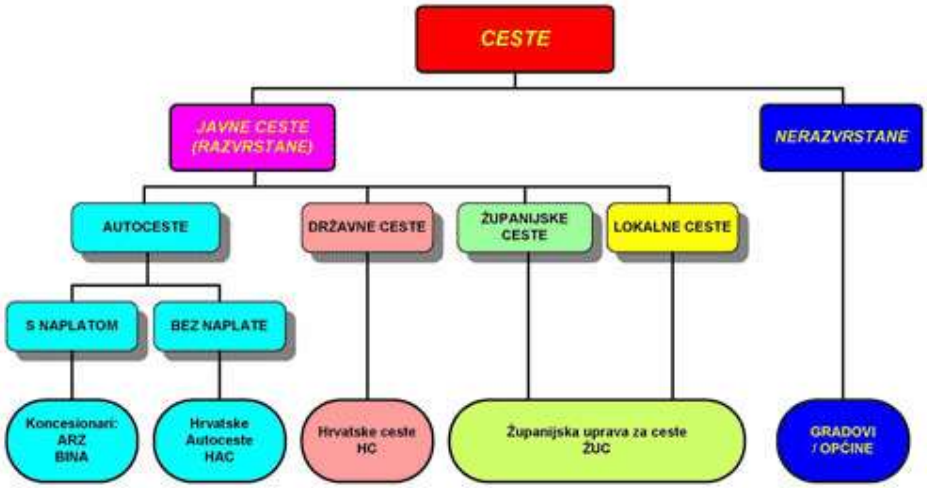
- autoceste Vp = 130 (100) km/h
- brze ceste i gradske autoceste Vp = 100 km/h
- gradske avenije Vp = 80 km/h
- glavne gradske prometnice Vp = 50–70 km/h
- spojne ceste i priključke čvorišta Vp = min 60 km/h

Tablica 1.: Mreža cesta na području Republike Hrvatske razvrstava se kako je prikazano u slijedećoj tablici

R.B.	VRSTE CESTA	NADLEŽNE INSTITUCIJE
1.	Autoceste (sa i bez naplate)	Koncesionar (U PGŽ Autoceste Rijeka-Zagreb te Bina Istra)
2.	Državne ceste	Hrvatske ceste d.o.o. Zagreb
3.	Županijske ceste	Županijska uprava za ceste Primorsko-goranske Županije
4.	Lokalne ceste	Županijska uprava za ceste Primorsko-goranske Županije
5.	Nerazvrstane ceste	Jedinica lokalne samouprave (grad – općina)

Izvor: http://www.hrvatske-ceste.hr/default.aspx (20. 4. 2018.)

Grafikon 5.: Mreža cesta na području Republike Hrvatske razvrstava se kako je prikazano u grafikonu



Izvor: http://www.hrvatske-ceste.hr/default.aspx (20. 4. 2018.)

Duljina autocesta u Primorsko - goranskoj županiji iznosi 133,40 km, državnih cesta 524,00 kn, županijskih cesta 569,10, lokalnih cesta 324,10 što daje da ukupna duljina cesta u PGŽ-u iznosi 1550,60. (Pristup: http://www.hrvatske-ceste.hr/default.aspx 20. 4. 2018.)

Praktična primjena ovih podataka svodi se na dvije uporabne svrhe:

- kalibracija modela postojećega prometnog sustava (cestovne mreže),
- ustanovljenje aktualnih stopa rasta prometne potražnje.

4.2. Promet u mirovanju - postojeće stanje

Svim načinima prometa uključenim u razradu kroz ovaj završni rad, osim prostornih koridora za prometovanje, neophodni su prostori za lociranje početno - završnih terminala te prostori na kojima će se obavljati presjedanje putnika između dvaju ili više načina prijevoza. Upravo su te lokacije one koje iziskuju planiranje prostora za potrebe prometa u mirovanju te, uz nedostajuće parkirališne objekte u užim gradskim centrima, predstavljaju osnovni razlog zbog kojih se prišlo izradi ove prognoze.

Koncepcijsko rješenje prometa u mirovanju na području Primorsko-goranske županije i Grada Rijeke respektira nekoliko činjenica:

- Županija Primorsko - Goranska ima urbanizirano i gusto naseljeno priobalje, slabije nastanjene otoke i nerazvijeno izolirano zaleđe, što ima za posljedicu različiti stupanj i karakter urbaniteta;
- U obalnom dijelu živi 79% od ukupnog broja stanovnika županije (305.505 stanovnika), na otocima 12%, u Gorskom Kotaru 9%;
- Grad Rijeka je metropola županije, sa i sjedištem svih javnih ustanova ima 144.043 stanovnika, što čini 47% sveukupnog stanovništva županije, na svega 4.482 ha, s prosječnom gustoćom od 32 stan/ha;
- stupanj motorizacije znatno je povećan je u odnosu na prethodno desetljeće i utječe na broj potrebnih parkirnih mjesta;
- izraziti porast broja stanovnika (turista) u vrijeme turističke sezone na obalnom i otočnom području;
- nehomogenost urbanizacije i sadržaja na području županije;
- zahtjevi za parkiranjem izbor su korisnika, mogućnosti izbora prijevoznog sredstva moraju dominirati nad potrebama. (Institut IGH d.d, 2010., 83.)

Tablica 2.: Stupanj motorizacije (stanovnici / osobna vozila)

Primorsko-goranska županija		**Broj stanovnika**	**Stupanj motorizacije**
	broj stanovnika	305.505	
	motorna vozila (sva vozila)	163.373	1,87
	osobna vozila	127.958	2,39
Grad Rijeka			
	broj stanovnika	144.043	
	motorna vozila (sva vozila)	72.450	1,99
	osobna vozila	59.485	2,42

Izvor: Institut IGH d.d, 2010., 83.

Za područje županije rezultati istraživanja su različiti. Različitost karaktera pojedinih općina i gradova obzirom na turističke destinacije uvelike utječe i na već izgrađena javna parkirališta i na buduće potrebe.

Područje Gorskog Kotara je urbanistički manje razvijeno. S podatkom da na tom području živi svega 9% stanovnika županije ili oko svega 27.500 stanovnika u pretežno ruralnim uvjetima, potrebe parkirnih mjesta se neće posebno razmatrati.

Na obalnom i otočkom području stanje je različito ovisno o razvijenosti općine i opremljenosti turističkim kapacitetima.

Analizom se može zaključiti da je vrlo mali broj postojećih parkiranja u garažama, svega u tri općine Viškovo, Mali Lošinj i Kastav. To su garaže se manjeg kapaciteta vezane uz trgovačke centre (WTC Viškovo).

Iz tablice je zamjetan velik broj parkirnih mjesta u općinama otoka Krka gdje se broj parkirnih mjesta na parkiralištima kreće od 2,5-5 stan/PM. U Malom Lošinju, broj stanovnika u samom gradu je 6.296, a broj parkirnih mjesta 1.315 na javnim parkiralištima odnosno 6

stan/PM. Nedostatak se osjeća na priobalnim općinama – Grad Crikvenica 9 stan/PM. Grad Opatija 12 stan/PM, Lovran 13,8 stan/PM, Grad Rab 20,4 stan/PM, te Kastav sa 20 stan/PM. Na ovom području izrazit je nedostatak parkirnih mjesta tijekom turističke sezone o kojima nemamo podatke, u vremenu potražnje za plažama i kupalištima, kada se uz domaće stanovnike slijeva obično u centre i velik broj turista i velik broj posjetitelja iz okolnih mjesta. (Institut IGH d.d, 2010., 84.)

Tablica 3.: Prikaz sadašnjih i planiranih parkirnih mjesta u Primorsko - goranskoj županiji

Red .br.	**Općina/Grad**	**broj stanovnika**	**broj potrebnih parkirnih mjesta**	**Postojeća parkiranja**		**Planirana /buduća parkiranja**		
				Garaže	**Otvorena parkiranja**	**Garaže**	**Otvorena parkiranja**	**Napomena**
1.	Grad Bakar	7.773	1.690		3.100	*	*	2.600 PM Radna zona
2.	Grad Cres	2.959	643		630		2.300	
3.	Grad Crikvenica	11.348	2.467		1.170	675	415	
4.	Grad Čabar	4.387	954		90		100	
5.	Grad Delnice	6.262	1.361		550		200	
6.	Grad Kastav	8.891	1.933	50	300	450	250	
7.	Grad Kraljevica	4.579	995		500		200	
8.	Grad Krk	5.491	1.194		1.240	300		140 PM GP Krk
9.	Grad Mali Lošinj	8.388	1.823	215	1.100	700	1.785	Planirano 550 PM u okolnim mjestima
10.	Grad Novi Vinodolski	5.282	1.148		514	300	400	
11.	Grad Opatija	12.719	2.765		1.131	790		330 PM u garaži Slatina u gradnji
12.	Grad Rab	9.480	2.061		450			
13.	Grad Vrbovsko	6.047	1.315		180			
14.	Općina Baška	1.554	338		700	*	*	

15.	Općina Brod Moravice	985	214		0		*	
16.	Općina Čavle	6.749	1.467		1.150			390 PM TC Metro
17.	Općina Dobrinj	1.970	428		80		*	
18.	Općina Fužine	1.855	403		120	60	60	
19.	Općina Jelenje	4.877	1.060		120		100	
20.	Općina Klana	1.931	420		100		60	
21.	Općina Kostrena	3.897	847		1.100	200	190	500 PM brodogradilišt e V. Lenac
22.	Općina Lokve	1.120	243		60		*	
23.	Općina Lopar	1.191	259		120		*	
24.	Općina Lovran	3.984	866		320		140	
25.	Općina Malinska Dubašnica	2.726	593		600	100		
26.	Općina Matulji	10.544	2.292		310	415	500	
27.	Općina Mošćenička Draga	1.641	357		360	200		
28.	Općina Mrkopalj	1.407	306		120			
29.	Općina Omišalj	2.998	652		820		*	
30.	Općina Punat	2.724	592		750		*	350 PM u marini Punat
31.	Općina Ravna Gora	2.724	592		110		*	
32.	Općina Skrad		0		70		*	
33.	Općina Vinodolska	3.530	767		0		*	
34.	Općina Viškovo	8.907	1.936	75	980		*	480 PM u Radnoj zoni
35.	Općina Vrbnik	1.245	271		180		*	

Izvor: Institut IGH d.d, 2010., 81.

4.3. Zakonitosti razvitka

Ova ocjena nema, barem izravne i/ili ciljane, prometno - sektorske analize društvenog i gospodarskog zonalnog razvitka područja istraživanja koja bi metodološki odgovarala potrebama prognoze. Stoga ova ocjena uključuje, temeljem svih dosadašnjih prosudbi, postavu

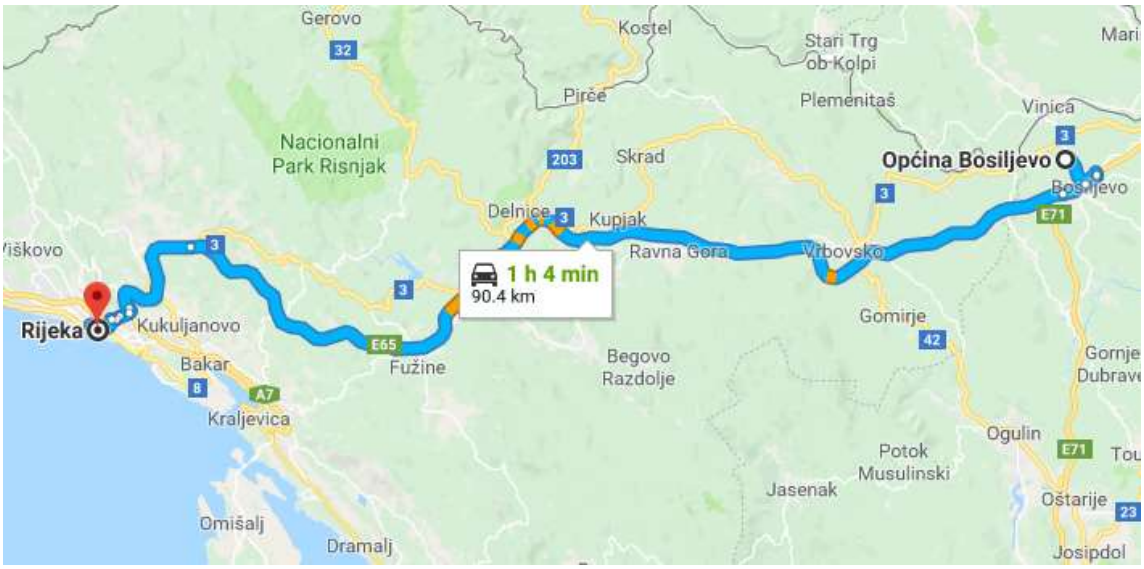
zakonitosti mogućeg rasta i pojavnosti novih i divergiranih međuzonskih putovanja od startne 2008. godine do kraja planskog perioda 2030. godine. Sažeto:

- za gradske ceste pretpostavlja se rast od 1% godišnje što se odnosi na uže i šire područje Grada Rijeke i u ostalim urbanim sredinama na što ukazuju podatci o dosadašnjem kretanju prometa,
- za državne ceste pretpostavlja se rast (pad) prosječnog ljetnog dnevnog prometa od 1,5 %, te prosječnog godišnjeg dnevnog prometa od 1% što se odnosi na izabrane državne ceste na području Primorsko - goranske županije, prema prikupljenim podatcima,
-za autoceste pretpostavlja se rast prosječnog ljetnog dnevnog prometa od 2,5 %, te prosječnog godišnjeg dnevnog prometa od 2% na izabranim autocestama na području Primorsko - goranske županije prema prikupljenim podatcima o kretanju prometa u prethodnim godinama i zbog toga što se pretpostavlja da će se autoceste sve više koristiti.

Smatra se da su zakonitosti razvitka prometne potražnje po zonama i u konačnici na razmatranom prostoru procijenjene konzervativno. To je učinjeno u ovom koraku procjene razvitka prometnog sustava ovog područja, ne samo zbog nedostatka valjanih makro-ekonomskih i usuglašenih integracijskih planova regionalnog i europskoga razvitka, nego većinom zbog potrebe da se društveno - gospodarska opravdanost ulaganja u razvitak ovoga segmenta države ocijeni s donjega praga i/ili niskoga rizika te nešto više pouzdanosti.

4.4. Prikupljeni podatci PGDP-a i PLDP-a na izabranim autocestama u Primorsko-goranskoj županiji

Slika 2.: Autocesta A6 - Čvor Bosiljevo



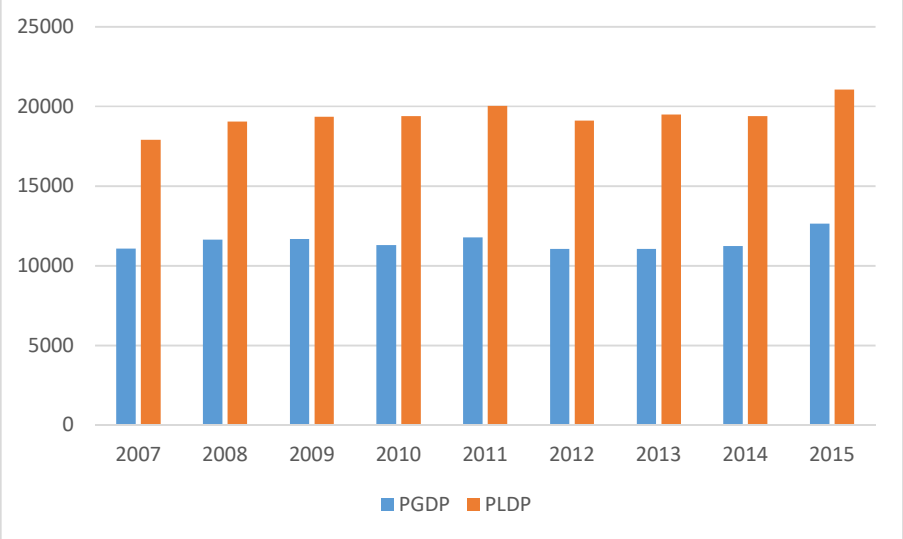
Izvor: Google Maps (17. 5. 2018.)

Tablica 4.: Prikupljeni podatci PGDP-a i PLDP-a na autocesti A6, čvor Bosiljevo – brojanje prometa od 2007. do 2015. godine.

Godina	**2007**	**2008**	**2009**	**2010**	**2011**	**2012**	**2013**	**2014**	**2015**
PGDP	11075	11645	11678	11293	11767	11055	11058	11239	12631
PLDP	17903	19061	19332	19388	20032	19107	19496	19404	21055
PROSJEK	14489	15353	15505	15340,5	15899,5	15081	15277	15321,5	16843

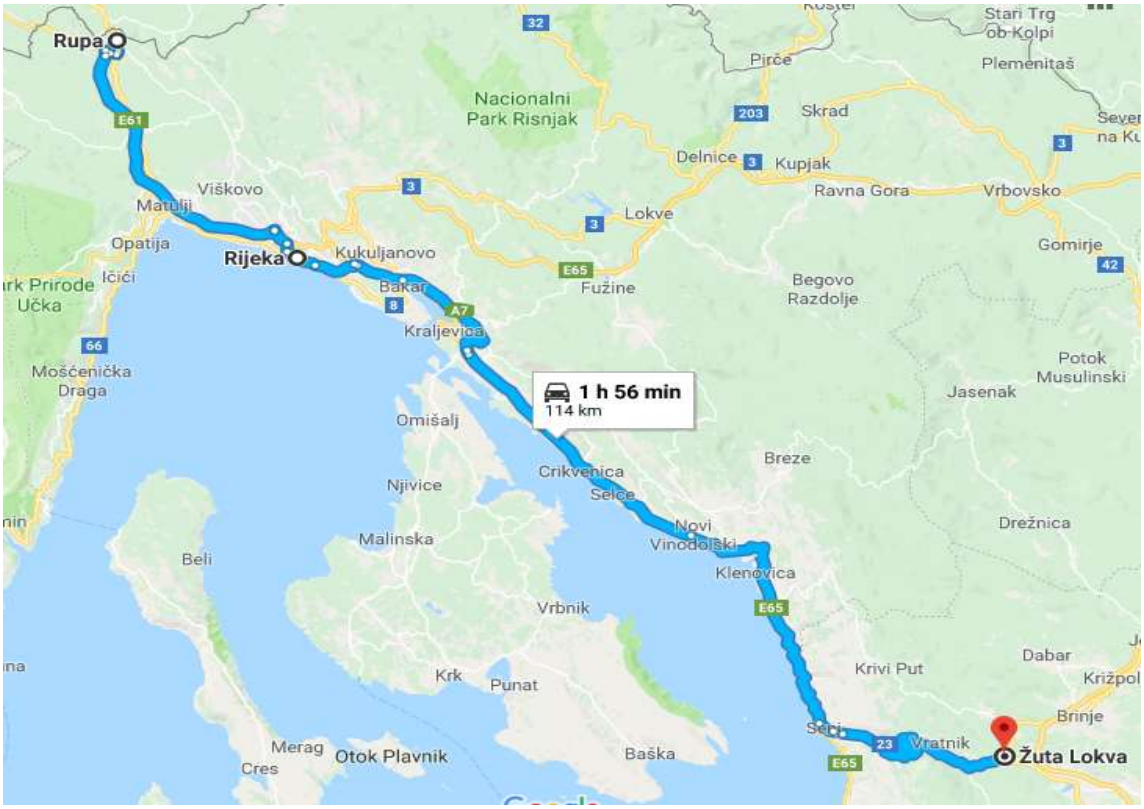
Izvor: http://www.hrvatske-ceste.hr/default.aspx?id=46 (15. 4. 2018.)

Grafikon 6.: PGDP-a i PLDP-a na autocesti A6



Izvor: Izrada autora

Slika 3.: Autocesta A7 - Čvor Rupa



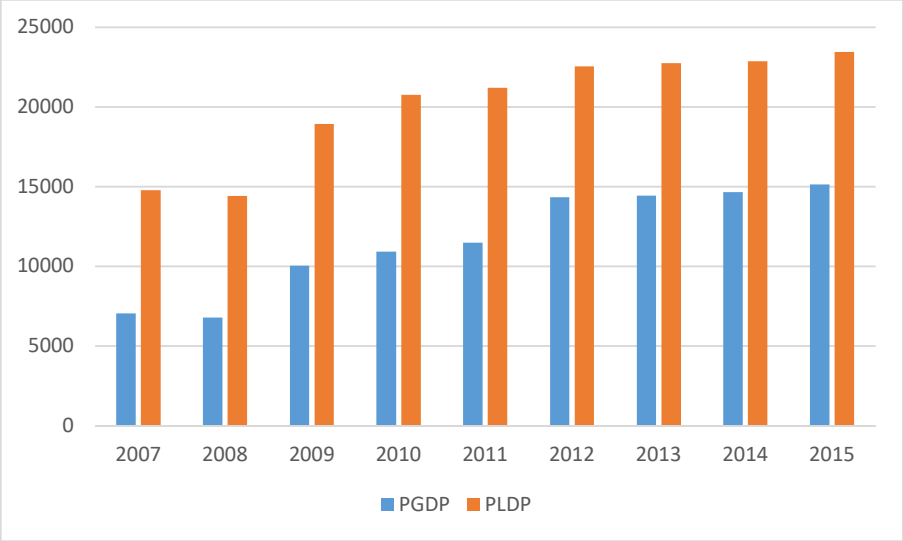
Izvor: Google Maps (17. 5. 2018.)

Tablica 5.: Prikupljeni podatci PGDP-a i PLDP-a na autocesti A7 čvor Rupa, – brojanje prometa od 2007. do 2015. godine.

Godina	2007	2008	2009	2010	2011	2012	2013	2014	2015
PGDP	7051	6781	10041	10916	11487	14337	14431	14661	15123
PLDP	14765	14405	18934	20760	21214	22548	22759	22875	23458
PROSJEK	10908	10593	14487,5	15838	16350,5	18442,5	18595	18768	19290,5

Izvor: http://www.hrvatske-ceste.hr/default.aspx?id=46 (15. 4. 2018.)

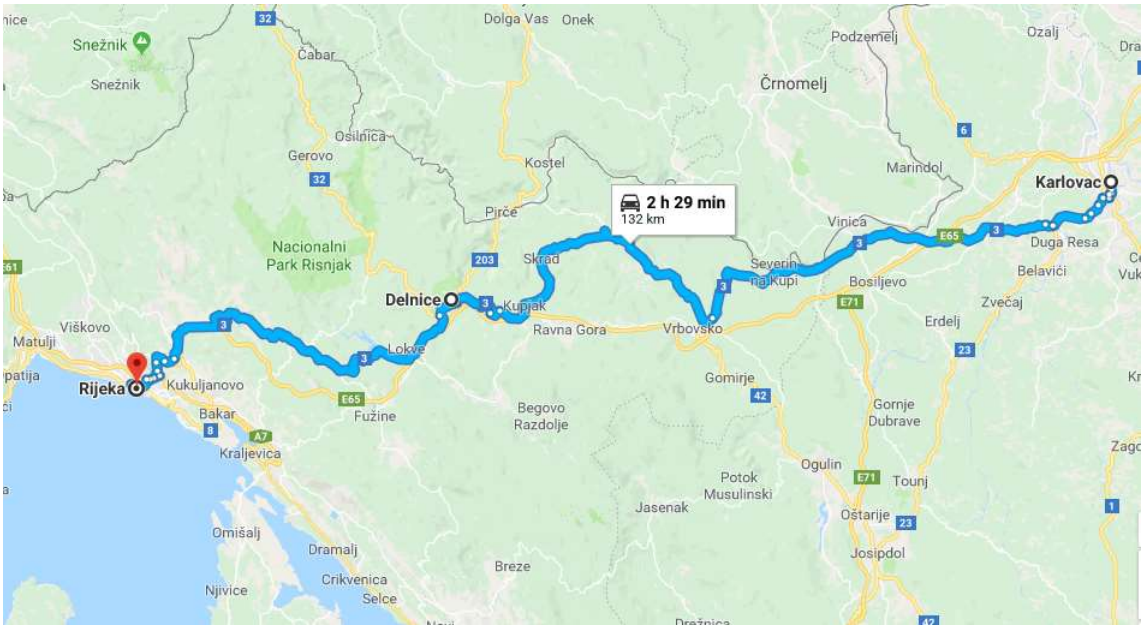
Grafikon 7.: PGDP-a i PLDP-a na autocesti A7



Izvor: Izrada autora

4.5. Prikupljeni podatci PGDP-a i PLDP-a na izabranim državnim cestama u Primorsko-goranskoj županiji

Slika 4.: Državna cesta D3 Karlovac - Delnice – Rijeka



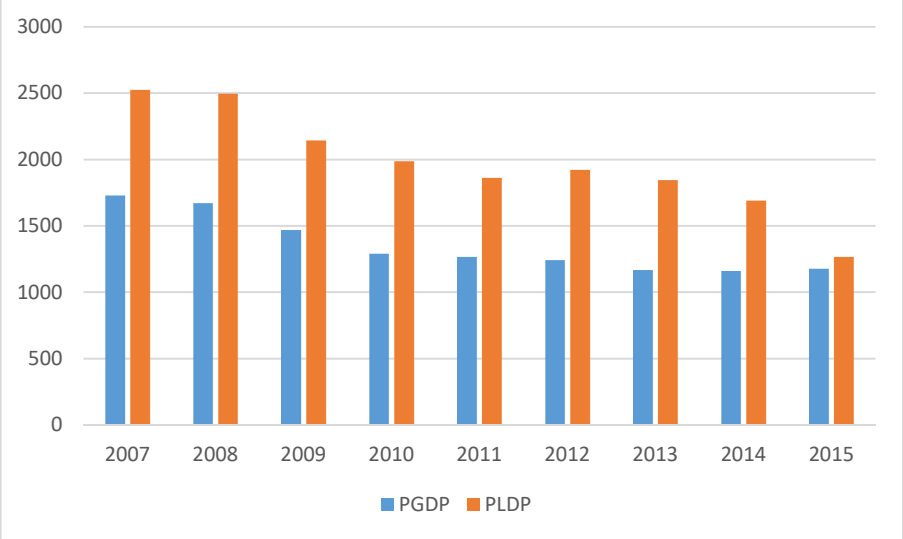
Izvor: Google Maps (17. 5. 2018.)

Tablica 6.: Prikupljeni podatci PGDP-a i PLDP-a na državnoj cesti D3 Karlovac - Delnice - Rijeka (mjerno mjesto Vrbovsko)

Godina	2007	2008	2009	2010	2011	2012	2013	2014	2015
PGDP	1729	1670	1469	1291	1268	1242	1168	1160	1177
PLDP	2525	2495	2143	1987	1860	1923	1845	1691	1267
PROSJEK	2127	2082,5	1806	1639	1564	1582,5	1506,5	1425,5	1222

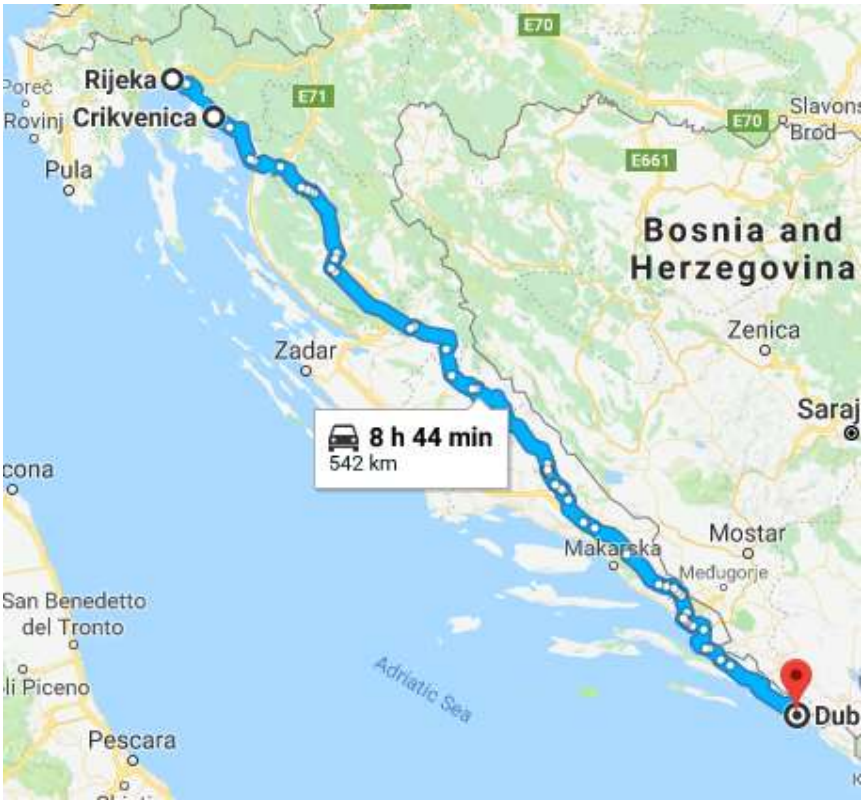
Izvor: http://www.hrvatske-ceste.hr/default.aspx?id=46 (15. 4. 2018.)

Grafikon 8.: PGDP-a i PLDP-a na državnoj cesti D3 Karlovac - Delnice - Rijeka



Izvor: Izrada autora

Slika 5.: Državna cesta D8 - Jadranska magistrala (Crikvenica)



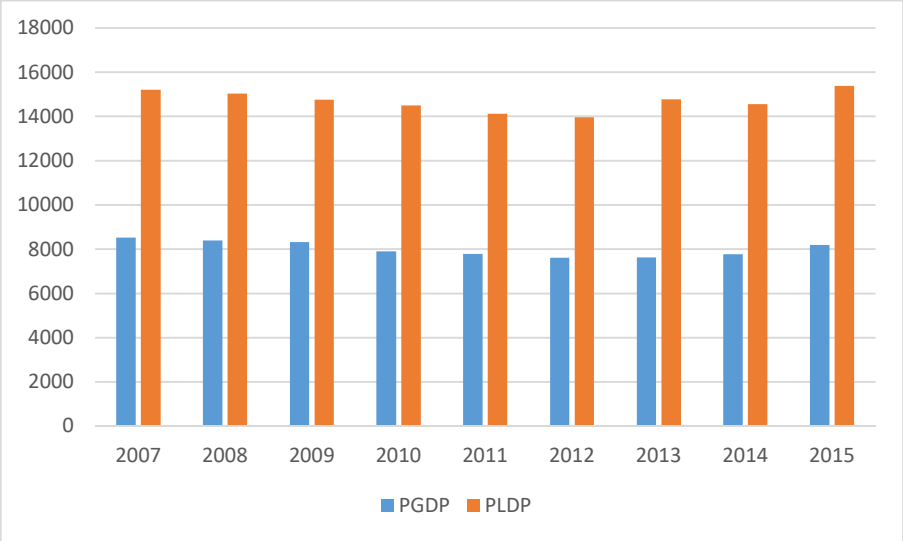
Izvor: Google Maps (17. 5. 2018.)

Tablica 7.: Prikupljeni podatci PGDP-a i PLDP-a na državnoj cesti D8 Jadranska magistrala (Crikvenica)

Godina	2007	2008	2009	2010	2011	2012	2013	2014	2015
PGDP	8527	8390	8326	7899	7789	7620	7637	7763	8194
PLDP	15204	15026	14752	14493	14132	13968	14768	14545	15383
PROSJEK	11865,5	11708	11539	11196	10960,5	10794	11202,5	11154	11788,5

Izvor: http://www.hrvatske-ceste.hr/default.aspx?id=46 (15. 4. 2018.)

Grafikon 9.: PGDP-a i PLDP-a na državnoj cesti D8 Jadranska magistrala



Izvor: Izrada autora

Slika 6.: Državna cesta D32 Čabar - Gerovo –Delnice



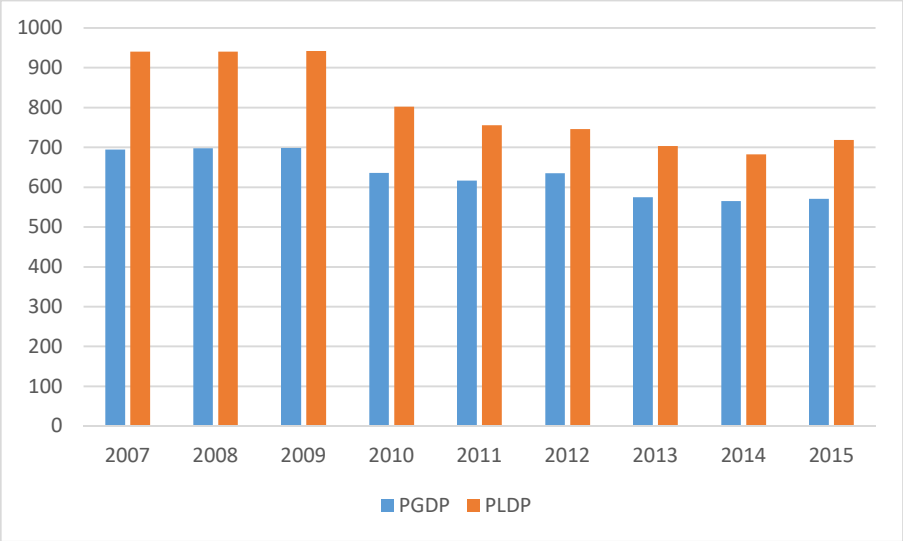
Izvor: Google Maps (17. 5. 2018.)

Tablica 8.: Prikupljeni podatci PGDP-a i PLDP-a na državnoj cesti D32 Čabar - Gerovo - Delnice (mjerno mjesto Crni lug)

Godina	2007	2008	2009	2010	2011	2012	2013	2014	2015
PGDP	695	698	699	636	617	635	575	565	571
PLDP	940	940	942	802	756	746	703	683	719
PROSJEK	817,5	819	820,5	719	686,5	690,5	639	624	645

Izvor: http://www.hrvatske-ceste.hr/default.aspx?id=46 (15. 4. 2018.)

Grafikon 10.: PGDP-a i PLDP-a na državnoj cesti D32 Čabar - Gerovo –Delnice



Izvor. Izrada autora

4.6. Prikupljeni podatci PGDP-a i PLDP-a u centru Grada Rijeke

Slika 7.: Grad Rijeka – centar



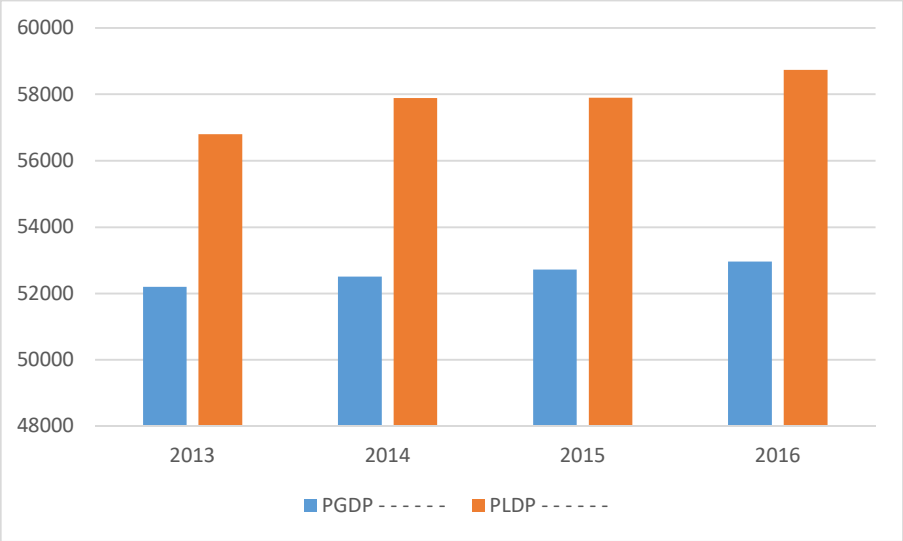
Izvor: Google Maps (17. 5. 2018.)

Tablica 9.: Prikupljeni podatci PGDP-a i PLDP-a centar Grada Rijeke

Godina	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
PGDP	-	-	-	-	-	-	52205	52512	52718	52960
PLDP	-	-	-	-	-	-	56796	57894	57902	58737
PROSJEK	-	-	-	-	-	-	54500,5	55203	55310	55848,5

Izvor: http://www.hrvatske-ceste.hr/default.aspx?id=46 (15. 4. 2018.)

Grafikon 11.: PGDP-a i PLDP-a centar Grada Rijeke



Izvor: Izrada autora

5. PROGNOZA PROMETNOG OPTEREĆENJA NA IZABRANIM LOKALNIM I ŽUPANIJSKIM PROMETNICAMA DO 2030. GODINE

Kako bi se upotpunilo istraživanje razine usluga županijskih i lokalnih prometnica na području primorsko - goranske županije, osim postojećeg stanja valja poznavati i buduće stanje prometnog opterećenja. Naime, tek u sklopu poznavanja prognoziranog prometnog opterećenja tih cesta moći će se steći prava slika o njihovoj kvaliteti s gledišta odnosa njihove propusne moći i prometnih tokova u duljem vremenskom razdoblju.

5.1. Prognoza prometnog opterećenja na izabranim autocestama u Primorsko-goranskoj županiji

Na autocestama je prognoziran rast godišnjeg dnevnog prometa (PGDP-a) od 2% zbog porasta korištenja autocesta u odnosu na ostale ceste, te rast ljetnog dnevnog prometa (PLDP-a) od 2,50% zbog turističke sezone i povećanja broja putovanja.

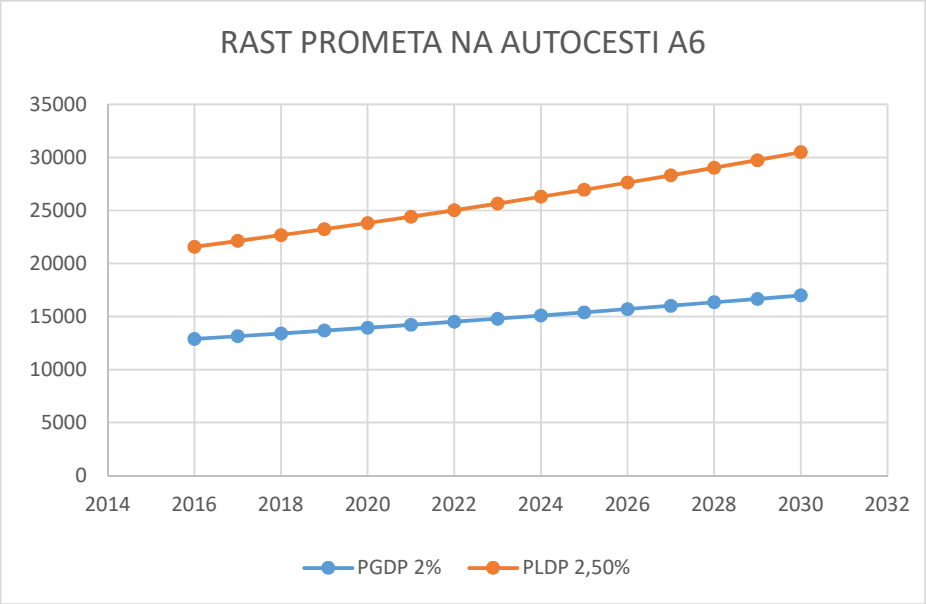
5.1.1. Prognoza prometnog opterećenja na autocesti A6 – PGDP i PLDP

Tablica 10.: Prognoza prometnog opterećenja na autocesti A6, čvor Bosiljevo

Godina	PGDP 2%	PLDP 2,50%
2016	12883	21581
2017	13141	22120
2018	13404	22673
2019	13672	23240
2020	13945	23821
2021	14224	24417
2022	14509	25027
2023	14799	25653
2024	15095	26294
2025	15397	26952
2026	15705	27625
2027	16019	28316
2028	16339	29024
2029	16666	29750
2030	16999	30493

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Grafikon 12.: Prognoza prometnog opterećenja na autocesti A6, čvor Bosiljevo



Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 10 sačinjeni su matematički regresijski modeli prognoze cestovnoga prometa na ovoj dionici autoceste A6. U tablici 11 nalaze se podatci potrebni za izradu matematičkih regresijskih modela.

Tablica 11.: Podatci za analizu modela prognoze cestovnoga prometa na autocesti A6 - PGDP

Godina	yi	xi
2007	11075	1
2008	11645	2
2009	11678	3
2010	11293	4
2011	11767	5
2012	11055	6
2013	11058	7
2014	11239	8
2015	12631	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 11 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 12: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	**0,315219487**
R Square	0,099363325
Adjusted R Squar	-0,029299057
Standard Error	518,2814765
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	207446,4	207446,4	**0,772279538**	0,408663619
Residual	7	1880309,822	268615,6889		
Total	8	2087756,222			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	**11199,44444**	376,5227634	29,74440202	1,25109E-08	10309,10959	12089,7793	10309,10959	12089,7793
X Variable 1	**58,8**	66,90985091	**0,878794366**	0,408663619	-99,41665612	217,0166561	-99,41665612	217,0166561

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 11199,44 + 58,8 X uz R = 0,315219, F = 0,77, t = 0,878

Mala vrijednost pokazatelja R upućuje na matematičku i statističku ne upotrebljivost regresijskog modela u ovom slučaju. Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na autocesti A6 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 13.

Tablica 13.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na autocesti A6

Cesta	PGDP 2015.	PGDP 2030. MPSR	PGDP 2030. RM	Razlika
A6	12631	16999	12610	4389

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 13. vidljivo je da su rezultati prognoze na autocesti A6 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

Tablica 14.: Podatci za analizu modela prognoze cestovnoga prometa na autocesti A6 – PLDP

Godina	yi	xi
2007	17903	1
2008	19061	2
2009	19332	3
2010	19388	4
2011	20032	5
2012	19107	6
2013	19496	7
2014	19404	8
2015	21055	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 14 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 15.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,747143552
R Square	0,558223487
Adjusted R Squar	0,495112557
Standard Error	593,9989525
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	3120864,267	3120864,267	8,845115787	0,020687896
Residual	7	2469843,289	352834,7556		
Total	8	5590707,556			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	**18279,44444**	431,5302344	42,35959149	1,06623E-09	17259,03759	19299,8513	17259,03759	19299,8513
X Variable 1	**228,0666667**	76,68493502	2,974073938	0,020687896	46,73560958	409,3977238	46,73560958	409,3977238

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 18279,44 + 228,06 X uz R = 0,747143, F = 8,84, t = 2,974

Usporedba procjene dobivenih rezultata o prosječnom ljetnim dnevnom prometu na autocesti A6 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 16.

Tablica 16.: Usporedba procjene dobivenih rezultata o prosječnom ljetnom dnevnom prometu na autocesti A6

Cesta	PLDP 2015.	PLDP 2030. MPSR	PLDP 2030. RM	Razlika
A6	12631	30493	23753	6740

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 16 vidljivo je da su rezultati prognoze na autocesti A6 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

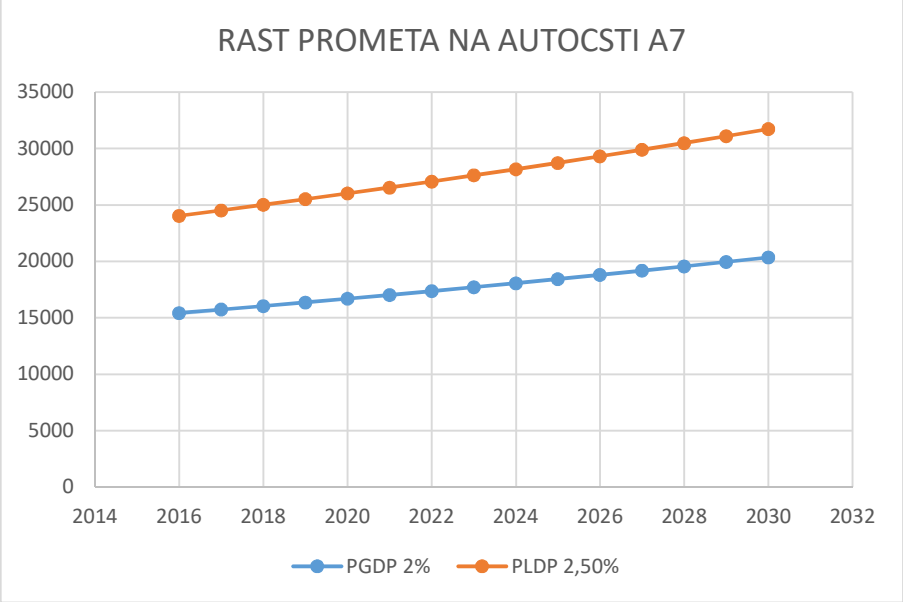
5.1.2. Prognoza prometnog opterećenja na autocesti A7 – PGDP i PLDP

Tablica 17.: Prognoza prometnog opterećenja na autocesti A7, čvor Rupa

Godina	PGDP 2%	PLDP 2,50%
2016	15425	24044
2017	15733	24525
2018	16048	25015
2019	16369	25516
2020	16697	26026
2021	17030	26547
2022	17371	27077
2023	17719	27619
2024	18073	28171
2025	18434	28735
2026	18803	29310
2027	19179	29896
2028	19563	30494
2029	19954	31104
2030	20353	31726

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Grafikon 13.: Prognoza prometnog opterećenja na autocesti A7, čvor Rupa



Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 17 sačinjeni su matematički regresijski modeli prognoze cestovnoga prometa na ovoj dionici autoceste A7. U tablici 18 nalaze se podatci potrebni za izradu matematičkih regresijskih modela.

Tablica 18.: Podatci za analizu modela prognoze cestovnoga prometa na autocesti A7 - PGDP

Godina	yi	xi
2007	7051	1
2008	6781	2
2009	10041	3
2010	10916	4
2011	11487	5
2012	14337	6
2013	14431	7
2014	14661	8
2015	15123	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 18 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 19.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,959122672
R Square	0,9199163
Adjusted R Squar	0,908475771
Standard Error	980,8560551
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	77359344,02	77359344,02	80,40854869	4,36856E-05
Residual	7	6734550,206	962078,6008		
Total	8	84093894,22			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	5970,138889	712,5754037	8,378255631	6,7786E-05	4285,165808	7655,11197	4285,165808	7655,11197
X Variable 1	1135,483333	126,6279722	8,967081392	4,36856E-05	836,0557593	1434,910907	836,0557593	1434,910907

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 5970,13888 + 1135,48 X uz R = 0,95912267, F = 80,40, t = 8,967

Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na autocesti A7 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 20.

Tablica 20.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na autocesti A7

Cesta	PGDP 2015.	PGDP 2030. MPSR	PGDP 2030. RM	Razlika
A7	15123	20353	33221	-12868

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 20 vidljivo je da su rezultati prognoze na autocesti A7 značajno različite, odnosno da su prognoze utemeljene na metodi regresijske analize rasta značajno optimističnije.

Tablica 21.: Podatci za analizu modela prognoze cestovnoga prometa na autocesti A7 – PLDP

Godina	yi	xi
2007	14765	1
2008	14405	2
2009	18934	3
2010	20760	4
2011	21214	5
2012	22548	6
2013	22759	7
2014	22875	8
2015	23458	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 21 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 22.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,917817366
R Square	0,842388717
Adjusted R Squar	0,81987282
Standard Error	1469,422735
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	80782406,67	80782406,67	37,41306405	0,000483111
Residual	7	15114422,22	2159203,175		
Total	8	95896828,89			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	14389,22222	1067,510868	13,47922785	2,90417E-06	11864,96013	16913,48431	11864,96013	16913,48431
X Variable 1	1160,333333	189,7016594	6,116621948	0,000483111	711,760189	1608,906478	711,760189	1608,906478

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 14389,22 + 1160,33 X uz R = 0,9178173, F = 37,413064, t = 6,1166

Usporedba procjene dobivenih rezultata o prosječnom ljetnim dnevnom prometu na autocesti A7 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 23.

Tablica 23.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem ljetnom prometu na autocesti A7

Cesta	PLDP 2015.	PLDP 2030. MPSR	PLDP 2030. RM	Razlika
A7	23458	31726	42237	-10511

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 23 vidljivo je da su rezultati prognoze na autocesti A7 značajno različite, odnosno da su prognoze utemeljene na metodi regresijske analize rasta značajno optimističnije.

5.2. Prognoza prometnog opterećenja na izabranim državnim cestama u Primorsko-goranskoj županiji

U nastavku je prikazana prognoza cestovnog prometa na mreži državnih cesta (D3, D8 i D32) do 2030. godine metodom prosječne stope (fiksne prosječne stopa rasta ili pada postotka za državne ceste) i matematičkim regresijskim modelom koje se temelji na rezultatima brojanja za razdoblje od 2007. do 2015. godine.

5.2.1. Prognoza prometnog opterećenja na državnoj cesti D3 – PGDP i PLDP

Na državnoj cesti D3 Karlovac - Delnice - Rijeka prognoziran je pad godišnjeg dnevnog prometa od (PGDP) -1,50% zbog povećanja korištenja autocesta, dok je za istu cestu

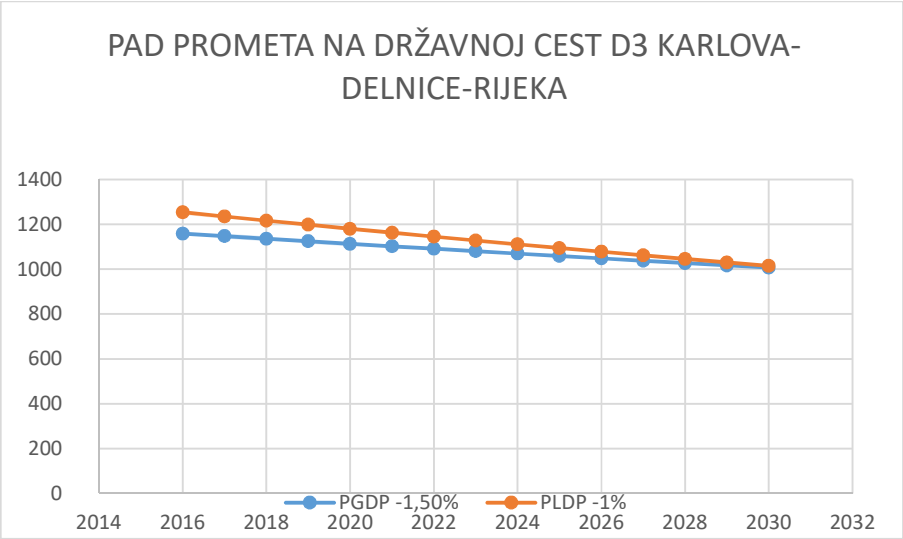
prognoziran pad od -1% za ljetni dnevni promet (PLDP), nešto manji pad zbog turističke sezone.

Tablica 24.: Prognoza prometnog opterećenja na državnoj cesti D3 Karlovac - Delnice – Rijeka

Godina	PGDP -1,50	PLDP -1%
2016	1159	1254
2017	1147	1235
2018	1136	1216
2019	1124	1198
2020	1113	1180
2021	1102	1163
2022	1091	1145
2023	1080	1128
2024	1069	1111
2025	1059	1094
2026	1048	1078
2027	1038	1062
2028	1027	1046
2029	1017	1030
2030	1007	1015

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Grafikon 14.: Prognoza prometnog opterećenja na državnoj cesti D3 Karlovac - Delnice – Rijeka



Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 24 sačinjeni su matematički regresijski modeli prognoze cestovnoga prometa na ovoj dionici državne ceste D3. U tablici 25 nalaze se podatci potrebni za izradu matematičkih regresijskih modela.

Tablica 25.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D3 – PGDP

Godina	yi	x1
2007	1729	1
2008	1670	2
2009	1469	3
2010	1291	4
2011	1268	5
2012	1242	6
2013	1168	7
2014	1160	8
2015	1177	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 25 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 26.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,917775154
R Square	0,842311234
Adjusted R Squar	0,819784268
Standard Error	92,66271403
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	321055,35	321055,35	37,39124094	0,000483959
Residual	7	60104,65	8586,378571		
Total	8	381160			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	1718,416667	67,31790105	25,52689017	3,61702E-08	1559,235125	1877,598208	1559,235125	1877,598208
X Variable 1	-73,15	11,96270494	-6,114837769	0,000483959	-101,4373022	-44,86269778	-101,4373022	-44,86269778

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 1718,41666 + (-73,15) X uz R = 0,917775, F = 37,39, t = -6,11

Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D3 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 27.

Tablica 27.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D3

Cesta	PGDP 2015.	PGDP 2030. MPSR	PGDP 2030. RM	Razlika
D3	1177	1007	0	1007

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 27 vidljivo je da su rezultati prognoze na državnoj cesti D3 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

Prognoza prometa temeljem regresijske analize na državnoj cesti D3 ne iskazuje pravovaljane podatke jer je prognoza prometa u 2030. temeljem regresijske analize iskazana negativnom vrijednošću, zbog znatnog pada prometa u razdoblju od 2007. do 2015. godine. Zato su se za izračun regresijske analize uzeli podatci o prometnom opterećenju od 2010. do 2015. godine.

Tablica 28.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D3 – PGDP (od 2010. do 2015.)

Godina	yi	xi
2010	1291	1
2011	1268	2
2012	1242	3
2013	1168	4
2014	1160	5
2015	1177	6

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 28 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 29.: Ispis obrade u programu EXCEL

Regression Statistics								
Multiple R	0,916125707							
R Square	0,839286311							
Adjusted R Squar	0,799107889							
Standard Error	25,31440396							
Observations	6							
ANOVA								
	df	*SS*	*MS*	*F*	*Significance F*			
Regression	1	13386,05714	13386,05714	20,88898136	0,010257322			
Residual	4	2563,27619	640,8190476					
Total	5	15949,33333						
	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	1314,466667	23,56642756	55,77708642	6,18583E-07	1249,035774	1379,897559	1249,035774	1379,897559
X Variable 1	-27,65714286	6,051299967	-4,570446517	0,010257322	-44,45824503	-10,85604068	-44,45824503	-10,85604068

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 1314,4666 + (-27,65) X uz R = 0,9161257, F = 37,39, t = -4,57

Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D3 uzimajući podatke od 2010. godine do 2015. godine, temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 30.

Tablica 30.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D3

Cesta	PGDP 2015.	PGDP 2030. MPSR	PGDP 2030. RM	Razlika
D3	1177	1007	733	274

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 30 vidljivo je da su rezultati prognoze na državnoj cesti D3 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

Tablica 31.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D3 – PLDP

Godina	yi	x1
2007	2525	1
2008	2495	2
2009	2143	3
2010	1987	4
2011	1860	5
2012	1923	6
2013	1845	7
2014	1691	8
2015	1267	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 31 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 32.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,94882073
R Square	0,900260778
Adjusted R Squar	0,886012318
Standard Error	131,6205224
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	1094580,267	1094580,267	63,18302203	9,49634E-05
Residual	7	121267,7333	17323,9619		
Total	8	1215848			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	2646	95,62009264	27,67200833	2,0663E-08	2419,89441	2872,10559	2419,89441	2872,10559
X Variable 1	-135,0666667	16,99213637	-7,948774876	9,49634E-05	-175,2466844	-94,88664892	-175,2466844	-94,88664892

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 2646 + (-135,066) X uz R = 0,9488207, F = 63,18, t = -7,948

Usporedba procjene dobivenih rezultata o prosječnom ljetnim dnevnom prometu na državnoj cesti D3 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 33.

Tablica 33.: Usporedba procjene dobivenih rezultata o prosječnom ljetnom dnevnom prometu na državnoj cesti D3

Cesta	PLDP 2015.	PLDP 2030. MPSR	PLDP 2030. RM	Razlika
D3	1267	1015	0	1015

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 33. vidljivo je da su rezultati prognoze na državnoj cesti D3 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije. Regresijska metoda za odabrano razdoblje iskazuje negativnu vrijednost prognoziranog prometa u 2030. godini, zbog znatnog pada prometa u 2015. godini.

5.2.2. Prognoza prometnog opterećenja na državnoj cesti D8 – PGDP i PLDP

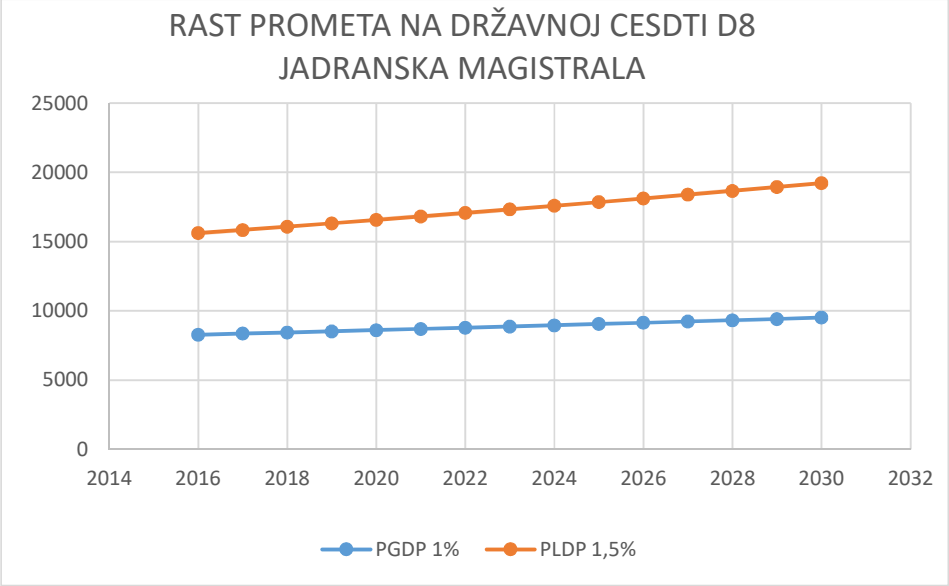
Na državnoj cesti D8 Jadranska magistrala (Crikvenica) prognoziran je rast godišnjeg dnevnog prometa od (PGDP) 1%, dok je za istu cestu prognoziran rast od 1,50% za ljetni dnevni promet (PLDP), što je prvenstveno zbog turističke sezone.

Tablica 34.: Prognoza prometnog opterećenja na državnoj cesti D8 Jadranska magistrala (Crikvenica)

Godina	PGDP 1%	PLDP 1,50%
2016	8275	15613
2017	8358	15847
2018	8442	16085
2019	8526	16326
2020	8611	16571
2021	8698	16820
2022	8785	17072
2023	8872	17328
2024	8961	17588
2025	9051	17852
2026	9141	18120
2027	9233	18392
2028	9325	18668
2029	9418	18948
2030	9512	19232

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Grafikon 15.: Prognoza prometnog opterećenja na državnoj cesti D8 Jadranska magistrala



Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 34 sačinjeni su matematički regresijski modeli prognoze cestovnoga prometa na ovoj dionici državne ceste D3. U tablici 35 nalaze se podatci potrebni za izradu matematičkih regresijskih modela.

Tablica 35.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D8 – PGDP

Godina	yi	xi
2007	8527	1
2008	8390	2
2009	8326	3
2010	7899	4
2011	7789	5
2012	7620	6
2013	7637	7
2014	7763	8
2015	8194	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 35 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 36.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,642192504
R Square	0,412411212
Adjusted R Squar	0,328469957
Standard Error	283,6454583
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	395281,6667	395281,6667	4,913093213	0,06219312
Residual	7	563183,2222	80454,74603		
Total	8	958464,8889			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	8421,944444	206,0636481	40,87059761	1,36851E-09	7934,681345	8909,207544	7934,681345	8909,207544
X Variable 1	-81,16666667	36,61847121	-2,216549844	0,06219312	-167,7555917	5,422258416	-167,7555917	5,422258416

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 8421,94444 + (-81,16) X uz R = 0,6421925, F = 4,91, t = -2,21

Mala vrijednost pokazatelja R upućuje na matematičku i statističku ne upotrebljivost regresijskog modela u ovom slučaju. Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D8 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 37.

Tablica 37.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D8

Cesta	PGDP 2015.	PGDP 2030. MPSR	PGDP 2030. RM	Razlika
D8	8194	9513	6474	3039

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 37 vidljivo je da su rezultati prognoze na državnoj cesti D8 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

Tablica 38.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D8 – PLDP

Godina	yi	x1
2007	15204	1
2008	15026	2
2009	14752	3
2010	14493	4
2011	14132	5
2012	13968	6
2013	14768	7
2014	14545	8
2015	15383	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 38 pomoću Proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 39.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,118743438
R Square	0,014100004
Adjusted R Squar	-0,126742853
Standard Error	497,7852217
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	24806,66667	24806,66667	0,100111602	0,760922201
Residual	7	1734530,889	247790,127		
Total	8	1759337,556			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	14798,44444	361,6325795	40,92121474	1,35675E-09	13943,31928	15653,56961	13943,31928	15653,56961
X Variable 1	-20,33333333	64,26379579	-0,316404176	0,760922201	-172,2930634	131,6263967	-172,2930634	131,6263967

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 14798,44 + (-20,33) X uz R = 0,1187434, F = 0,10, t = -0,31

Mala vrijednost pokazatelja R upućuje na matematičku i statističku ne upotrebljivost regresijskog modela u ovom slučaju. Usporedba procjene dobivenih rezultata o prosječnom ljetnim dnevnom prometu na državnoj cesti D8 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 40.

Tablica 40.: Usporedba procjene dobivenih rezultata o prosječnom ljetni dnevnom prometu na državnoj cesti D8

Cesta	PLDP 2015.	PLDP 2030. MPSR	PLDP 2030. RM	Razlika
D8	15383	19232	14310	4922

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 40 vidljivo je da su rezultati prognoze na državnoj cesti D8 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

5.2.3. Prognoza prometnog opterećenja na državnoj cesti D32 – PGDP i PLDP

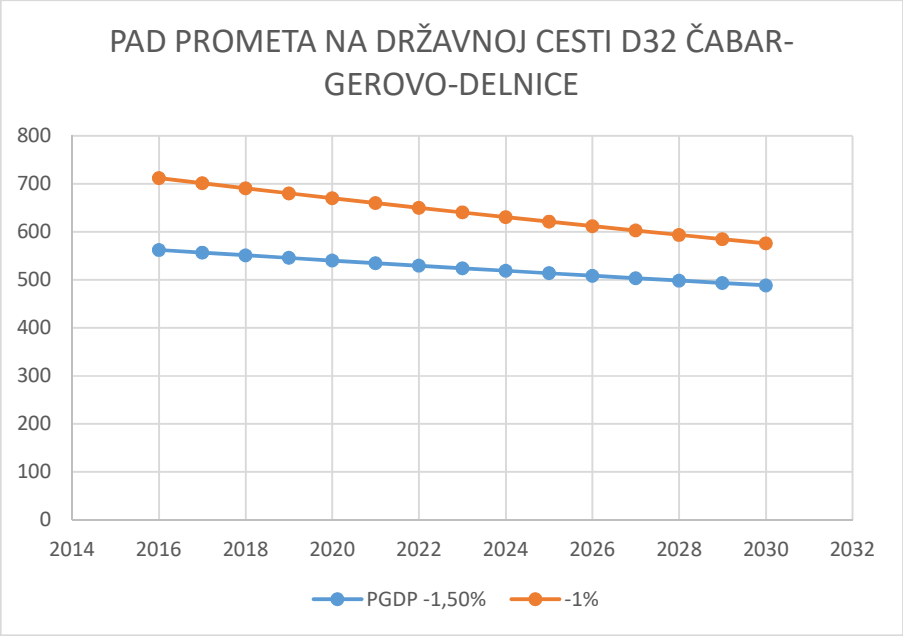
Na državnoj cesti D 32 Čabar - Gerovo - Delnice (Crni lug) prognoziran je pad godišnjeg dnevnog prometa od (PGDP) -1,50% zbog povećanja korištenja autocesta, dok je za istu cestu prognoziran pad od -1% za ljetni dnevni promet (PLDP), nešto manji pad zbog turističke sezone.

Tablica 41.: Prognoza prometnog opterećenja na državnoj cesti D 32 Čabar - Gerovo - Delnice (Crni lug)

Godina	PGDP -1,50%	PLDP- 1%
2016	562	711
2017	556	701
2018	551	690
2019	545	680
2020	540	670
2021	534	660
2022	529	650
2023	524	640
2024	518	630
2025	513	621
2026	508	611
2027	503	602
2028	498	593
2029	493	584
2030	488	576

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Grafikon 16.: Prognoza prometnog opterećenja na državnoj cesti D 32 Čabar - Gerovo - Delnice (Crni lug)



Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 41 sačinjeni su matematički regresijski modeli prognoze cestovnoga prometa na ovoj dionici državne ceste D32. U tablici 42 nalaze se podatci potrebni za izradu matematičkih regresijskih modela.

Tablica 42.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D32 – PGDP

Godina	yi	xi
2007	695	1
2008	698	2
2009	699	3
2010	636	4
2011	617	5
2012	635	6
2013	575	7
2014	565	8
2015	571	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 42 pomoću proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 43.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,943131945
R Square	0,889497866
Adjusted R Squar	0,873711847
Standard Error	19,67497807
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	21812,26667	21812,26667	56,34719284	0,000136558
Residual	7	2709,733333	387,1047619		
Total	8	24522			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	727,6666667	14,29354018	50,90877818	2,95517E-10	693,8678149	761,4655184	693,8678149	761,4655184
X Variable 1	-19,06666667	2,540028746	-7,506476726	0,000136558	-25,07288024	-13,06045309	-25,07288024	-13,06045309

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 727,6666 + (-19,06) X uz R = 0,9431319, F = 56,34, t = -7,50

Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D32 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 44.

Tablica 44.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D32

Cesta	PGDP 2015.	PGDP 2030. MPSR	PGDP 2030. RM	Razlika
D32	571	488	270	218

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 44 vidljivo je da su rezultati prognoze na državnoj cesti D32 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

Tablica 45.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D32 – PLDP

Godina	yi	x1
2007	940	1
2008	940	2
2009	942	3
2010	802	4
2011	756	5
2012	746	6
2013	703	7
2014	683	8
2015	719	9

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 45 pomoću proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 46.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,922854071
R Square	0,851659636
Adjusted R Squar	0,830468156
Standard Error	44,57770993
Observations	9

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	79862,01667	79862,01667	40,18877467	0,000389136
Residual	7	13910,20556	1987,172222		
Total	8	93772,22222			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	985,8611111	32,38495545	30,44194742	1,06488E-08	909,2828601	1062,439362	909,2828601	1062,439362
X Variable 1	-36,48333333	5,754957605	-6,339461702	0,000389136	-50,09164565	-22,87502101	-50,09164565	-22,87502101

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 985,86 + (-36,48) X uz R = 0,922854, F = 40,18, t = -6,34

Usporedba procjene dobivenih rezultata o prosječnom ljetnim dnevnom prometu na državnoj cesti D32 , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 47.

Tablica 47.: Usporedba procjene dobivenih rezultata o prosječnom ljetnom dnevnom prometu na državnoj cesti D32

Cesta	PLDP 2015.	PLDP 2030. MPSR	PLDP 2030. RM	Razlika
D32	719	576	110	466

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 47 vidljivo je da su rezultati prognoze na državnoj cesti D32 značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

5.3. Prognoza prometnog opterećenja u centru Grada Rijeke

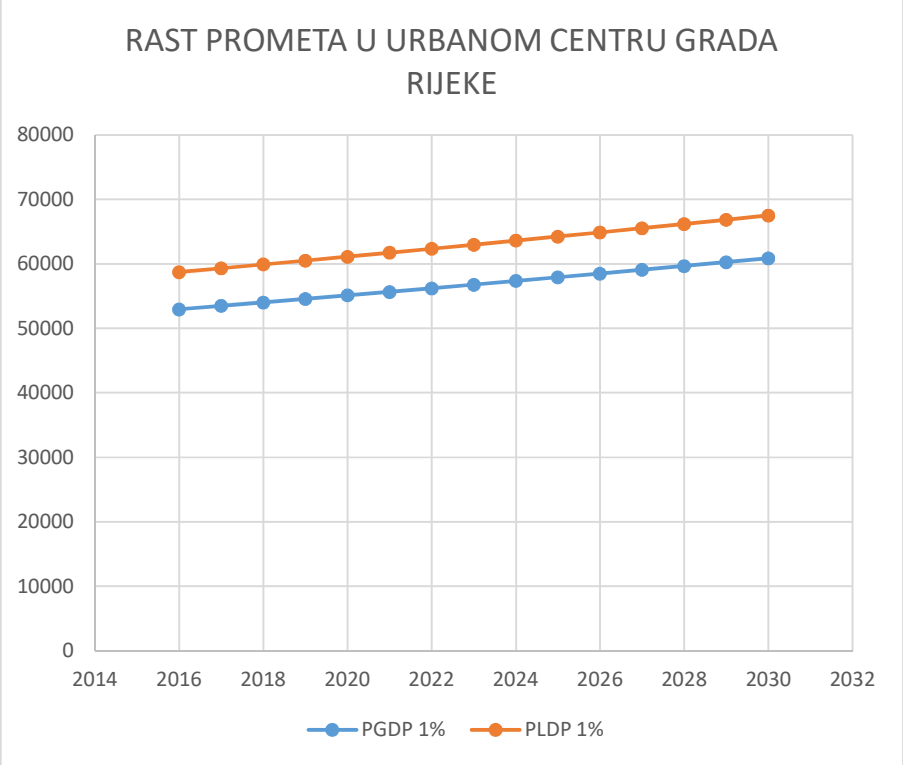
Za centar Grada Rijeke prognoziran je rast godišnjeg dnevnog (PGDP) i ljetnog dnevnog prometa (PLDP) za 1% zbog toga što u prethodnim godinama nije zabilježen veliki rast prometa na ovom području, te ne postoje razlika između ljetnog i godišnjeg dnevnog prometa. Ulice u kojima je brojan promet: R6 Krešimirova, R38 Vukovarska, R40-41 1. Maja, R46-47 Laginjina, R24-25 F. Račkog, R20-21 Strossmayerova, Križanićeva, R89 D404 - A.K.Miošića.

Tablica 48.: Prognoza prometnog opterećenja u Gradu Rijeci

Godina	PGDP 1%	PLDP 1%
2016	52960	58737
2017	53489	59324
2018	54024	59917
2019	54564	60516
2020	55110	61121
2021	55661	61733
2022	56218	62350
2023	56780	62974
2024	57348	63603
2025	57921	64239
2026	58500	64882
2027	59085	65531
2028	59676	66186
2029	60273	66848
2030	60876	67516

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Grafikon 17.: Prognoza prometnog opterećenja u Gradu Rijeci



Izvor: Izrada autora na temelju prethodno prikazanih podataka

Tablica 49.: Podatci za analizu modela prognoze cestovnoga prometa u Gradu Rijeci – PGDP

Godina	yi	x1
2013	52205	1
2014	52512	2
2015	52718	3
2016	52960	4

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 49 pomoću proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 50.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,99674905
R Square	0,993508669
Adjusted R Squar	0,990263004
Standard Error	31,58084863
Observations	4

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	305292,05	305292,05	306,1032235	0,00325095
Residual	2	1994,7	997,35		
Total	3	307286,75			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	51981	38,67848239	1343,925531	5,53668E-07	51814,57992	52147,42008	51814,57992	52147,42008
X Variable 1	247,1	14,12338486	17,49580588	0,00325095	186,3319796	307,8680204	186,3319796	307,8680204

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 51981+247,1 X uz R = 0,996749, F = 306,10, t =17,49

Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na gradskim cestama grada Rijeke , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 51.

Tablica 51.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu u Gradu Rijeci

Cesta	PGDP 2015.	PGDP 2030. MPSR	PGDP 2030. RM	Razlika
GC	52960	60876	56428	4448

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 51 vidljivo je da su rezultati prognoze na gradskim cestama grada Rijeke značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta značajno optimističnije.

Tablica 52.: Podatci za analizu modela prognoze cestovnoga prometa u Gradu Rijeci – PLDP

Godina	yi	xi
2013	56796	1
2014	57894	2
2015	57902	3
2016	58737	4

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka u tablici 52 pomoću proračunske tablice EXCEL napravljena je regresijska analiza.

Tablica 53.: Ispis obrade u programu EXCEL

SUMMARY OUTPUT

Regression Statistics	
Multiple R	0,945648176
R Square	0,894250472
Adjusted R Squar	0,841375708
Standard Error	317,04629
Observations	4

ANOVA

	df	*SS*	*MS*	*F*	*Significance F*
Regression	1	1700028,05	1700028,05	16,91261397	0,054351824
Residual	2	201036,7	100518,35		
Total	3	1901064,75			

	Coefficients	*Standard Error*	*t Stat*	*P-value*	*Lower 95%*	*Upper 95%*	*Lower 95,0%*	*Upper 95,0%*
Intercept	56374,5	388,3008177	145,1825426	4,74395E-05	54703,77643	58045,22357	54703,77643	58045,22357
X Variable 1	583,1	141,7874113	4,112494859	0,054351824	-26,96199223	1193,161992	-26,96199223	1193,161992

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Linearni model: Y = 56374,5 +583,1 X uz R = 0,945648, F =16,91, t = 4,11

Usporedba procjene dobivenih rezultata o prosječnom ljetnim dnevnom prometu na gradskim cestama grada Rijeke , temeljem metode prosječne stope rasta (MPSR) i odabranih regresijskih modela (RM) dana je u tablici 54.

Tablica 54.: Usporedba procjene dobivenih rezultata o prosječnom ljetnom dnevnom prometu u Gradu Rijeci

Cesta	PLDP 2015.	PLDP 2030. MPSR	PLDP 2030. RM	Razlika
GC	58737	67516	66870	646

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 54 vidljivo je da su rezultati prognoze na gradskim cestama grada rijeke značajno različite, odnosno da su prognoze utemeljene na metodi prosječne stope rasta optimističnije.

Tablica 55.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem i prosječnom ljetnom dnevnom prometu na izabranim prometnicama Primorsko-goranske županije

Cesta	Mjesto brojanja	PGDP 2015.	PLDP 2015.	PGDP 2030. MPSR	PGDP 2030. RM	PLDP 2030. MPSR	PLDP 2030. RM
Autocesta A6	Bosiljevo	12631	21055	16999	nm	30493	23753
Autocesta A7	Rupa	15123	23458	20353	33221	31726	42237
Državna cesta D3	Vrbovsko	1177	1267	1007	nm	1015	nm
Državna cesta D8	Crikvenica	8194	15383	9513	nm	19232	nm
Državna cesta D32	Crni lug	571	719	488	270	576	110
Grad Rijeka	Centar	52718	57902	60876	56428	67516	66870

nm – nepouzdanost modela

Izvor: Izrada autora na temelju prethodno prikazanih podataka

Temeljem podataka iz tablice 55 vidljivo je da su rezultati prognoze regresijskim modelom na autocesti A7 znatno optimističniji u odnosu na rezultate metode prosječne stope rasta, dok na svim ostalim cestama i ulicama metoda prosječne stope rasta daje znatno optimističniju prognozu prometnog opterećenja.

6. ZAKLJUČAK

Poznato je da cestovna mreža u razvoju županijskog prostora ima veoma važnu ulogu i predstavlja jedan od značajnih čimbenika razvoja njenoga gospodarstva iako po mogućnostima razvoja županija nije homogeno gospodarsko područje, već područje s velikim razlikama, specifičnostima i posebnostima pojedinih područja, koja predstavljaju razvojne – prostorne cjeline, cestovna mreža predstavlja jedan od veoma važnih razvojnih čimbenika cjelokupnoga njenoga prostora. Suvremena gospodarstva zahtijevaju djelotvorni cestovni prometni sustav, koji je u stanju zadovoljiti prometnu potražnju. S obzirom na to je posebice važno kvalitetno održavanje te mreže, a osobito onih cestovnih pravaca koji su od veoma važnoga lokalnog značenja s pristupom do najmanjih naselja i gospodarskih centara.

U ovom završnom radu pomno je analizirano prometno opterećenje cestovne mreže na području Primorsko-goranske županije, najprije su izneseni prikupljeni podatci o samoj županiji, prostornom obuhvatu i stanovništvu kao bi se upoznalo samo područje obuhvata. Potom su analizirana gospodarska kretanja za protekla razdoblja o kojima su se mogli prikupiti potrebni podatci. Kada su prikupljani podatci o gospodarskim kretanjima bilo je potrebno prikupiti podatke o prosječnim dnevnim i prosječnim ljetnim godišnjim prometima na izabranim cestovnim prometnicama na području Primorsko-goranske županije. S obzirom na to da su prikupljeni potrebni podatci za analizu i prognozu prometnog opterećenja moglo se pristupiti samim postupcima analiziranja i prognoziranja prometnog opterećenja na području Primorsko goranske županije pomoću matematičkih regresijskih modela.

Temeljem prikupljanih i analiziranih podataka može se zaključiti da je prometno opterećenje najveće na autocestama i u urbanim sredinama na području ove županije što pokazuju podatci o kretanju prometa u prethodnim godinama. Uzimajući u obzir podatke o kretanju prometa u proteklom razdoblju za ove prometnice se prognozira daljnji rast prometnog opterećenja na istim. Dok se na nekim izabranim državnim prometnicama iskazuje lagani pad prometnog opterećenja proteklih godina, čime se prognozira daljnji pad prometa i u budućnosti. S obzirom na dobivene rezultate prognoze može se pretpostaviti da bi u budućnosti moglo doći do velikih prometnih zagušenja na autocestama i urbanim središtima dok bi se na nekim državnim cestama promet mogao uvelike smanjiti pa skoro i nestati.

LITERATURA

Knjige:

1. Padjen, J., Prometna politika, Ekonomski institut, Zagreb, 1996.
2. Pupavac D., Prometna ponuda i prometna potražnja; Veleučilište u Rijeci, Rijeka, 2017.
3. Pupavac, D., Načela ekonomike prometa, Veleučilište u Rijeci, Rijeka, 2009.
4. Radačić, Ž., Šimulčik, D., Ekonomika prometnog sustava, Fakultet prometnih znanosti, Zagreb, 1995.
5. Zelenika, R., Ekonomika prometne industrije, Ekonomski fakultet u Rijeci, Rijeka, 2010.

Znanstveni radovi:

6. Institut IGH, d.d., Prostorno i prometno integralna studija Primorsko - goranske županije i Grada Rijeke, Zagreb, 2010.
7. Lajić, I., demografska studija, popis stanovništva 2001. godine., Zagreb, 2001.

Internet:

8. URL: http://gkr.hr/O-nama/Za-knjiznicare/Narodne-knjiznice/Narodne-knjiznice-Primorsko-goranske-zupanije (20. 4. 2018.)
9. URL: www.dsz.hr (15. 4. 2018.)
10. URL: http://www.hrvatske-ceste.hr/default.aspx (20. 4. 2018.)
11. URL: http://www.visitrijeka.hr/Korisne_informacije/TIC (20. 4. 2018.)

POPIS SLIKA

Slika 1.: Područje primorsko-goranske županije 3
Slika 2.: Autocesta A6 - Čvor Bosiljevo 13
Slika 3.: Autocesta A7 – Čvor Rupa 17
Slika 4.: Državna cesta D3 Karlovac – Delnice - Rijeka 19
Slika 5.: Državna cesta D8 – Jdranska magistrala (Crikvenica) 20
Slika 6.: Državna cesta D32 Čabar – Gerovo - Rijeka 22
Slika 7.: Grad Rijeka - centar 23

POPIS GRAFIKONA

Grafikon 1.: Broj stanovnika po županijama 4
Grafikon 2.: Ukupan broj stanovništava u PGŽ 1991.,2001. i 2011. godine 5
Grafikon 3.: Kretanje BDP-a u PGŽ od 2010. do 2016. godine 6
Grafikon 4.: Dolasci i noćenja u gradu Rijeci za razdoblje od 2000. do 2012. godine 7
Grafikon 5.: Mreža cesta na području Republike Hrvatske razvrstava se kako je prikazano u godinama 10
Grafikon 6.: PGDP-a i PLDP-a na autocesti A6 17
Grafikon 7.: PGDP-a i PLDP-a na autocesti A7 18
Grafikon 8.: PGDP-a i PLDP-a na državnoj cesti D3 Karlovac - Delnice – Rijeka 20
Grafikon 9.: PGDP-a i PLDP-a na državnoj cesti D8 Jadranska magistrala 21
Grafikon 10.: PGDP-a i PLDP-a na državnoj cesti D32 Čabar - Gerovo –Delnice 23
Grafikon 11.: PGDP-a i PLDP-a centar Grada Rijeke 24
Grafikon 12.: Prognoza prometnog opterećenja na autocesti A6, čvor Bosiljevo 26
Grafikon 13.: Prognoza prometnog opterećenja na autocesti A7, čvor Rupa 30
Grafikon 14.: Prognoza prometnog opterećenja na državnoj cesti D3 Karlovac - Delnice – Rijeka 34
Grafikon 15.: Prognoza prometnog opterećenja na državnoj cesti D8 Jadranska magistrala 40

Grafikon 16.: Prognoza prometnog opterećenja na državnoj cesti D 32 Čabar - Gerovo - Delnice (Crni lug) 45
Grafikon 17.: Prognoza prometnog opterećenja u Gradu Rijeci 49

POPIS TABLICA

Tablica 1.: Mreža cesta na području Republike Hrvatske razvrstava se kako je prikazano u sljedećoj tablici 9
Tablica 2.: Stupanj motorizacije (stanovnici/vozila) 12
Tablica 3.: Prikaz sadašnjih i planiranih parkirnih mjesta u Primorsko-goranskog županijiSlika 2Autocesta A6 - Čvor Bosiljevo 13
Tablica 4.: Prikupljeni podaci PGDP-a I Pldp-a na autocesti A6, čvor Bosiljevo - brojanje prometa od 2007. do 2015. goine. 16
Tablica 5.: Prikupljeni podatci PDGP-a i PLDP-a na autocesti A7 čvor Rupa – brojanje prometa od 2007. – do 2015. godine 18
Tablica 6.: Prikupljeni podatci PGDP-a i PLDP-a na državnoj cesti D3 Karlovac - Delnice - Rijeka (mjerno mjesto Vrbovsko) 19
Tablica 7.: Prikupljeni podatci PGDP-a i PLDP-a na državnoj cesti D8 Jadranska magistrala (Crikvenica) 21
Tablica 8.: Prikupljeni podatci PGDP-a i PLDP-a na državnoj cesti Čabar - Gerovo -Delnice (mjerno mjesto Crni lug) 22
Tablica 9.: Prikupljeni podatci PGDP-a i PLDP-a centru Grada Rijeke 24
Tablica 10.: Prognoza prometnog opterećenja na autocesti A6, čvor Bosiljevo 25
Tablica 11.: Podatci za analizu modela prognoze cestovnoga prometa na autocesti A6 - PGDP 26
Tablica 12.: Ispis obrade u programu EXCEL 27
Tablica 13.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na autocesti A6. 27
Tablica 14.: Podatci za analizu modela prognoze cestovnoga prometa na autocesti A6 – PLDP 28
Tablica 15.: Ispis obrade u programu EXCEL 28

Tablica 16.: Usporedba procjene dobivenih rezultata o prosječnomljetnom dnevnom prometu na autocesti A6 29
Tablica 17.: Prognoza prometnog opterećenja na autocesti A7, čvor Rupa 29
Tablica 18.: Podatci za analizu modela prognoze cestovnoga prometa na autocesti A7 - PGDP 30
Tablica 19.: Ispis obrade u programu EXCEL 31
Tablica 20.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na autocesti A7..... 31
Tablica 21.: Podatci za analizu modela prognoze cestovnoga prometa na autocesti A7 – PLDP 32
Tablica 22.: Ispis obrade u programu EXCEL 32
Tablica 23.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem ljetnom prometu na autocesti A7..... 33
Tablica 24.: Prognoza prometnog opterećenja na državnoj cesti D3 Karlovac - Delnice – Rijeka 34
Tablica 25.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D3 – PGDP 35
Tablica 26.: Ispis obrade u programu EXCEL 35
Tablica 27.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D3..... 36
Tablica 28.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D3 – PGDP (2010.-2015.) 36
Tablica 29.: Ispis obrade u programu EXCEL 36
Tablica 30.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D3 (2010-2015.)..... 37
Tablica 31.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D3 – PLDP 37
Tablica 32.: Ispis obrade u programu EXCEL 38
Tablica 33.: Usporedba procjene dobivenih rezultata o prosječnom ljetnom dnevnom prometu na državnoj cesti D3..... 38
Tablica 34.: Prognoza prometnog opterećenja na državnoj cesti D8 Jadranska magistrala (Crikvenica)..... 39

Tablica 35.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D8 – PGDP 40
Tablica 36.: Ispis obrade u programu EXCEL 41
Tablica 37.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D8 41
Tablica 38.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D8 – PLDP 42
Tablica 39.: Ispis obrade u programu EXCEL 42
Tablica 40.: Usporedba procjene dobivenih rezultata o prosječnom ljetni dnevnom prometu na državnoj cesti D8 43
Tablica 41.: Prognoza prometnog opterećenja na državnoj cesti D 32 Čabar - Gerovo - Delnice (Crni lug) 43
Tablica 42.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D32 – PGDP 44
Tablica 43.: Ispis obrade u programu EXCEL 45
Tablica 44.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu na državnoj cesti D32 46
Tablica 45.: Podatci za analizu modela prognoze cestovnoga prometa na državnoj cesti D32 – PLDP 46
Tablica 46.: Ispis obrade u programu EXCEL 47
Tablica 47.: Usporedba procjene dobivenih rezultata o prosječnom ljetnom dnevnom prometu na državnoj cesti D32 47
Tablica 48.: Prognoza prometnog opterećenja u Gradu Rijeci 48
Tablica 49.: Podatci za analizu modela prognoze cestovnoga prometa u Gradu Rijeci – PGDP 48
Tablica 50.: Ispis obrade u programu EXCEL 49
Tablica 51.: Usporedba procjene dobivenih rezultata o prosječnom godišnjem dnevnom prometu u Gradu Rijeci 50
Tablica 52.: Podatci za analizu modela prognoze cestovnoga prometa u Gradu Rijeci – PLDP 50
Tablica 53.: Ispis obrade u programu EXCEL 51

Tablica 54.: Usporedba procjene dobivenih rezultata o prosječnom ljetnom dnevnom prometu u Gradu Rijeci..... 51
Tablica 55.: Usporedba procjene dobivenih rezultata o prosječnom ljetnom dnevnom prometu u Gradu Rijeci..... 52