Prognostički model broja paketskih pošiljaka u funkciji unaprjeđenja učinkovitosti prijevoza

Poljičak, Ana-Mari

Doctoral thesis / Disertacija

2021

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:119:436159

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

Fakultet prometnih znanosti

Ana-Mari Poljičak

PROGNOSTIČKI MODEL BROJA PAKETSKIH POŠILJAKA U FUNKCIJI UNAPRJEĐENJA UČINKOVITOSTI PRIJEVOZA

DOKTORSKI RAD

Zagreb, 2021.

Sveučilište u Zagrebu

Fakultet prometnih znanosti

Ana-Mari Poljičak

PROGNOSTIČKI MODEL BROJA PAKETSKIH POŠILJAKA U FUNKCIJI UNAPRJEĐENJA UČINKOVITOSTI PRIJEVOZA

DOKTORSKI RAD

Mentor:
prof. dr. sc. Zvonko Kavran

Zagreb, 2021.

University of Zagreb

Faculty of Transport and Traffic Sciences

Ana-Mari Poljičak

PROGNOSTIC MODEL OF PARCEL NUMBERS IN IMPROVING THE EFFICIENCY OF TRANSPORT

DOCTORAL DISSERTATION

Supervisor:
prof. Zvonko Kavran, Ph. D.

Zagreb, 2021.

INFORMACIJE O MENTORU: prof. dr. sc. Zvonko Kavran

Prof. dr. sc. Zvonko Kavran rođen je 1969. godine u Zagrebu. Godine 1989. upisao je studij na Elektrotehničkom fakultetu Sveučilišta u Zagrebu gdje je 1994. godine diplomirao. Na Fakultetu prometnih znanosti zaposlen je od 1995. gdje je 2003. godine stekao doktorat znanosti iz područja tehničkih znanosti. Od 2017. godine izabran je u redovitog profesora u trajnom zvanju u znanstvenom području tehničkih znanosti, polje tehnologija prometa i transport. Obnašao je dužnosti voditelja odjela za PT promet na Zavodu za prometno-tehnička vještačenja, voditelja Katedre za tehniku poštanskog i telekomunikacijskog prometa, ECTS koordinatora, prodekana za nastavu i znanost, vršitelja dužnosti dekana. Od 2005. godine predstojnik je Zavoda za poštanski promet.

Sudjelovao je kao voditelj i istraživač na znanstvenim projektima MZOŠ-a, znanstveno-istraživačkim projektima programa suradnje MZOŠ-a, razvojno istraživačkim projektima programa South-East Europe, programa FP7, programa Interreg i Fonda za razvoj Sveučilišta u Zagrebu. Surađivao je u izradi više stručnih projekta i studija, te kao voditelj projekta Ministarstva pomorstva, prometa i infrastrukture „Strategija razvoja tržišta poštanskih usluga u Republici Hrvatskoj do 2020. godine“ i voditelj projekta Hrvatske pošte d.d. „Mjerenje kakvoće usluge prijenosa pismovnih pošiljaka i prioritetnih pismovnih pošiljaka u unutarnjem prometu“. Sudjelovao je na više znanstvenih i stručnih savjetovanja u zemlji i inozemstvu, gdje je i objavio više znanstvenih i stručnih radova, te održao pozvana predavanja.

Zahvaljujem dragom Bogu za ustrajnost te podršku od obitelji i kolega!

SAŽETAK

Utvrđivanje čimbenika koji utječu na broj paketskih pošiljaka, izrada prognostičkih modela broja paketskih pošiljaka te definiranje metodologije za potreban kapacitet prijevoznih sredstava važni su za učinkovito planiranje prijevoznih kapaciteta budući da na tržištu poštanskih usluga svake godine dolazi do povećanja broja paketskih pošiljaka.

U ovom doktorskom radu, kroz njegova poglavlja, definirane su odrednice modela utjecaja čimbenika na broj paketskih pošiljaka, odnosno objašnjena je korelacijska i regresijska analiza te su analizirani čimbenici koji utječu na broj paketskih pošiljaka. Zatim su opisani postupci izrade regresijskih modela koji su kasnije i testirani. Prilikom njihove izrade napravljeno je vrednovanje čimbenika koji utječu na broj paketskih pošiljaka. Temeljem dosadašnjih istraživanja i istraživanja provedenog na jednom davatelju poštanskih usluga u Republici Hrvatskoj izabrani su pokazatelji učinkovitosti prijevoza, izračunata je prosječna masa i volumen paketskih pošiljaka te je definirana metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava kako bi se unaprijedila učinkovitost prijevoza paketskih pošiljaka u poštanskom prometu.

Temeljem korelacijske analize vrednovani su čimbenici koji utječu na broj paketskih pošiljaka te je napravljen izbor varijabli, odnosno čimbenika za izradu modela predviđanja. Regresijskom analizom također su vrednovane izabrane varijable temeljem kojih su izrađena dva prognostička modela. Modeli su testirani na stvarnim podacima čime je potvrđena njihova primjenjivost za predviđanje paketskih pošiljaka u budućim razdobljima. Također je napravljena usporedba rezultata prognostičkog modela broja paketskih pošiljaka s planiranim brojem paketskih pošiljaka promatranog davatelja poštanskih usluga čime je dodatno potvrđena primjenjivost prognostičkog modela. Uz odabrane pokazatelje učinkovitosti prijevoza definirana je i primijenjena metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava između entiteta poštanske mreže. Vrednovanjem čimbenika koji utječu na broj paketskih pošiljaka, primjenom modela za predviđanje broja paketskih pošiljaka te korištenjem definirane metodologije za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unaprjeđenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu pruža se mogućnost optimizacije voznog parka.

Ključne riječi: vrednovanje čimbenika, korelacija analiza, regresijska analiza, prognostički modeli, metodologija, učinkovitost prijevoza, paketske pošiljke

SUMMARY

The establishment of the factors influencing the number of package shipments, the elaboration of predictive models for the number of package shipments and the definition of the methodology for the necessary capacity of means of transport are important for the efficient planning of transport capacities, because the number of package shipments on the postal services market keeps increasing each year.

Throughout its chapters, this doctoral thesis defines the determinants of the model of the influence of factors on the number of package shipments, explains the correlation and regression analyses and analyses the factors that influence the number of package shipments. The above is followed by a description of the elaboration procedures of regression models, which have subsequently been tested. In their elaboration, the factors that influence the number of package shipments have been evaluated. On the basis of previous research and research conducted in one postal service provider in the Republic of Croatia, the transport efficiency indicators were selected, the average mass and volume of package shipments calculated and the methodology for establishing the necessary capacity of means of transport defined, in order to improve the efficiency of package shipments in postal traffic.

On the basis of correlation analysis, the factors that influence the number of package shipments have been evaluated and variables and factors for the elaboration of the predictive model selected. By means of the regression analysis, the selected variables, on the basis of which two predictive models have been elaborated, were also evaluated. The models were tested on the basis of real data, which helped verify their applicability in the prediction of package shipments in future periods. The results of the predictive model for the number of package shipments were also compared to the planned number of package shipments in the observed postal service provider, which additionally confirmed the applicability of the predictive model. Apart from the selected efficiency indicators, the methodology for the establishment of the necessary capacities of means of transport between the entities of the postal network was also defined and applied. The evaluation of the factors influencing the number of package shipments, application of the model for predicting the number of package shipments and use of the defined methodology for the establishment of the necessary capacities of means of transport and the improvement of package transport efficiency in postal traffic offer a possibility for optimisation of the vehicle fleet.

Keywords: evaluation of factors, correlation analysis, regression analysis, predictive models, methodology, transport efficiency, package shipments

SADRŽAJ

1. UVOD ... 1
1.1. Problem istraživanja i znanstvena hipoteza ... 1
1.2. Svrha i cilj istraživanja ... 2
1.3. Osvrt na dosadašnja istraživanja ... 2
1.4. Metode istraživanja ... 6
1.5. Kompozicija rada ... 7
2. PAKETSKO TRŽIŠTE U POŠTANSKOM PROMETU ... 10
2.1. Svjetsko paketsko tržište ... 10
2.2. Europsko paketsko tržište ... 13
2.3. E-trgovina ... 20
2.4. Paketsko tržište Republike Hrvatske ... 23
3. ODREDNICE MODELA UTJECAJA ČIMBENIKA NA BROJ PAKETSKIH POŠILJAKA ... 26
3.1. Metodološka podloga za izradu regresijskih modela ... 26
3.1.1. Korelacijska analiza ... 26
3.1.2. Regresijska analiza ... 29
3.2. Analiza čimbenika koji utječu na broj paketskih pošiljaka u poštanskom prometu ... 37
4. REGRESIJSKI MODELI UTJECAJA IZABRANIH ČIMBENIKA NA BROJ PAKETSKIH POŠILJAKA ... 47
4.1. Linearni regresijski model utjecaja izabranih čimbenika na broj paketskih pošiljaka upotrebom godišnjih vrijednosti ... 49
4.1.1. Deskriptivna statistika godišnjih podataka ... 50
4.1.2. Polazne pretpostavke linearnog regresijskog modela ... 72
4.1.3. Korelacijska analiza ... 74
4.1.4. Regresijski model s trendom ... 80
4.1.5. Regresijski model ... 86
4.2. Usporedba procjenjenih regresijskih modela ... 92
4.3. Analiza reprezentativnosti prognostičkog modela broja paketskih pošiljaka ... 94
5. UČINKOVITOST PRIJEVOZA PAKETSKIH POŠILJAKA ... 96
5.1. Pokazatelji učinkovitosti prijevoza ... 96
5.2. Validacija prognostičkog modela u svrhu unaprjeđenja učinkovitosti prijevoza paketskih pošiljaka ... 100
5.2.1. Utvrđivanje broja paketskih pošiljaka primjenom godišnjeg prognostičkog modela ... 100
5.2.2. Utvrđivanje broja paketskih pošiljaka davatelja poštanske usluge ... 101

5.2.3. Validacija prognostičkog modela 103
5.3. Metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava 106
5.4. Primjena metodologije između entiteta poštanske mreže 112
6. ZAKLJUČAK 120
LITERATURA 123
POPIS SLIKA 132
POPIS TABLICA 135
PRILOZI 137
Životopis 140
Popis objavljenih radova 141

1. UVOD

1.1. Problem istraživanja i znanstvena hipoteza

Posljednjih je godina u poštanskom prometu zabilježen porast broja paketskih pošiljaka, dok je kod broja pismovnih pošiljaka prisutan trend smanjenja broja. Pristup Internetu i trgovina putem Interneta imaju značajan utjecaj na povećanje broja paketskih pošiljaka u poštanskom sustavu.

Kako bi paket stigao na odredište, mora proći kroz nekoliko tehnoloških faza u prometu pošiljaka. Jedna od faza od prijema do uručenja pošiljke je i faza prijevoza paketskih pošiljaka između entiteta poštanske mreže. U prijevozu paketskih pošiljaka najzastupljeniji je cestovni prijevoz.

Davatelji poštanskih usluga nastoje što učinkovitije obaviti prijevoz paketskih pošiljaka između vlastitih entiteta poštanske mreže. Za procjenu učinkovitosti prijevoza koriste se razni pokazatelji učinkovitosti. Kako bi procjena bila što točnija, potrebno je poznavati relevantne čimbenike koji utječu na kretanje broja paketskih pošiljaka.

Stoga, kako bi se planirao i unaprijedio prijevoz paketskih pošiljaka svih davatelja poštanskih usluga na području Republike Hrvatske čiji broj na tržištu svake godine raste, potrebno je odabrati čimbenike koji značajno utječu na broj paketskih pošiljaka, prognozirati njihov broj te odrediti metodologiju za definiranje potrebnih kapaciteta prijevoznih sredstava. U ovom su doktorskom radu analizirani i vrednovani čimbenici koji utječu na broj paketskih pošiljaka, izrađeni i uspoređeni prognostički modeli, napravljena validacija prognostičkog modela radi unapređenja učinkovitosti prijevoza paketskih pošiljaka, definirani pokazatelji učinkovitosti prijevoza te definirana i primijenjena metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava. Definirani su postupci koji predstavljaju korake za procjenu i unapređenje učinkovitosti prijevoza paketskih pošiljaka.

Rezultati istraživanja ovog doktorskog rada mogu se primijeniti za unapređenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu planiranjem prijevoznih kapaciteta, a temeljem predloženih koraka za utvrđivanje potrebnih kapaciteta prijevoznih sredstava.

Analizom predmetnog područja slijede sljedeće znanstvene hipoteze:

- Analizom čimbenika koji utječu na broj paketskih pošiljaka u poštanskom prometu moguće je utvrditi njihovu nejednakost postojanja i vrijednosti ovisnosti,
- Vrednovanjem pokazatelja učinkovitosti prijevoza moguće je unaprijediti proces planiranja kapaciteta potrebnih prijevoznih sredstava.

1.2. Svrha i cilj istraživanja

Svrha istraživanja je istražiti povezanost između utjecajnih čimbenika i broja paketskih pošiljaka, izraditi regresijske modele te definirati metodologiju za utvrđivanje potrebnih kapaciteta prijevoznih sredstava. Vrednovanjem utjecaja pojedinih čimbenika, odnosno koliko oni utječu na broj paketskih pošiljaka u poštanskom prometu, primjenom prognostičkog modela broja paketskih pošiljaka te metodologijom za utvrđivanje potrebnih kapaciteta prijevoznih sredstava, moguće je unaprijediti učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu. Slijedom navedenog istražena je korelacija između čimbenika pojedinačno i broja paketskih pošiljaka koji su rangirani koeficijentom korelacije. Izrađene su dvije varijante regresijskih modela pri čijoj su izradi vrednovani utjecaji pojedinih čimbenika na broj paketskih pošiljaka. Navedeno predstavlja podlogu za utvrđivanje potrebnih kapaciteta prijevoznih sredstava.

Cilj istraživanja jest temeljem analiziranih i vrednovanih čimbenika izraditi prognostički model broja paketskih pošiljaka u poštanskom prometu te primjenom definirane metodologije procijeniti učinkovitost prijevoza poštanskih pošiljaka davatelja poštanskih usluga.

1.3. Osvrt na dosadašnja istraživanja

Temeljem pregleda dosadašnjih istraživanja i dostupne literature u području poštanskog prometa utvrđeno je da su istraživanja uglavnom usmjerena na područje optimizacije poštanske mreže gdje se optimizacija odnosi na optimizaciju poštanskih ruta i entiteta poštanske mreže. Tako je 1999. godine napravljen sustav za potporu odlučivanju za Deutsche Post AG radi poboljšanja transportne mreže pismovnih pošiljaka, a optimizacija se odnosila na problem planiranja cestovnih ruta [1]. U 2007. godini razvijen je model za optimizaciju poštanskih ruta i prijevoznog kapaciteta kako bi se minimizirali fiksni troškovi i transportni

troškovi između poštanskih ureda Kineske pošte [2]. Također 2009. godine razvijen je model kako bi se ostvario najbrži prijevoz poštanskih pošiljaka između poštanskih ureda u ekspresnoj poštanskoj mreži te smanjio trošak izgradnje ekspresne mreže u Kini [3]. Za optimizaciju međuregionalnih transportnih rješenja Švedske pošte 2008. godine razvijen je simulacijski model [4]. U [5] su 2013. godine razvijeni modeli za određivanje optimalnog broja jedinica poštanske mreže Srpske pošte. U 2014. godini razvijen je model za organizaciju transporta na mreži i upravljanje vozilima te model za odlučivanje o potencijalnim centrima razmjene poštanskih pošiljaka za Korejsku poštu [6].

Za prognozu te za ispitivanje ovisnosti jedne zavisne varijable o jednoj ili više nezavisnih varijabli koriste se prognostičke metode u koje spada i regresijska metoda. Ova metoda primjenjuje se i u području prometa. Tako je 2000. godine na temelju provedenog istraživanja na području dvaju gradova Australije, Sydney-a i Melbourne-a, razvijen regresijski model za prognoziranje odabira prigradskog moda prijevoza za odlazak na posao [7]. U istraživanju 2004. godine je korištena metoda regresije za prognoziranje učinkovitosti različitih strategija smanjenja stope putovanja vozilom na posao [8]. Za prognoziranje kontejnerskog prometa Luke Rijeka u 2011. godini korištena je metoda regresije [9]. Iste godine korištena je metoda regresije za prognoziranje vjerojatnosti odabira između cestovnog i željezničkog moda prijevoza na američkom tržištu [10] te za prognoziranje obujma prometa putnika na autocesti u Kini [11]. Metodom regresije 2015. ispitano je sedam modela za prognoziranje ukupnog broja generiranih putovanja na razini kućanstva [12].

Europska komisija je 2008. godine koristila regresijsku analizu kako bi ispitala utjecaj propisa na količinu poštanskih pošiljaka [13]. Svjetska poštanska unija (UPU) je 2010. godine u svom istraživanju koristila metodu regresije kako bi ispitala potražnju za pismovnim pošiljkama, za uslugama ubrzane pošte (EMS), te za paketskim uslugama [14]. Godine 2011. korištena je metoda regresije kako bi se istražila povezanost poštanskog prometa i pokretne komunikacijske mreže u Republici Hrvatskoj [15]. U 2011. godini korištena je metoda regresije za prognoziranje količine poštanskih pošiljaka Pošte Srbije radi optimalnog upravljanja ljudskim resursima u dostavnim poštanskim uredima [16]. Metoda regresije 2012. godine korištena je za prognoziranje poštanskog prometa Irana. Ovo je istraživanje značajno jer daje i pregled čimbenika za koje je pretpostavljeno, temeljem izvještaja Svjetske poštanske unije, da utječu na poštanski promet u toj zemlji [17]. Metoda regresije 2016. godine korištena je za prognoziranje poštanskih usluga za područje jugoistočne Europe [18] te za prognoziranje slanja i primitka paketskih pošiljaka s nekog područja [19].

Analizom dosadašnjih istraživanja primjene metode regresije može se zaključiti da su u ovim istraživanjima korišteni prognostički modeli kojima nisu obuhvaćena vrednovanja čimbenika koji utječu na broj paketskih pošiljaka u funkciji unapređenja učinkovitosti prijevoza.

U cestovnom prijevozu istraživani su razni pokazatelji koji se koriste za mjerenje operativne učinkovitosti. U istraživanjima iz 1993. i 1999. godine [20, 21] istražena je potrošnja goriva kao pokazatelj operativne učinkovitosti kojim se željelo poboljšati učinkovitost prijevoza. Ovaj pokazatelj također je istraživan 2014. godine kada je i razvijen regresijski model za prognoziranje energetske učinkovitosti (potrošnju goriva) [22]. U Australiji je 1992. godine provedeno istraživanje koje je pokazalo da se najčešće koristi šest pokazatelja učinkovitosti prijevoza i to: ukupni godišnji kilometri po vozilu, ukupni godišnji tonski kilometri po vozilu, kilometri praznog vozila u ukupnim prijeđenim kilometrima, prosječna stvarna natovarenost u odnosu na maksimalnu natovarenost, godišnji broj kilometara po vozaču, potrošnja goriva po tipu vozila [23]. U cestovnom su prijevozu i distribuciji 1998. godine istraženi sljedeći pokazatelji za mjerenje učinkovitosti: troškovi po vozilu, plaće po vozaču, radni sati po vozilu, radni sati po vozaču, prosječna brzina, vrijeme utovara/istovara, prosječna natovarenost vozila, promet (izražen u novčanim jedinicama) po vozilu, udio kilometara praznog vozila u ukupnim prijeđenim kilometrima, kilometri po vozilu [24]. Za ocjenu učinkovitosti vozila za prijevoz tereta 2010. godine korištena je potrošnja goriva, cijena goriva, trošak rada, trošak potrošnog materijala, porez, osiguranje, prijeđena udaljenost, prevezena količina tereta u tonama [25]. Učinkovitost prijevoza tereta u Belgiji je istražena 2010. godine gdje su kao pokazatelje učinkovitosti prijevoznika u cestovnoom sektoru koristili dodanu vrijednost i profit [26]. U 2011. godini istražena je stopa punjenja vozila kao mjera za izračun učinkovitosti prijevoza. Kao pokazatelji istraženi su: masa, volumen te udio površine vozila prekrivenog teretom [27]. U tematskom području učinkovitosti prijevoza 2016. godine dan je pregled različitih istraživanja koja su se bavila učinkovitošću prijevoza te je za svako istraživanje dan pregled istraženih pokazatelja učinkovitosti prijevoza. Također tu je istražen problem prijevoza između distribucijskih centara gdje su kao pokazatelji učinkovitosti prijevoza korišteni potrošnja goriva, cijena goriva, vrijeme iskorištenosti vozila, masa prevezenog tereta, prijeđena udaljenost i volumenska iskorištenost vozila [28].

U prijevozu paketskih pošiljaka poštom značajno je istraživanje Ministarstva za promet Velike Britanije provedeno 2006. godine. U njemu je istražena učinkovitost prijevoza paketskih pošiljaka. Istraživanje je provedeno na davateljima poštanskih usluga u Velikoj Britaniji (DHL Express UK-u, Geopost-u, OCS Worldwide-u (Overseas Courier Service),

Parcelforce Worldwide-u). Davatelji su poštanskih usluga smatrali da su izvedbeni pokazatelji za mjerenje učinkovitosti prijevoza paketskih pošiljaka za područje dostave i prikupljanja paketskih pošiljaka sljedeći: popunjenost vozila na početku i kraju putovanja, vrijeme iskorištenosti vozila, broj pošiljaka po vožnji po tipu vozila, broj kilometara po vožnji po tipu vozila i iskorištenost goriva (potrošnja goriva (km/l goriva), intenzitet goriva (ml goriva potrebni za prijevoz jedne pošiljke po kilometru) i učinkovitost goriva (pošiljaka/l goriva)). Za prijevoz između hub-ova odnosno poštanskih središta izvedbeni pokazatelji su: popunjenost vozila, kilometri praznog vozila, vrijeme iskorištenosti vozila i potrošnja goriva [29]. Temeljem analize provedenih istraživanja može se zaključiti da ne postoje opći izvedbeni pokazatelji za mjerenje učinkovitosti prijevoza koju primjenjuju davatelji prijevoznih usluga kako bi mjerili svoju operativnu učinkovitost. Davatelji prijevoznih, odnosno poštanskih usluga primjenjuju različite izvedbene pokazatelje za mjerenje učinkovitosti prijevoza za koje smatraju da su bitne za njihovo poslovanje.

Istraživanja su pokazala da se učinkovitost prijevoza može mjeriti kroz iskorištenost prijevoznih kapaciteta. Učinkovitost prijevoza može se definirati kao omjer stvarnog iskorištenog kapaciteta s ukupnim raspoloživim kapacitetom [30]. Istraživanje je na uzorku od 53 vozna parka u britanskom lancu opskrbe hranom pokazalo da je prosječna masena iskorištenost vozila 69% [30], dok je kod srodnog istraživanja, u području učinkovitosti prijevoza paketskih pošiljaka na davateljima poštanskih usluga u Velikoj Britaniji utvrđeno da je prosječna volumenska iskorištenost vozila na početku svakog putovanja bila 44%, pri čemu je šest od osam voznih parkova imalo iskorištenost ispod 55% [29]. Istraživanje provedeno u Nizozemskoj na pet različitih prijevoznika gdje je analizirano 150 putovanja na kojima se prevozio generalni teret utvrđen je prosječni iskorišteni volumenski kapacitet od 82% [27]. Istraživanje provedeno na tri vodeće švedske tvrtke u prijevozu tereta, gdje su analizirana 263 prijevoza, pokazalo je prosječnu stopu volumenske iskorištenosti vozila 61,2% [31].

Povećanje iskorištenosti prijevoznih kapaciteta može se postići na više načina kao što je povećanje konsolidacije tereta, promjena ambalaže i sortiranja, modificiranje dizajna i dimenzija opreme kojom se rukuje (palete, roll kontejneri itd.), korištenjem vozila s dvije razine koje mogu smjestiti teret u dva sloja (dvostrukom površinom za prijevoz tereta) te prilagodbom kapaciteta vozila da ono što više odgovara specifičnim dimenzijama i masi prevoženog tereta [27, 32].

1.4. Metode istraživanja

Za istraživanje i prikazivanje rezultata istraživanja korištena je metoda analize i sinteze, različite metode deskriptivne i inferencijalne statistike, komparativna metoda, metoda uzorka te matematička metoda [33, 34, 35].

Metoda analize i sinteze korištena je za analizu varijabli koje su korištene za izradu regresijskih modela, za tumačenje dobivenih rezultata istraživanja, za utvrđivanje metodologije za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unaprjeđenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu.

Metode deskriptivne statistike korištene su za statističko opisivanje prikupljenih podataka o nezavisnim i zavisnoj varijabli dobivenih iz relevantnih dostupnih znanstvenih i stručnih izvora te redovitih statističkih publikacija. Tabelarno i grafički prikazani su za svaku pojedinu varijablu vrijednosti njihovih kretanja. Tabelarno su prikazane prosječne vrijednosti, medijan, minimalna vrijednost, maksimalna vrijednost, standardna devijacija te koeficijent varijacije. Grafički su prikazane prosječne vrijednosti, standardna devijacija te linijskim grafom kretanje varijabli tijekom promatranog razdoblja.

Metode inferencijalne statistike korištene su za donošenje zaključaka temeljem odabranih varijabli, za koje se pretpostavlja postojanje izravne i neizravne povezanosti s kretanjem broja paketskih pošiljki u odabranoj jedinici vremena te kod izrade projekcija za buduća kretanja. Od metoda inferencijalne statistike korištena je metoda korelacije i metoda regresije. Metodom korelacije ispitana je korelacija između broja paketskih pošiljaka i nezavisnih varijabli te međusobna korelacija nezavisnih varijabli. Za ispitivanje korelacije korišten je Pearsonov koeficijent korelacije. Ova metoda korištena je za izradu matrice korelacije te grafički prikaz korelacija između varijabli. Metoda regresije korištena je za izradu modela pri čemu je korištena višestruka linearna regresija. Ovom metodom izračunati su parametri regresijskog modela. Vrednovani su parametri (regresijski koeficijent) izabranih nezavisnih varijabli, odnosno njihov utjecaj na broj paketskih pošiljaka. Za izbor (selekciju) varijabli u regresijski model korištena je stepwise regresijska metoda koja osigurava da model uključuje samo statistički značajne varijable, a eliminira one koje nisu statistički značajne [36]. Izabrana je stepwise regresija s pomakom unaprijed poznata kao forward stepwise regresija. Za validaciju modela korišten je ANOVA test. Ovim testom testirane su hipoteze o postojanju značajnih parametara u modelu.

Metode regresijske dijagnostike, koje dijelom spadaju u inferencijalnostatističke, a dijelom u deskriptivnostatističke [33], korištene su za ispitivanje kakvoće modela. Metoda analize korelacijske matrice, uz pokazatelja multikolinearnost (tolerancu), korištena je za otkrivanje problema multikolinearnosti. Za otkrivanje problema heteroskedastičnosti korišteni su grafički prikazi i test značajnosti Spearmanova koeficijenta korelacije.

Komparativna metoda korištena je za usporedbu utjecaja odabranih varijabli na kretanje broja paketa u odnosu na očekivano, usporedbu rezultata preciznosti procjene regresijskih modela te usporedbu odstupanja modela i pretpostavke promatranog davatelja poštanske usluge u odnosu na ostvareni broj paketskih pošiljaka promatranog davatelja poštanskih usluga.

Metoda uzorka korištena je za izračun prosječne mase i volumena paketskih pošiljaka.

Matematička metoda korištena je primjenom matematičkih operacija i formula za određivanje učinkovitosti prijevoza paketskih pošiljaka.

1.5. Kompozicija rada

Doktorski rad sastoji se od šest poglavlja, literature, priloga, popisa tablica te popisa slika.

Poglavlja doktorskog rada su:

1. Uvod

2. Paketsko tržište u poštanskom prometu

3. Odrednice modela utjecaja čimbenika na broj paketskih pošiljaka

4. Regresijski modeli utjecaja izabranih čimbenika na broj paketskih pošiljaka

5. Učinkovitost prijevoza paketskih pošiljaka

6. Zaključak

U uvodu je opisan problem istraživanja te su definirane znanstvene hipoteze. Nakon toga opisana je svrha i cilj istraživanja. Zatim je dan pregled dosadašnjih istraživanja u predmetnom području te su opisane znanstvene metode koje su korištene u istraživanju i

prikazu rezultata istraživanja. Na kraju prikazana je kompozicija rada u kojoj je dan kratak opis svakog poglavlja doktorskog rada.

U drugom poglavlju „Paketsko tržište u poštanskom prometu“ opisano je CEP (eng. Courier, Express, Postal) tržište. Prikazan je broj paketskih pošiljaka u svijetu u unutarnjem i međunarodnom prometu te predviđanje budućeg razvoja svjetskog CEP tržišta. Posebno je prikazano europsko CEP tržište, broj paketskih i ekspres pošiljaka te mase pošiljaka po zemljama. Opisana je e-trgovina kao pokretač razvoja tržišta i povećanog broja paketskih pošiljaka. Na kraju poglavlja opisano je tržište Republike Hrvatske te udio paketskih pošiljaka u unutarnjem i međunarodnom prometu.

U trećem poglavlju „Odrednice modela utjecaja čimbenika na broj paketskih pošiljaka“ dana je metodološka podloga za izradu regresijskih modela. Opisana je i objašnjena korelacijska analiza. Objašnjen je Pearsonov koeficijent korelacije i dan je izraz za njegov izračun. Objašnjena je korelacijska matrica i dijagram rasipanja prognostičkog modela. Opisane su postavke regresijske analize, svi postupci koji su korišteni za izradu prognostičkog modela te mogući problemi koji se pri tome mogu javiti. Zatim je napravljena analiza čimbenika koji utječu na broj paketskih pošiljaka. Prikazana su relevantna istraživanja u kojima su definirani mogući čimbenici te su utvrđeni novi čimbenici za koje se smatra da bi mogli utjecati na broj paketskih pošiljaka. Također se daje opis svakog čimbenika, prikazan je način prikupljanja i obrade podataka o svakom istraženom čimbeniku.

U četvrtom poglavlju „Regresijski modeli utjecaja izabranih čimbenika na broj paketskih pošiljaka“ opisani su postupci izrade regresijskih modela. Napravljena su dva regresijska modela koja se temelje na godišnjim podacima od kojih je jedan s varijablom trend. Za izradu modela korištena je višestruka linearna regresija. Napravljena je usporedba procijenjenih regresijskih modela te analiza reprezentativnosti izabranog prognostičkog modela broja paketskih pošiljaka na stvarnim podacima. Primjenom deskriptivne statistike i korelacijske analize odabrane su varijable koje se koriste u modelu. Vrednovani su čimbenici koji utječu na kretenje broja paketskih pošiljaka.

U petom poglavlju „Učinkovitost prijevoza paketskih pošiljaka“ opisuju se relevantna istraživanja i pokazatelji učinkovitosti prijevoza. Učinkovitost prijevoza je mjerena pokazateljima masene i volumenske iskorištenosti prijevoznih kapaciteta budući da se često primjenjuje u istraživanjima učinkovitosti prijevoza. Podatak o masi i volumenu paketskih pošiljaka u Republici Hrvatskoj je dobiven uzorkom te je nakon prikupljanja izračunata

prosječna masa i volumen paketskih pošiljaka. Napravljena je validacija prognostičkog modela, radi unapređenja učinkovitosti prijevoza paketskih pošiljaka, usporedbom rezultata prognostičkog modela broja paketskih pošiljaka s planiranim brojem paketskih pošiljaka promatranog davatelja poštanskih usluga te je napravljena i validacija modela temeljem pokazatelja mase i volumena. Definirana je metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unapređenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu te je razvijen model koji omogućuje analizu prijevoznih kapaciteta i optimizaciju voznog parka. Na kraju je primijenjena metodologija između entiteta poštanske mreže za definiranje potrebnih kapaciteta prijevoznih sredstava.

U šestom poglavlju „Zaključak“ dan je kratak osvrt na poglavlja doktorskog rada te su izneseni zaključci vezani za znanstveno istraživanje i ostvarene rezultate istraživanja. Također predložena je mogućnost primjene modela i metodologije za utvrđivanje potrebnih kapaciteta prijevoznih sredstava čime je moguće unaprijediti učinkovitost prijevoza paketskih pošiljaka u poštanskom prometu.

2. PAKETSKO TRŽIŠTE U POŠTANSKOM PROMETU

Na tržištu poštanskih usluga zastupljene su tri grupe usluga koje uključuju pismovne pošiljke, paketske pošiljke te ekspres i kurirske pošiljke. Na tržištu se bilježi konstantni pad pismovnih pošiljaka uzrokovan supstitucijom poštanskih usluga elektroničkim uslugama [37]. Kod paketskih, ekspresnih i kurirskih pošiljaka događa se suprotno, njihov broj s godinama raste, čemu je sigurno pridonijela e-trgovina [38, 39]. Ovi trendovi zahvatili su poštansko tržište u čitavom svijetu uključujuću EU i Republiku Hrvatsku. U Europi se posljednjih deset godina kupovne navike mijenjaju te raste udio korisnika koji kupovinu obavljaju online, stoga industrija poštanskih usluga ima važnu ulogu u gospodarskom i društvenom razvoju mnogih država [37].

2.1. Svjetsko paketsko tržište

Koliko je značajno paketsko tržište pokazuje procjena rasta do 2024. godine. Procjenjuje se da će tržište kurirskih, ekspresnih i paketskih pošiljaka iznositi više od 400 milijardi USD u 2024. godini s prosječnom godišnjom stopom rasta (engl. Compound Annual Growth Rate – CAGR) od 8-10% tijekom predviđenog razdoblja od 2019. do 2024. godine [38]. U 2017. godini svjetsko paketsko tržište procijenjeno je na oko 289 milijardi USD [40].

U cijelom svijetu u posljednjih deset godina zabilježena je velika stopa rasta CEP industrije gdje je e-trgovina jedan od važnijih pokretača rasta tržišta, a što istovremeno donosi značajne prihode industriji. Značajan je rast CEP industrije u zemljama u razvoju zbog rasta međunarodne trgovine, povećanja širenja Interneta i pametnih telefona koji potiču e-trgovinu, povećanja broja stanovnika srednje klase i raspoloživog dohodaka te poboljšanja životnog standarda. Također na rast CEP industrije utječe nastajanje maloprodaje s više kanala te rast trgovine potaknut ekonomskim rastom, dok s druge strane dolazi do problema nedostatka odgovarajuće infrastrukture i tehnologije što uzrokuje usporavanje rasta tržišta [38].

Do rasta prometa međunarodnih paketskih pošiljaka dolazi zbog rasta prekogranične e-trgovine, zbog čega međunarodno CEP tržište ima veći rast od unutarnjeg CEP tržišta [38].

Paketske pošiljke na tržištu mogu biti Business to Business (B2B), Business to Customer (B2C) i Consumer to Consumer (C2C) odnosno mogu se slati između tvrtki, tvrtke mogu slati

paketske pošiljke prema osobnom korisniku te se paketske pošiljke mogu slati između fizičkih osoba [54]. Do prije nekoliko godina B2C pošiljke prevladavale su na unutarnjem tržištu od strane CEP tvrtki. Međutim širenje kupovine putem Interneta dovelo je do prekogranične e-trgovine što je rezultiralo rastom međunarodnih B2C pošiljaka diljem svijeta. Rast u međunarodnoj trgovini potaknut je sporazumima o slobodnoj trgovini i posebnim gospodarskim zonama što također pokreće međunarodno tržište paketa. Dvije u svijetu najpopularnije destinacije za prekograničnu kupovinu putem e-trgovine su Kina i SAD [38]. Na slici 1. može se vidjeti da broj paketskih pošiljaka otpremljenih diljem svijeta raste.

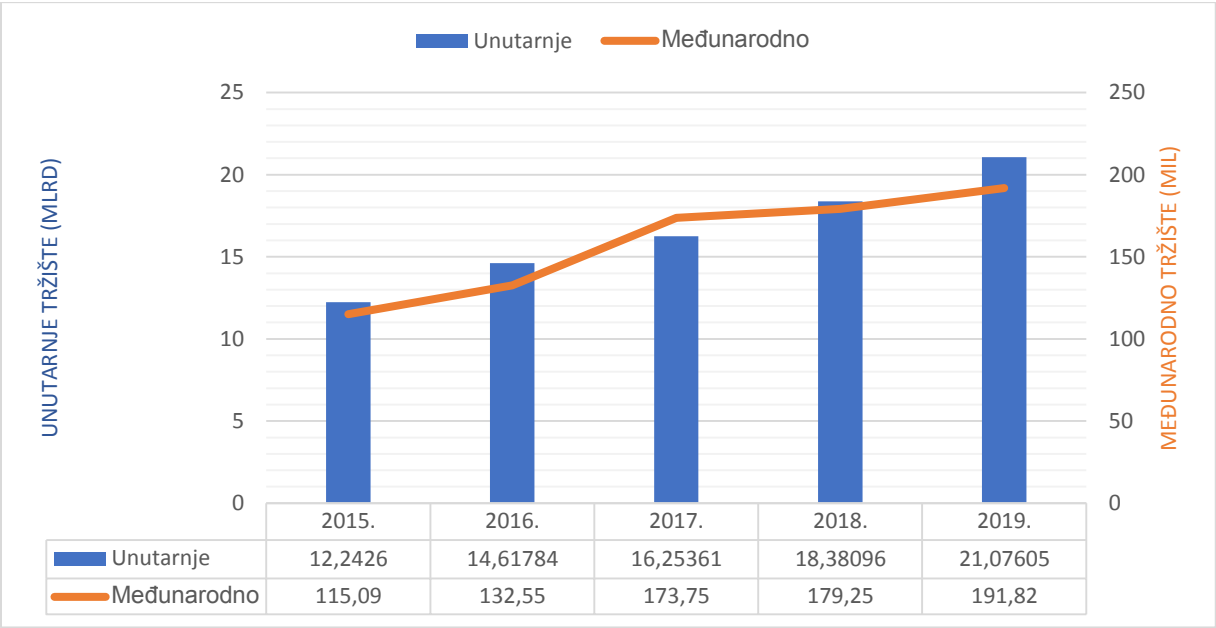

Slika 1. Broj paketskih pošiljaka u svijetu na unutarnjem i međunarodnom tržištu. Autor uredio prema [41]

Unutarnje tržište paketskih pošiljaka 2016. u odnosu na 2015. poraslo je za 19,40%, 2017. poraslo za 11,19% u odnosu na prethodnu godinu, 2018. za 13,09% u odnosu na 2017. te 2019. u odnosu na 2018. za 14,66%. U međunarodnom paketskom tržištu 2016. u odnosu na 2015. zabilježen je porast paketskih pošiljaka za 15,17%, u 2017. za 31,08% u odnosu na 2016., 2018. za 3,17% u odnosu na 2017. te 2019. za 7,01% u odnosu na 2018.

U periodu od 2015. do 2019. unutarnje je paketsko tržište u svijetu poraslo za 72,15%, te je utvrđena prosječna godišnja stopa rasta od 14,55%, dok je međunarodno tržište u tom periodu poraslo za 66,67%, odnosno utvrđen je prosječan godišnji porast od 13,62%. Ukupno paketsko tržište (unutarnje i međunarodno) u periodu od 2015. do 2019. poraslo je za 72,10%.

Pandemija uzrokovana COVID-Sars2 virusom krajem 2019. dodatno je utjecala na razvoj tržišta. Tijekom 2020. godine na CEP tržištu dogodila se promjena odnosno došlo je do pada na B2B tržištu, dok je u unutarnjem prometu došlo do značajnog povećanja na B2C i C2C tržištu [42].

Očekuje se da će potražnja za uslugama CEP-a imati veliki porast do 2024. u Azijsko-pacifičkoj regiji koja geografski obuhvaća Kinu, Japan, Australiju, Indiju, Singapur, Maleziju, Indoneziju, Vijetnam, Južnu Koreju te ostatak Azijsko-pacifičke regije. Ta se očekivanja temelje na velikom porastu broja stanovnika, rastućim dohodcima pa tako i životnog standarda te dinamici međunarodne trgovine. Vlade zemalja u Azijsko-pacifičkoj regiji fokusiraju se na razvoj proizvodnog sektora. Globalne tvrtke, uglavnom, uspostavljaju svoju proizvodnju u ovoj regiji zbog čega međunarodna trgovina zemalja ove regije raste te se očekuje da će se u budućnosti i dalje povećavati. Sektor maloprodaje u ovoj regiji, također, ima brzi rast. Kina ima najveći udio na azijsko-pacifičkom CEP tržištu, te najveće tržište ekspresne dostave na svijetu koje čini gotovo 40% ukupnog broja isporuka cijelog svijeta. Kako Jugoistočna Azija predstavlja na globalnoj razini najpopularnije područje glede ulaganja, u njoj se očekuje povećanje e-trgovine u nekoliko narednih godina. Na slici 2. može se vidjeti stopa rasta CEP tržišta po regijama za predviđeno razdoblje od 2019. do 2024. [38].

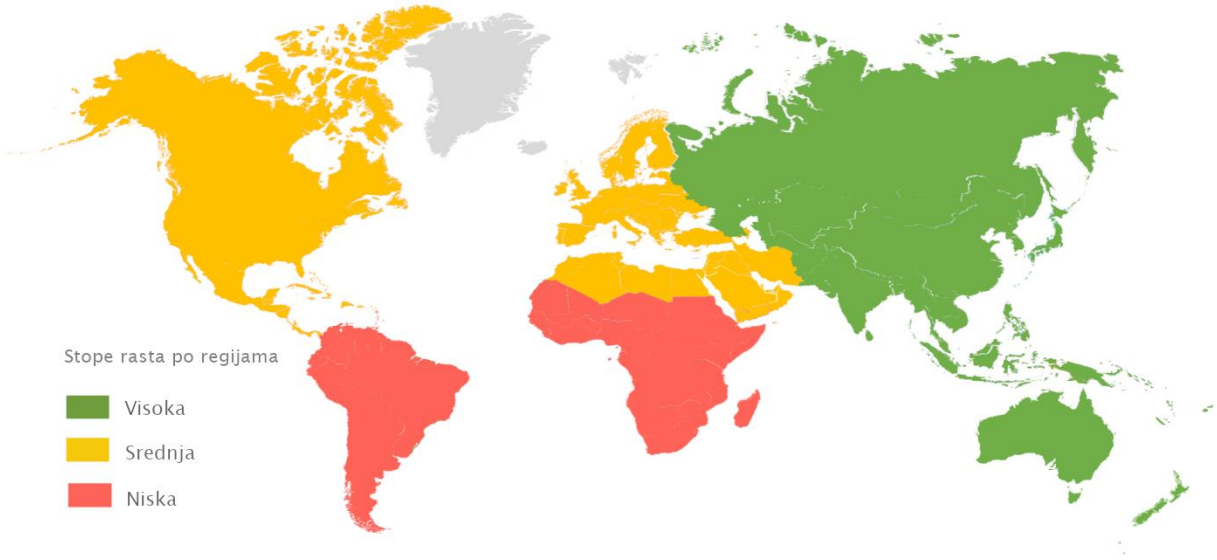

Slika 2. CEP tržište po regijama [38]

Glavni operatori na CEP tržištu su globalni integratori usluga poput Deutsche Post DHL Group, United Parcel Service Inc. (UPS), FedEx Corporation, Aramex PJSC, SF Express (Group) Co. Ltd. [38].

2.2. Europsko paketsko tržište

Na europskom CEP tržištu događaju se isti trendovi kao i na svjetskoj razini. Prihodi i broj pošiljaka iz godine u godinu bilježe stalni rast. Pošiljke u međunarodnom prometu zauzimaju manji udio na europskom tržištu, primjetan je trend bržeg rasta u odnosu na broj pošiljaka u unutarnjem prometu.

Od 2009. do 2011. godine CEP industrija imala je godišnji rast broja pošiljaka od 6% [43]. Od 2011. do 2013. godine poslovanje CEP tržišta nastavlja rasti. Pošiljke u unutarnjem prometu na europskom tržištu 2013. zauzimaju 90% od ukupnog broja pošiljaka i donose 70% ukupnog prihoda dok se na međunarodno tržište odnosi 10%. Broj pošiljaka na unutarnjem tržištu imao je isti godišnji rast od 5% dok se rast na međunarodnom tržištu povećavao. Tako je rast pošiljaka na međunarodnom tržištu od 2011. do 2012. bio 6%, a od 2012. do 2013. 8%.

U svim europskim zemljama, izuzev Rusije, broj međunarodnih pošiljaka rastao je brže od broja unutarnjih pošiljaka, jedino je Italija bilježila smanjenje broja pošiljaka u unutarnjem prometu [44]. Na paketskom tržištu bio je predviđen daljnji rast prometa paketskih pošiljaka u unutarnjem prometu, s ukupnim prometom od 5,554 milijardi [44].

Od 2013. na EU tržištu prosječno godišnje povećanje paketskih i ekspresnih pošiljaka bilo je 13% što je prikazano na slici 3. [45].

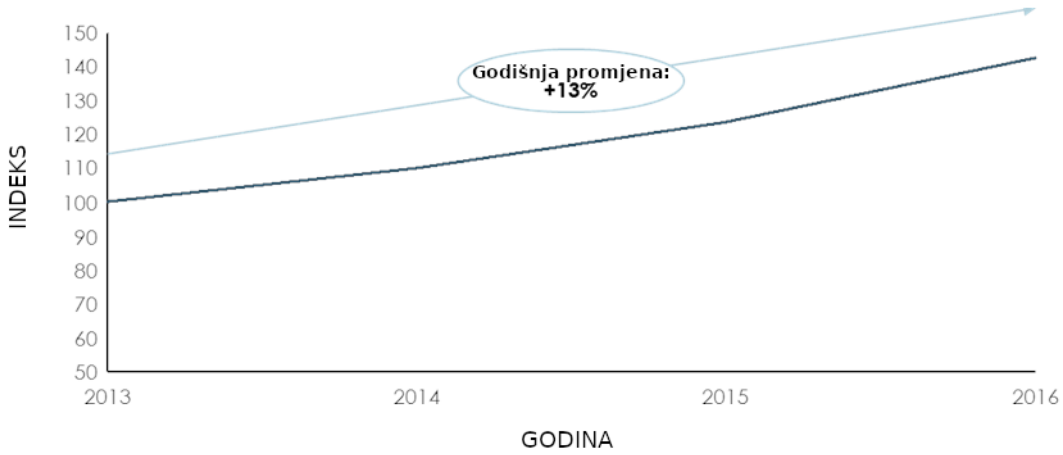

Slika 3. Prikaz rasta broja paketskih i ekspresnih pošiljaka, indeks (2013 = 100) [45]

Broj pošiljki na međunarodnom CEP tržištu nastavio je rasti što je prikazano na slici 4. Najveći rast broja imala je Poljska s 31%, iza nje su slijedile Rumunjska sa 17%, Nizozemska

s 15%, Češka s 14% te Velika Britanija s 13%. U Nizozemskoj i Velikoj Britaniji rast broja pošiljaka nastao je zbog velikog rasta pošiljaka e-trgovine, a dodatnu potražnju za pošiljkama iz Velike Britanije potaknuo je i pad vrijednosti britanske funte [46, 47]. Najmanji rast imala je Francuska sa 6% i Švedska s 4%, dok u Turskoj nije bilo porasta broja pošiljaka [46]. Iz slike 4. također se može vidjeti da su na međunarodnom europskom CEP tržištu zastupljenije standardne paketske pošiljke (usluga u određeno vrijeme i s odgodom) nego paketske ekspresne pošiljke (najbrža moguća usluga s garantiranim vremenom uručenja).

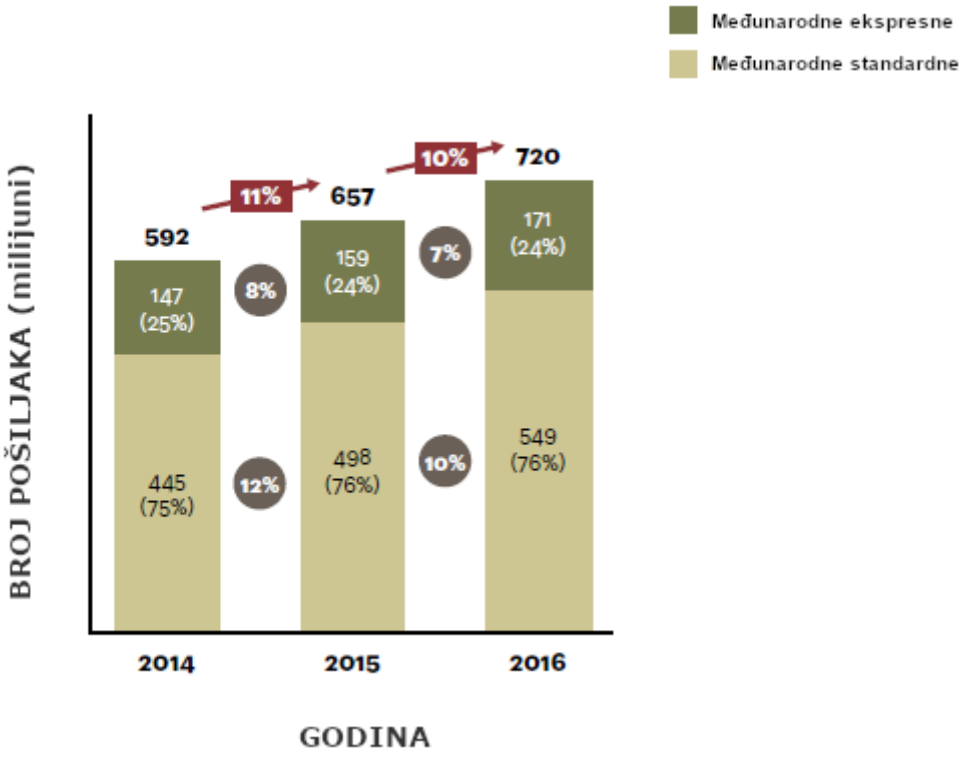

Slika 4. Europsko međunarodno CEP tržište [46]

Rast europskog paketskog tržišta se nastavlja što se može vidjeti na slici 5. U 2019. broj paketskih pošiljaka na europskom CEP tržištu nastavio je rasti zbog međunarodne i prekogranične B2C e-trgovine [48].

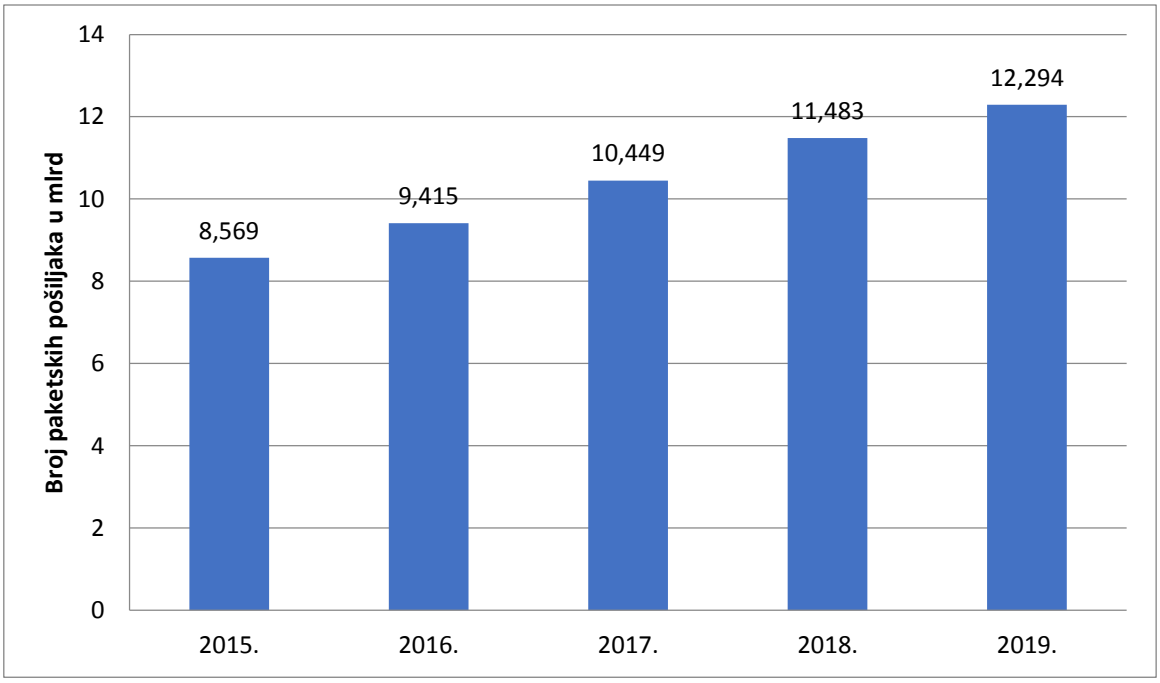

Slika 5. Isporučene paketske pošiljke na europskom CEP tržištu [49]

U 2016. 71% paketskih pošiljaka isporučeno je u tri zemlje (Njemačka, Velika Britanija i Francuska). U 2017. godini zabilježen je rast udjela isporučenih paketskih pošiljaka za 1 postotni bod u Velikoj Britaniji, zbog čega je ukupni udio 3 najznačajnije zemlje u isporuci paketskih pošiljaka (Njemačka, Velika Britanija i Francuska) porastao na 72%., što se može vidjeti na slikama 6. i 7.

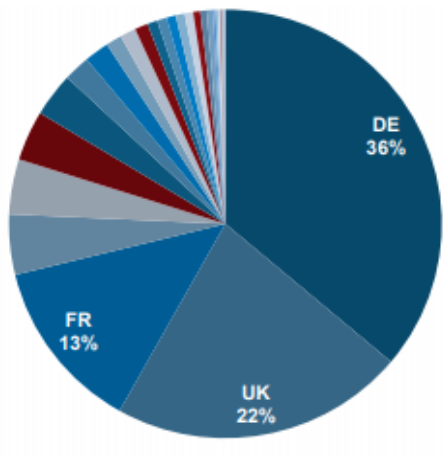

Slika 6. Europsko paketno tržište 2016. [50]

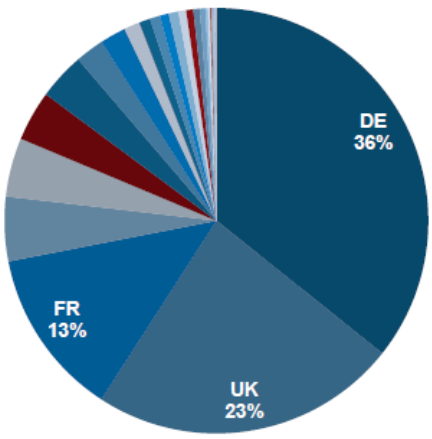

Slika 7. Europsko paketsko tržište 2017. [51]

Broj poslanih paketskih i ekspresnih pošiljaka s 22 po stanovniku najveći je u sjevernoj Europi, zatim iza nje slijedi zapadna Europa s 12 pošiljaka, istočna s 10 te južna sa 6. Na slici 8. može se vidjeti potražnja za paketskim i ekspres pošiljkama po stanovniku prema pojedinim zemljama. Na prvom se mjestu nalazi Velika Britanija s 22 pošiljke po stanovniku, dok je na zadnjem Malta sa samo jednom pošiljkom po stanovniku. Republika Hrvatska ima 5 poslanih paketskih i ekspresnih pošiljka po stanovniku što je svrstava ispod prosjeka EU koji iznosi 8 pošiljaka po stanovniku [45].

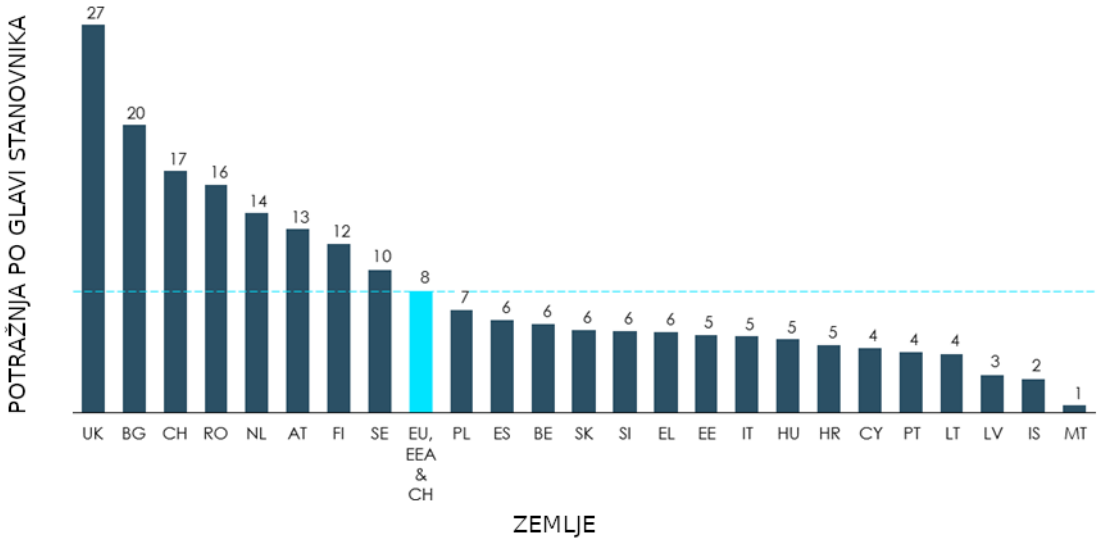

Slika 8. Potražnja za paketskim i ekspres pošiljkama po stanovniku po zemljama [45]

Kada je riječ o tržištu, nacionalni poštanski operatori imaju niže tržišne udjele u segmentu paketa nego u segmentu pismovnih pošiljaka. Tržišni udio nacionalnih poštanskih operatora u području paketa u prosjeku je 32%. Na slici 9. mogu se vidjeti velike razlike u tržišnom udjelu nacionalnih poštanskih operatora u području paketskih i ekspresnih pošiljaka pojedinih zemalja. Prema podacima prikazanim na slici Hrvatska Pošta d.d. s udjelom od 18% nema značajan udio u segmentu paketa na Hrvatskom tržištu [45].

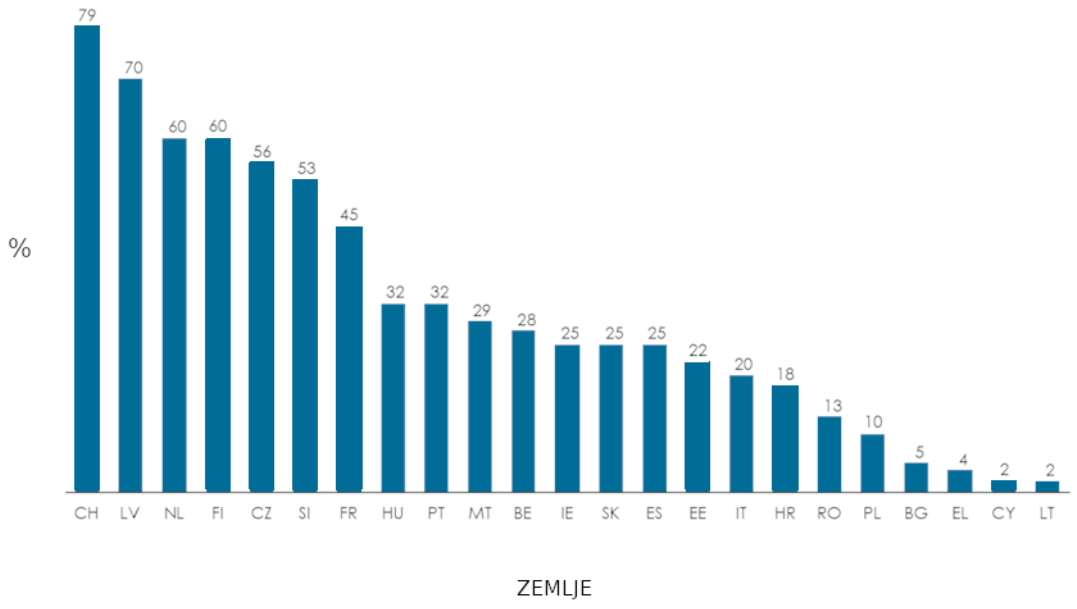

Slika 9. Prikaz postotnog udjela nacionalnih poštanskih operatera na unutarnjem tržištu paketa i ekspresnih pošiljaka u 2016. [45]

Vezano uz masu paketskih pošiljaka na međunarodnom tržištu, kod međunarodnih običnih paketskih pošiljki došlo je do smanjenja mase za 0,6%, dok je kod međunarodnih ekspres pošiljki došlo do rasta mase pošiljaka za 1,3% s tim da je masa ekspresnih pošiljaka ostala ispod 10 kg [44], što se može vidjeti iz slike 10. U međunarodnim običnim paketskim pošiljkama zabilježen je pad prosječne mase pošiljke 2013. u odnosu na 2012. sa 16,9 kg na 16,8 kg dok se kod međunarodnih ekspres pošiljaka prosječna masa pošiljke 2013. u odnosu na 2012. povećala sa 7,5 kg na 7,6 kg. Istraživanje je pokazalo da se masa običnih paketskih pošiljaka razlikuje među zemljama. Na primjer u Velikoj Britaniji iznosila je 14 kg, Nizozemskoj 15 kg, Austriji 8 kg, Turskoj 18 kg [44].

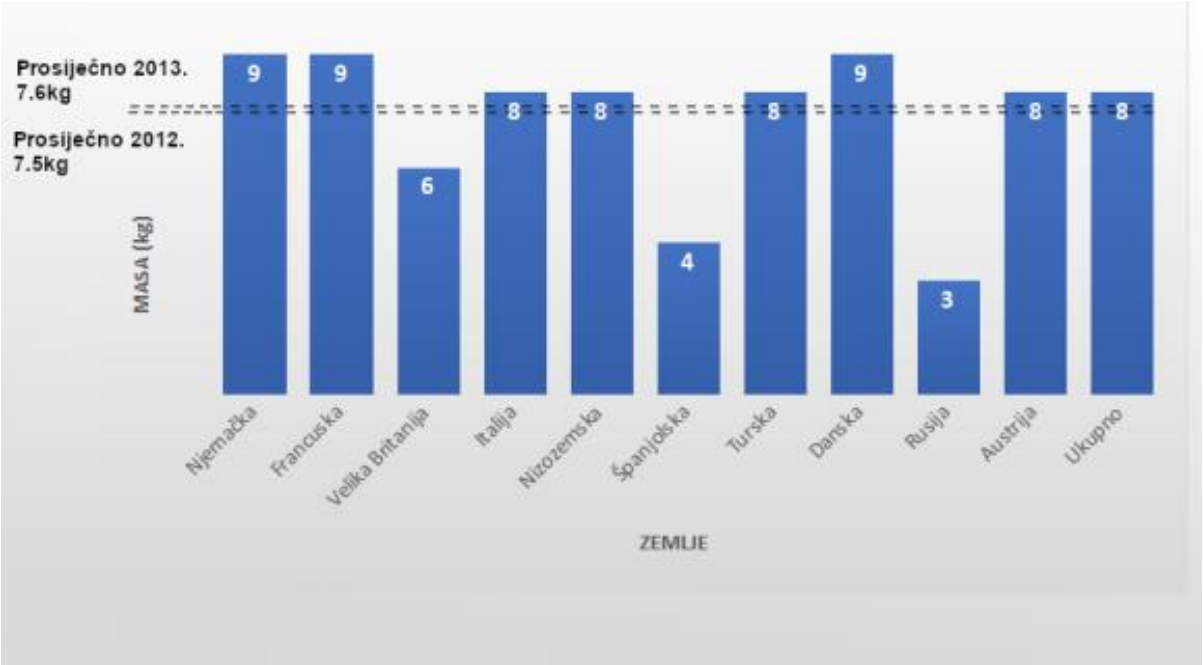

Slika 10. Prikaz mase međunarodnih ekspres pošiljki u pojedinim zemljama u 2013. Autor uredio prema [44]

Prosječna masa paketskih i ekspresnih pošiljaka ponovno je bila predmet istraživana 2015. i 2016. godine. Usporedba mase ekspresnih pošiljaka po zemljama može se vidjeti na slici 11. Za razliku od prijašnjeg istraživanja ovdje su uključene još tri zemlje. Prosjeci masa običnih paketskih pošiljaka bili su veći, dok je prosječna masa ekspresnih pošiljaka bila gotovo ista. Ovdje se masa pojedinačne pošiljke nastavila smanjivati u oba međunarodna segmenta. U međunarodnim običnim paketskim pošiljkama zabilježen je pad prosječne mase pošiljke za 2% s 19,3 kg na 18,9 kg. Kod međunarodnih ekspres pošiljaka prosječna masa pošiljke smanjila se za 1% sa 7,3 kg na 7,2 kg i to zbog većeg broja lakših pošiljka e-trgovine, usmjeravanja težih pošiljaka prema špediterima te smanjenog udjela dokumenata u ukupnom asortimanu proizvoda [46].

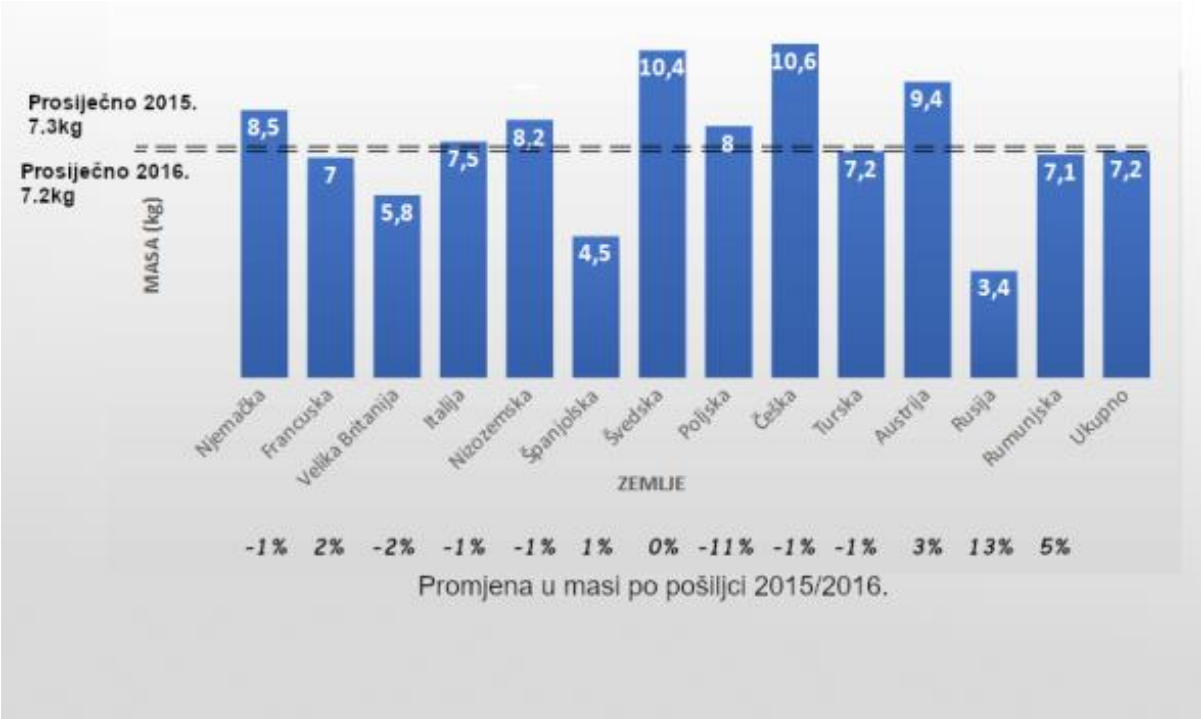

Slika 11. Prikaz mase međunarodnih ekspresnih pošiljaka pojedinih zemalja u 2016. Autor uredio prema [46]

Mase običnih paketskih pošiljaka u istraženim zemljama također su bile različite. U pojedinim zemljama u odnosu na prijašnje istraživanje došlo je do znatnije promjene mase običnih paketskih pošiljaka, kao na primjer u Nizozemskoj i Velikoj Britaniji, dok kod ekspresnih pošiljaka nije bilo većih oscilacija. Tako je u Nizozemskoj masa običnih paketskih pošiljaka pala na 7,9 kg, a u Velikoj Britaniji na 11,1 kg, u Austriji na 7,3 kg, te u Turskoj na 17,1 kg [46]. Iako se prosječna masa međunarodnih ekspres pošiljaka smanjila, u nekim zemljama njihova masa prešla je 10 kg za razliku od 2013. kada ni u jednoj zemlji, koja je bila uključena u istraživanje, nije premašen taj iznos.

Prosječan volumen paketskih pošiljaka u EU iznosi 0,06 m^3 [52].

Rast broja paketskih pošiljaka/paketskih pošiljaka e-trgovine ima značajne posljedice za okoliš. Dostava paketskih pošiljaka zahtijeva znatno više logističkih i transportnih kapaciteta od pisama. Emisija ugljika po paketskoj pošiljci veća je deset puta od emisije ugljika po pismovnoj pošiljci [45].

2.3. E-trgovina

Kao bitan čimbenik rasta broja paketskih pošiljaka u svijetu svakako treba spomenuti e-trgovinu koja je započela 1990-ih godina. U početnom razdoblju najveći rast bio je u razdoblju između 1997. i 2000. godine koji je poznat pod nazivom dot-com mjehurić. U godinama koje su slijedile nastavljen je trend porasta udjela e-trgovine na godišnjoj razini [53]. U razdoblju između 2000. i 2007. u Europi je došlo do intenzivije primjene širokopojasnih tehnologija i Interneta. Unapređenjem tehnologija brzog Interneta, padom cijena za krajnje korisnike i povećanjem mogućnosti izbora došlo je do sve većeg širenja tržišta e-trgovine. Dodatno, na rast e-trgovine utjecao je i sve veći broj web trgovina, poboljšanje online sustava plaćanja te fleksibilnije opcije isporuke pošiljaka [53].

Na području EU kupovina putem Interneta raste bilo da se radi o kupovini unutar zemlje ili prekograničnoj kupovini. E-trgovina razvijenija je u zemljama Zapadne i Sjeverne Europe nego u Istočnoj i Južnoj što je vidljivo na slici 12.

Može se utvrditi da je među EU-28 članicama došlo do porasta udjela potrošača koji kupuju online, te potrošača koji kupuju online u inozemstvu u 2017. godini u odnosu na 2013. godinu.

Najmanja upotreba Interneta za kupnju, kao i online kupnju u inozemstvu, utvrđena je među stanovnicima Rumunjske, a najveća je upotreba Interenta za kupovinu utvrđena među stanovnicima Velike Britanije, te Švedske nakon kojih slijedi Luksemburg koji ima najveći udio online kupnji u inozemstvu. Upotreba online trgovine, te online trgovine u inozemstvu u Republici Hrvatskoj je ispod prosjeka EU-28 (2017.).

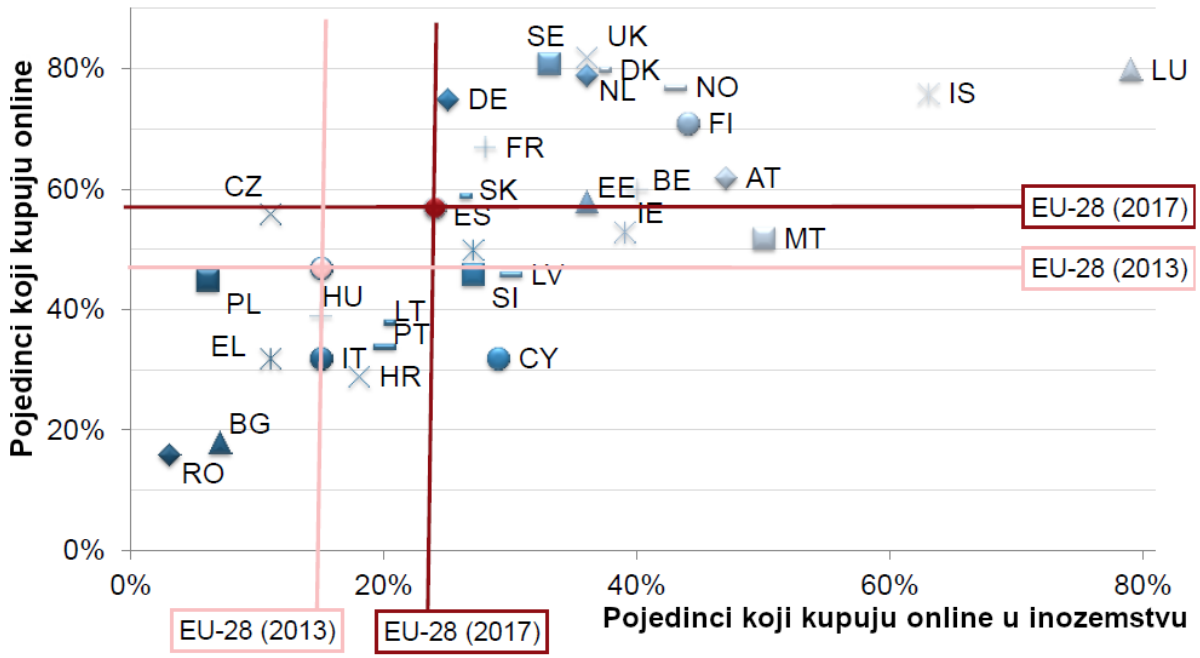

Slika 12. Usporedba B2C online kupovine 2013. i 2017. godine na području EU-28 [51]

Uobičajeni poštanski paketi većinom su dio C2C tržišnog segmenta [54] dok se B2C tržište sastoji uglavnom od paketskih pošiljaka od prodaje na daljinu kod koje se proizvodi naručuju putem usluge elektroničke pošte i Internet prodajom [53]. Veliki poslovni korisnici, koji u svom poslovanju imaju segment e-trgovine, šalju veliki broj paketa, a privatni korisnici uglavnom šalju poklone ili stvari koje su prodali na mreži C2C [45]. B2C pošiljke te C2X pošiljke (eng. consumer to consumer/package returns), koje obuhvaćaju slanje paketskih pošiljaka između fizičkih osoba/povrat paketa, bilježe velik rast zbog Internet trgovine koja je rasla u svim zemljama EU od 2009. godine. Internetski trgovci poput Amazona za isporuku svojih proizvoda koriste B2C paketske pošiljke. „Peer to peer“ Internetske usluge poput eBaya koriste C2X paketske usluge kako bi korisnici međusobno mogli slati kupljenu robu [40].

Internetska kupovina ovisi o dostupnosti i brzini prijenosa podataka putem Interneta što znači da veća rasprostranjenost Interneta direktno utječe na povećanje udjela broja pojedinaca koji kupuju online [51]. Povezanost između korištenja Interneta i naručivanja robe online prikazana je na slici 13. iz koje se može vidjeti da postoji pozitivna linearna korelacija između korištenja Interneta i naručivanja robe online. Republika Hrvatska nalazi se pri samom dnu ljestvice zemalja EU kada se analizira korištenje Interneta pojedinaca i njihovom naručivanju robe online.

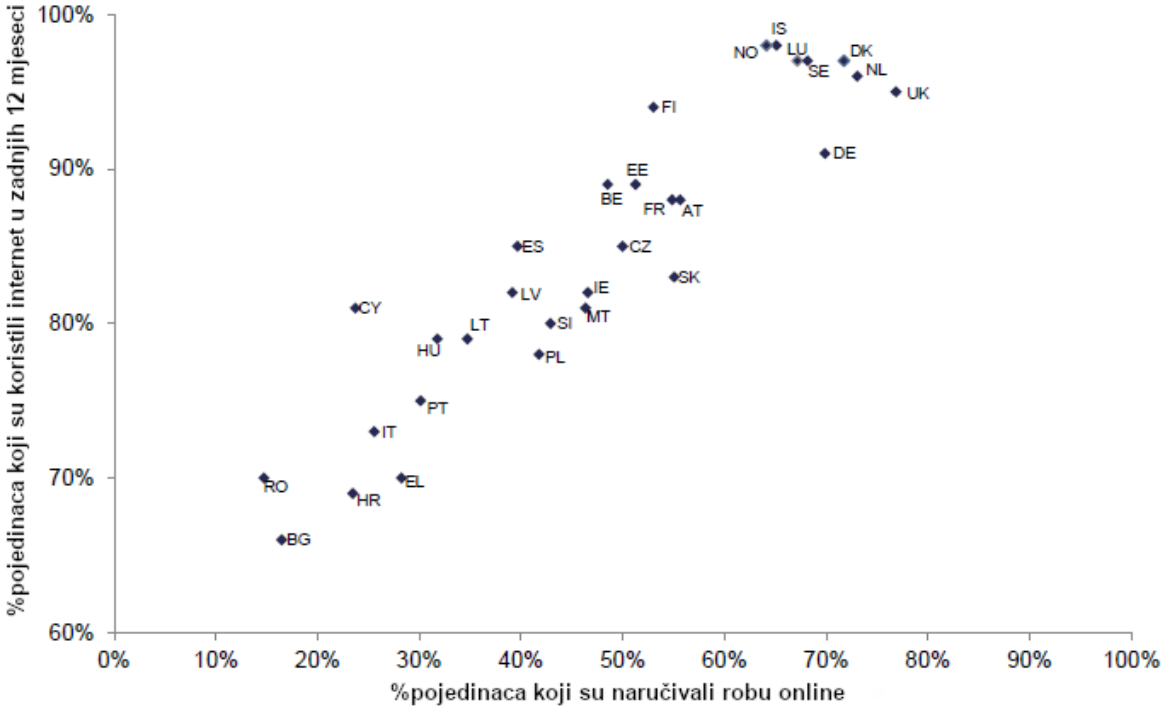

Slika 13. Povezanost između korištenja Interneta i naručivanja robe online [51]

Online kupci najčešće kupuju proizvode iz Kine, zatim iza nje slijede Velika Britanija, Njemačka i SAD. Republika Hrvatska također slijedi trend ostalih europskih zemalja. Tako je čak više od 50% online kupovine iz Kine, zatim iz Velike Britanije, SAD-a i Njemačke što se može vidjeti na slici 14.

Zadnja online kupovina internet kupaca u ...					
	naručena je od online trgovca u ...				
AT	DE (68%)	CN (13%)	UK (2%)	USA (2%)	NL (1%)
BE	FR (49%)	CN (10%)	NL (8%)	DE (7%)	UK (6%)
BG	CN (44%)	UK (17%)	DE (10%)	USA (6%)	RO (3%)
CY	UK (39%)	CN (22%)	EL (18%)	DE (5%)	USA (4%)
CZ	CN (67%)	UK (7%)	DE (7%)	USA (6%)	PL (1%)
DE	CN (41%)	UK (15%)	AT (5%)	USA (5%)	ES (4%)
DK	DE (22%)	CN (20%)	UK (15%)	SE (11%)	USA (8%)
EE	CN (49%)	UK (14%)	DE (9%)	USA (8%)	FI (2%)
EL	CN (31%)	UK (21%)	DE (8%)	USA (7%)	ES (5%)
ES	CN (40%)	UK (16%)	DE (12%)	USA (6%)	FR (5%)
FI	CN (28%)	DE (20%)	UK (12%)	SE (10%)	USA (10%)
FR	CN (30%)	DE (15%)	UK (14%)	USA (6%)	IT (5%)
HR	CN (53%)	UK (12%)	USA (7%)	DE (6%)	ES (2%)
HU	CN (55%)	UK (8%)	DE (7%)	USA (5%)	SK (3%)
IE	UK (58%)	CN (16%)	USA (6%)	DE (4%)	IT (2%)
IS	CN (32%)	UK (17%)	USA (11%)	LV (5%)	DE (4%)
IT	CN (29%)	UK (20%)	DE (19%)	USA (7%)	ES (4%)
LT	CN (55%)	UK (17%)	DE (9%)	USA (4%)	PL (3%)
LU	DE (71%)	FR (12%)	UK (5%)	CN (4%)	BE (3%)
LV	CN (46%)	UK (16%)	DE (6%)	USA (5%)	EE (3%)
MT	UK (68%)	CN (18%)	DE (5%)	USA (3%)	IE (1%)
NL	CN (36%)	DE (18%)	UK (10%)	BE (5%)	USA (4%)
NO	CN (29%)	UK (17%)	USA (15%)	SE (10%)	DE (7%)
PL	CN (46%)	DE (12%)	UK (8%)	USA (6%)	CZ (2%)
PT	CN (31%)	ES (20%)	UK (17%)	DE (7%)	FR (6%)
RO	CN (35%)	UK (17%)	DE (9%)	USA (7%)	PL (4%)
SE	CN (24%)	DE (21%)	UK (17%)	USA (15%)	DK (4%)
SI	CN (35%)	DE (22%)	UK (15%)	AT (4%)	USA (3%)
SK	CN (41%)	CZ (26%)	UK (8%)	DE (7%)	HU (2%)
UK	CN (34%)	USA (19%)	DE (5%)	IT (2%)	PL (2%)
	CN	UK	DE	susjedne zemlje	

Slika 14. Zemlje iz kojih je naručena roba Internetom [51]

2.4. Paketsko tržište Republike Hrvatske

Poštansko je tržište Republike Hrvatske dio poštanskog tržišta EU. Određeni trendovi u Republici Hrvatskoj prate trendove EU. Napredak tehnologije širokopojasnog pristupa doveo je do promjene ponašanja korisnika. Dolazi do supstitucije poštanskih usluga elektroničkim odnosno elektroničke komunikacije sve više zamjenjuju korištenje tradicionalne pisane oblike komunikacija što je jedan od razloga trenda pada broja pismovnih pošiljaka u proteklom razdoblju. Istovremeno broj paketskih pošiljaka raste zbog povećanja elektroničke trgovine u kojoj su paketske pošiljke nezaobilazna karika u dostavnom lancu [55, 37]. Otvoreno tržište utječe na povećanje broja međunarodnih pošiljaka zbog prekogranične dostave pošiljaka u sklopu e-trgovine [55]. Ovo nije slučaj samo u Republici Hrvatskoj već u cijelom svijetu što je vidljivo iz podataka prikazanih u prethodnim poglavljima o paketskom tržištu svijeta i Europe. Na poštanskom tržištu Republike Hrvatske u unutarnjem prometu ostvareno je 92% usluga, dok se na međunarodni promet odnosi 8% usluga, a ukupni prihodi rastu od

obavljanja poštanskih usluga. Najveći utjecaj na povećanje prihoda ima rast broja paketskih pošiljaka [55] prikazan na slici 15. Na rast paketskih usluga najveći utjecaj ima rast ekspresnih paketskih pošiljaka koje su najvećim dijelom povezane s e-trgovinom [56]. Udio paketskih pošiljaka na ukupnom tržištu je 7,7% [57].

Sektor poštanskih usluga ima svoju ulogu u gospodarstvu obzirom na njegov udio u BDP-u države. Kako rast broja paketskih pošiljaka pozitivno utječe na ukupne poslovne rezultate i produktivnost davatelja poštanskih usluga, tako istovremeno rast poštanskih usluga pozitivno utječe na gospodarstvo [58]. Udio prihoda poštanskih usluga u BDP-u Republike Hrvatske od 2013. do 2019. može se vidjeti u tablici 1.

Tablica 1. Udio prihoda od poštanskih usluga u BDP-u Republike Hrvatske u razdoblju od 2013.-2019. godine. Autor uredio prema [55, 59, 60, 61]

Godina	2013.	2014.	2015.	2016.	2017.	2018.	2019.
Udio u BDP-u (%)	0,43	0,43	0,42	0,43	0,42	0,43	0,45

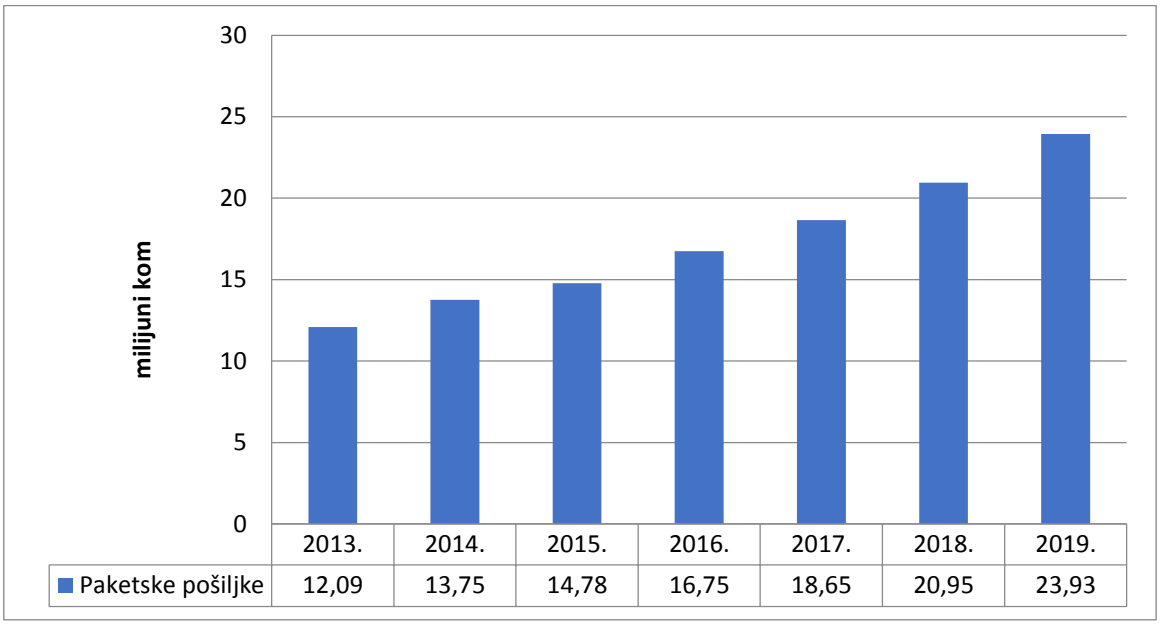

Slika 15. Broj paketskih pošiljaka u RH [57, 53, 60]

Godišnja stopa rasta broja paketskih pošiljaka 2014. u odnosu na 2013. bila je 13,73%, 2015. u odnosu na 2014. iznosila je 7,49%, 2016. u odnosu na 2015. 13,33%, 2017. u odnosu na 2016. 11,34%, 2018. u odnosu na 2017. 12,33% te 2019. u odnosu na 2018. 14,22%. Paketsko tržište Republike Hrvatske od 2013. do 2019. poraslo je za 97,93%, dok je prosječna godišnja stopa rasta 12,05% (slika 15.).

Trendovi u Republici Hrvatskoj u skladu su sa trendovima na tržištu EU vezano za udjele paketskih pošiljaka u unutarnjem i međunarodnom prometu gdje je je puno veći udio paketskih pošiljaka u unutarnjem prometu. Udio paketskih pošiljaka u unutarnjem i međunarodnom prometu prikazan je na slici 16. Vidljiv je trend povećanja paketskih pošiljaka što je povezano s povećanjem prekogranične online kupovine kako u svijetu tako i u zemljama EU među kojima je i Republika Hrvatska.

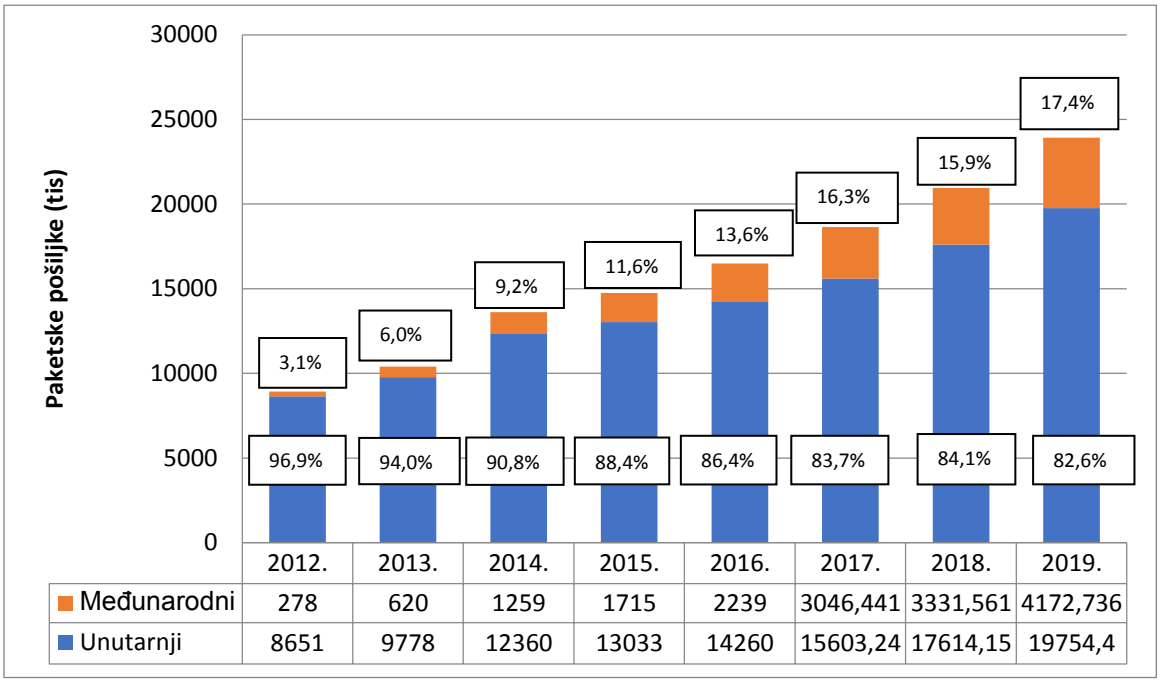

Slika 16. Udio paketskih pošiljaka u unutarnjem i međunarodnom prometu. Autor uredio prema [62,63]

Najveći utjecaj na rast ukupnih usluga u 2019. godini imala je potražnja za paketskim uslugama koje su korištene za fizičku dostavu kupljene robe putem e-trgovine [60]. Prema dostupnim podacima HAKOMA u prva tri tromjesečja 2020. zabilježen je pad ukupnog broja poštanskih usluga u odnosu na prva tri tromjesječja 2019. Došlo je do pada pismovnih pošiljaka i tiskanica dok je s druge strane došlo do povećanja paketskih pošiljaka u ukupnom broju poštanskih usluga. Može se zaključiti da je pojava COVID-Sars2, zbog uvedenih mjera radi sprečavanja širenja zaraze, dovela do promjene u potražnji za pojedinim uslugama. Dakle, došlo je do povećanja potražnje za paketskim uslugama jer se za vrijeme uvedenih mjera povećao broj korisnika koji su kupovali robu putem Interneta, odnosno e-trgovinom [64, 65, 66].

3. ODREDNICE MODELA UTJECAJA ČIMBENIKA NA BROJ PAKETSKIH POŠILJAKA

U nastavku se definiraju odrednice modela utjecaja ekonomskih, tehničko-tehnoloških, poštanskih i demografskih čimbenika na broj paketskih pošiljaka.

3.1. Metodološka podloga za izradu regresijskih modela

3.1.1. Korelacijska analiza

Francis Galton pokrenuo je ideju o koeficijentu korelacije dok je Karl Pearson riješio problem temeljem obrasca za izračunavanje koeficijenta korelacije [67]. Korelacija predstavlja povezanost ili uzajamni odnos među pojavama čije se promjene opisuju matematičkim relacijama odnosno metodama statističke analize.

Statističke metode koje se koriste za analizu i utvrđivanje jačine veze između pojava i obilježja nazivaju se metode korelacije. Njihova je osnovna svrha da se dobiju saznanja o zakonitosti odnosno tendenciji promjena kod masovnih pojava, jačini povezanosti dviju ili više pojava te posljedicama koje takva kretanja izazivaju. U korelacijskoj analizi se [67]:

- utvrđuje da li uopće postoji veza između jedne ili više pojava ili njihovih obilježja,
- utvrđuje intenzitet promjena smjera i s tim u vezi opće karakteristike među pojavama,
- utvrđuje konkretni oblik veze među pojavama,
- utvrđuje jakost veze između dvije ili više pojava.

Korelacijska analiza se sastoji u primjeni postupaka kojima se utvrđuju pokazatelji jakosti statističke veze među pojavama. Kod korelacijske analize više numeričkih varijabli utvrđuju se različiti koeficijenti korelacije od kojih se najčešće izračunava *koeficijent jednostavne korelacije* za svaki par varijabli gdje se kovarijanca standardiziranih vrijednosti x i y zove *Pearsonov koeficijent linearne korelacije* [33].

Može se reći da je koeficijent korelacije standardizirana mjera jakosti statističke veze među pojavama predočenih dvjema kvantitativnim varijablama. Osim za mjerenje jakosti statističke veze koeficijent korelacije koristi se i za izbor varijabli u modelu te u postupcima ispitivanja kakvoće modela.

Kovarijanca predstavlja polaznu veličinu za mjerenje jakosti i smjera linearne statističke povezanosti dviju pojava. Kovarijanca dviju varijabli je konstanta kojom se predočuje zajednička varijacija dviju varijabli. Računa se kovarijanca zavisne varijable y i nezavisnih varijabli x_j te kovarijance parova nezavisnih varijabli. Kovarijance standardiziranih vrijednosti varijabli tvore elemente korelacijske matrice [33]. U regresijskoj analizi korelacijska matrica pruža uvid u linearnu povezanost varijabli (sadrži koeficijente linearne korelacije nultog reda odnosno *koeficijente jednostavne linearne korelacije* između svih parova varijabli uključenih u regresijski model) [36], te je sadržaja [33]:

$$R = \begin{bmatrix} 1 & r_{y1} & \dots & r_{yK} \\ r_{1y} & 1 & \dots & r_{1K} \\ r_{2y} & r_{21} & \dots & r_{2K} \\ . & . & \dots & . \\ r_{Ky} & r_{K1} & \dots & 1 \end{bmatrix} \quad (1)$$

Korelacijska matrica je simetrična. Ima jedinice na glavnoj dijagonali jer je koeficijent korelacije jedne varijable sa samom sobom uvijek jednak jedan. U prvom retku i prvom stupcu korelacijske matrice su koeficijenti jednostavne linearne korelacije zavisne varijable i svake nezavisne varijable. U preostalim recima odnosno stupcima su koeficijenti korelacije parova nezavisnih varijabli. Može se zaključiti da koeficijent korelacije u korelacijskoj matrici pruža brojčane informacije o smjeru i jakosti linearne veze *para varijabli.* Koeficijent korelacije poprima vrijednost iz zatvorenog intervala od minus do plus jedan ($-1 \leq r \leq 1$). Ako je vrijednost koeficijenta jednaka nuli, znači ne postoji linearna korelacija među pojavama, zatim ako je vrijednost plus jedan, linearna korelacija je potpuna i pozitivna smjera, a ako je vrijednost minus jedan, tada je također potpuna, ali negativnog smjera. Što je koeficijent po apsolutnoj vrijednosti bliže jedinici, veza je uža [33]. Kod pozitivne veze (smjer odnosno predznak koeficijenta je plus) porastom vrijednosti jedne varijable raste i vrijednost druge varijable i obratno s opadanjem vrijednosti jedne varijable opada i vrijednost druge, dok kod negativne veze s porastom vrijednosti jedne varijable pada vrijednost druge varijable i obratno s opadanjem jedne varijable raste vrijednost druge varijable. Na sljedećoj slici prikazane su vrijednosti koeficijenta korelacije i pripadajuća tumačenja [68].

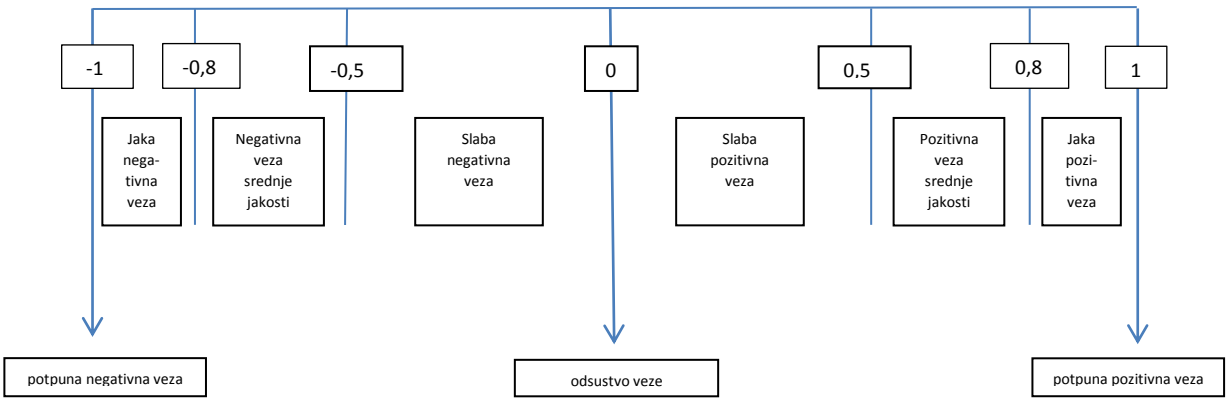

Slika 17. Prikaz tumačenja vrijednosti koeficijenta korelacije [68]

Iako je riječ o varijablama x_i kao nezavisnim i y_i kao zavisnom primjenom korelacijske analize se utvrđuje postojanje povezanosti među odabranim varijablama neovisno o uzročno-posljedičnoj vezi zbog čega se kod korelacije sve varijable promatraju kao nezavisne. Intenzitet i smjer povezanosti se utvrđuje na temelju koeficijenta korelacije. Kod regresijske analize bitno je odrediti koja varijabla će biti zavisna, a koja nezavisna.

Pearsonov koeficijent korelacije se najčešće izračunava uporabom slijedeće jednadžbe [33]:

$$r = \frac{\sum_{i=1}^{n} x_i y_i - n\overline{x}\overline{y}}{\sqrt{\left(\sum_{i=1}^{n} x_i^2 - n\bar{x}^2\right)\left(\sum_{i=1}^{n} y_i^2 - n\bar{y}^2\right)}}, \qquad i = 1, 2, \ldots, n. \qquad (2)$$

Kod korelacijske analize osim matrice korelacije izrađuje se i dijagram rasipanja. To je grafički prikaz koji služi da se uoče odnosi između pojava koje se promatraju. Svaka točka u grafikonu predstavlja par vrijednosti nezavisne i zavisne varijable. Raspored točaka u grafičkom prikazu omogućuje da se uoči postoji li ili ne povezanost između pojava, zatim koji je oblik, smjer i jakost povezanosti između njih [68, 69]. Dijagram rasipanja također se koristi i za grafički prikaz korelacija između parova nezavisnih varijabli.

Da bi se mogla primijeniti linearna regresija za izradu modela, potrebno je imati linearne odnose između dvije varijable. Odnosi između zavisne i svih nezavisnih varijabli moraju biti linearni [70].

3.1.2. Regresijska analiza

Regresijskom analizom se ispituje ovisnost jedne zavisne varijable o jednoj ili više nezavisnih varijabli kako bi se utvrdio analitički izraz odnosno regresijski model koji služi u analitičke i prognostičke svrhe [68]. Regresijski modeli mogu imati različite oblike, ali njihov opći oblik je:

$$Y = f(X_1, X_2, \ldots, X_j, \ldots, X_k) + e \tag{3}$$

uz pretpostavku da je očekivana vrijednost reziduala jednaka nuli te rezidualne vrijednosti slijede normalnu distribuciju dobiva se model oblika:

$$\hat{Y} = f(X1, X2, \ldots, Xj, \ldots, Xk) \tag{4}$$

pri čemu je:

Y - zavisna varijabla

$f(X_1, X_2, \ldots, X_j, \ldots, X_k)$ - funkcionalni dio modela koji je različit i ovisi o danom slučaju primjene

$X_1, X_2, \ldots, X_j, \ldots, X_k$ - nezavisne varijable

e - slučajna varijabla koja izražava nepoznata odstupanja od funkcionalnog odnosa.

Zavisna varijabla je varijabla čije se varijacije objašnjavaju pomoću drugih varijabli dok su nezavisne varijable one kojima se objašnjava varijacija zavisne varijable.

3.1.2.1. Modeli regresijske analize

Modeli regresijske analize dijele se na *nesimultane* (sastoje od jedne jednadžbe) i *simultane* (sastoje od dvije jednadžbe ili više povezanih jednadžbi).

Ukoliko se u modelu nalazi jedna zavisna i jedna nezavisna varijabla, tada se taj model naziva *model jednostavne regresije*, a ako model ima jednu zavisnu i dvije ili više nezavisnih varijabli, tada se taj model naziva *model višestruke (multiple) regresije.*

Model također može biti *linearan ili nelinearan*. Korištenjem odgovarajuće transformacije nelinearni modeli mogu se transformirati u opće linearne modele s obzirom da se linearni modeli lakše analiziraju, a sam postupak se naziva lineariziranje [33].

Jednostavna linearna regresija

Jednostavnom linearnom regresijom izražen je odnos između dvije pojave odnosno između jedne zavisne i jedne nezavisne varijable. Primjenjuje se za opisivanje pojava koje su u linearnom statističkom odnosu što bi značilo da jediničnom povećanju vrijednosti nezavisne varijable odgovara približno ista linearna promjena vrijednosti zavisne varijable.

Model jednostavne linearne regresije ima sljedeći opći oblik:

$$Y_i = \alpha + \beta X_i + e_i \tag{5}$$

pri čemu je:

Y_i - zavisna varijabla

α i β - nepoznati parametri

X_i - nezavisna varijabla

e_i - slučajna varijabla koja izražava nepoznata odstupanja od funkcionalnog odnosa.

Slučajna varijabla se naziva pogreškom relacije. Pretpostavka kod jednostavne linearne regresije je da su bilo koje dvije slučajne varijable međusobno nezavisne, a time i nekorelirane zatim da su normalno distribuirane sa sredinom nula i jednakom varijancom [68].

Višestruka linearna regresija

Ako se je veza između Y i (X_1, X_2, …, X_k) linearna, tada se može govoriti o modelu višestruke linearne regresije [34]. Oblik općeg višestrukog linearnog regresijskog modela je [33]:

$$Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \ldots + \beta_j X_j + \ldots + \beta_k X_k + e_i \tag{6}$$

pri čemu je:

Y_i- zavisna varijabla

α i β - nepoznati parametri

X_i - nezavisne varijable

e_i - slučajna varijabla koja izražava nepoznata odstupanja od funkcionalnog odnosa.

Regresijska analiza ima nekoliko ciljeva [68]:

- procjena nepoznatih parametara na osnovi raspoloživog uzorka veličine n, tj. na osnovi n empirijskih vrijednosti varijabli,
- analiza utjecaja svake pojedine nezavisne varijable na varijacije zavisne varijable,
- određivanje procjene parametara jednim brojem, analiza i protumačenje intervalne procjene parametara te provedba postupaka testa statističkih hipoteza,
- ispitivanje ispunjenosti svih polaznih pretpostavki u analizi modela.

Prilikom analize i razvoja modela polazne pretpostavke višestruke linearne regresije moraju biti ispunjene. Polazne pretpostavke su da je [71]:

- veza između zavisne varijable i odabranog skupa nezavisnih varijabli linearna (u parametrima),
- očekivana vrijednost grešaka relacije jednaka je nuli,
- varijanca grešaka relacije je konstantna,
- slučajne varijable su nekorelirane,
- greške relacije su normalno distribuirane slučajne varijable s očekivanom vrijednosti nula i varijancom σ^2,
- nezavisne varijable su nekorelirane i niti jedna nije konstanta, tj. ne postoji egzaktna linearna povezanost između dviju ili više nezavisnih varijabli.

Modelom višestruke linearne regresije analizira se ovisnost jedne zavisne varijable o većem broju nezavisnih varijabli. Kod analize modela najprije se moraju odabrati varijable koje će se uključiti u model te zatim odabrati oblik modela [68]. Nakon toga slijede procjene parametara, varijance, standardne devijacije te testiranje hipoteza i ispitivanje kakvoće dobivenih rezultata [33].

Kod procjene parametara brojem, procjene nepoznatih parametara označavaju se s $\hat{\alpha}$ i $\hat{\beta}_j$, j = 1, 2, …, K, procjene vrijednosti grešaka relacije $\hat{e}_i$ nazivaju se rezidualna ili neprotumačena odstupanja. Poželjno je da su rezidualna odstupanja što manja zato jer što su manje razlike

stvarnih vrijednosti zavisne varijable i regresijskih vrijednosti $\hat{Y}_i$ to je regresijski model reprezentativniji.

Konstantni član $\hat{\alpha}$ je vrijednost regresijske funkcije uzorka ako su vrijednosti K nezavisnih varijabli jednake nuli dok regresijski koeficijent $\hat{\beta}_j$ pokazuje za koliko se linearno u prosjeku mijenja vrijednost zavisne varijable ako se varijabla X_j poveća za jedan, uz uvjet da se ne mijenjaju vrijednosti preostalih nezavisnih varijabli.

Nezavisne procjene komponenti varijance prikazuju se u tablici analize varijance (tablica ANOVA).

Nakon što se napravi procjena parametara mora se prosuditi njihova kakvoća korištenjem testova (testiranje hipoteza o modelu). Za to se koriste dva testa. S*kupni test* govori o značajnosti regresije, tj. značajnosti svih parametara u modelu odnosno značajnosti prisutnosti svih nezavisnih varijabli u modelu. Test-veličina za *skupni test* je empirijski F-omjer, koji se nalazi i u tablici analize varijance:

$$F = \frac{\sum_{i=1}^{n}(\hat{y}_i - \bar{y})^2 / K}{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 / n-(K+1)} \tag{7}$$

Nulta hipoteza (H_0) koja se odnosi na test o značajnosti regresije, odnosno skupni test, sadrži tvrdnju koja kaže da nijedna nezavisna varijabla nije signifikantna u modelu odnosno da su svi parametri uz nezavisne varijable u modelu jednaki nuli. Suprotno tvrdi alternativna hipoteza (H_1) koja kaže da postoji barem jedna od K nezavisnih varijabli koja je signifikantna za objašnjenje varijabilnosti zavisne varijable, odnosno da postoji barem jedan parametar β_j od njih K različit od nule.

Drugi test je *pojedinačni test* koji govori o značajnosti jednog parametra odnosno jedne nezavisne varijable u modelu. Ovaj test odnosi se na testiranje hipoteze o značajnosti parametra β_j (nezavisne varijable x_j). Kod ovog testa nulta hipoteza tvrdi da je parametar β_j jednak nuli, odnosno da je varijabla x_j u modelu suvišna. Suprotno tvrdi alternativna hipoteza (H_1). Test-veličina za *pojedinačni test* je empirijski t-omjer:

$$t = \frac{\hat{\beta}_j - 0}{\sigma_{\hat{\beta}_j}} \tag{8}$$

Ukoliko je empirijska razina značajnosti (p-vrijednost) kod skupnog i pojedinačnog testa manja od razine značajnosti (signifikantnosti) α, koja je određena u istraživanju, nulta se hipoteza ne prihvaća već se prihvaća hipoteza H_1 [71]. Nulta se hipoteza prihvaća ako je p-vrijednost veća od α [33].

Koeficijent determinacije (R^2) je opći pokazatelj kakvoće regresijskog modela. On je najčešće korištena mjera za reprezentativnosti regresijskog modela.

Izraz za izračun koeficijenta determinacije je:

$$R^2 = \frac{\sum_{i=1}^{n}(\hat{y}_i - \bar{y})^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{9}$$

Vrijednost koeficijenta nalazi se između nule i jedan ($0 \leq R^2 \leq 1$). On pokazuje koliko je primijenjenim modelom protumačeno varijacija (odstupanja), a model je reprezentativniji što mu je vrijednost bliža jedinici [33].

Postoji povezanost između koeficijenta determinacije i koeficijenta jednostavne linearne korelacije (Tablica 2.). Ukoliko je npr. vrijednost koeficijenta determinacije 0,75, znači da je protumačeno 75% odstupanja, te se odnosi na koeficijent jednostavne linearne korelacije od $\pm 0{,}87$, što upućuje na jaku pozitivno/negativnu vezu [68].

Tablica 2. Odnos koeficijenta determinacije i koeficijenta jednostavne linearne korelacije [68]

$\mathbf{R^2}$	$\pm \boldsymbol{r}$	**Interpretacija**
0	0	Odsutnost veze
0 – 0,25	0 – ($\pm$0,5)	Slaba pozitivna/negativna veza
0,25 – 0,64	($\pm$0,5) – ($\pm$0,8)	Pozitivna/negativna veza srednje jakosti
0,64 - 1	($\pm$0,8) – ($\pm$1)	Jaka pozitivna/negativna veza
1	$\pm$1	Potpuna pozitivna/negativna veza

Nedostatak koeficijenta determinacije je da se njegova vrijednost povećava s brojem nezavisnih varijabli u modelu, odnosno uključivanje dodatne nezavisne varijable u pravilu povećava njegovu vrijednost. Kako je osnovna ideja regresijske analize da se sa što manje nezavisnih varijabli objasni što više varijacija zavisne varijable umjesto koeficijenta determinacije (R^2) promatra se korigirani koeficijent determinacije ($\bar{R}^2$) koji korigira R^2 za broj nezavisnih varijabli u modelu i time ograničava uključivanje u model nezavisne varijable koje zanemarivo ili nedovoljno smanjuju rezidualni zbroj kvadrata. Prema definiciji je $\bar{R}^2 \leq R^2$. Korigirani koeficijent determinacije predstavlja bolji kriterij izbora modela višestruke linearne regresije od koeficijenta determinacije. Ukoliko se uspoređuje više regresijskih modela s jednakim zavisnim varijablama, model s većom vrijednosti $\bar{R}^2$ smatra se boljim [71].

Regresijski modeli s procijenjenim parametrima koriste se za predviđanje. Na kraju regresijske analize izračunava se prognostička vrijednost i prognostički interval. U praksi se najčešće prognostički intervali izračunavaju za pouzdanost procjene 0,90, 0,95 i 0,99 [71].

Statističke metode za izbor varijabli u model

Za izbor varijabli u model koriste se različite statističke metode. Neke od metoda su [33, 70, 72]:

- metoda postupnog proširenja modela (engl. Forward selection procedure),
- metoda postupnog smanjenja dimenzije modela (engl. Backward selection procedure),
- stupanjska regresija (engl. Stepwise regression).

Kod metode postupnog proširenja modela (Forward) postupno se uvode nezavisne varijable tako da se najprije postavlja model s jednom nezavisnom varijablom te se zatim uvodi sljedeća koja ima sa zavisnom varijablom najveći koeficijent linearne korelacije bez obzira bio on pozitivan ili negativan. Značajnost varijable ispituje se standardnim F-testom. Razina signifikantnosti često se kod ove metode fiksira na 0,05.

Metoda postupnog smanjenja dimenzije modela (Backward) polazi od modela maksimalne dimenzije. U model su uključene sve nezavisne varijable, gdje se u svakom koraku testira značajnost prisutnosti određene nezavisne varijable i varijabla koja nije signifikantna

isključuje iz modela. Ovdje se postavljaju kriteriji za izlazak varijabli iz modela. Maksimalna signifikantnost za isključenje iznosi 0,10.

Stupanjska regresija (Stepwise) predstavlja kombinaciju metode postupnog proširenja modela i metode postupnog smanjenja dimenzije modela. Ovdje se značajnost svake varijable ispituje u svakom koraku, a postupak završava kada nijedna nova varijabla ne udovoljava kriteriju uključivanja u model i kada se niti jedna varijabla ne može isključiti iz modela prema kriteriju isključivanja. Zbog postojanja interkorelacija, varijable čija je prisutnost bila signifikantna u prijašnjem koraku ne mora biti signifikantna u kasnijem. Kako bi se spriječilo da neka varijabla čas bude uključena u model, a čas isključena signifikantnost za ulazak se fiksira na manjoj razini od signifikantnosti za izlazak.

3.1.2.2. Mogući problemi u regresijskoj analizi

Ovdje će biti opisana dva potencijalna problema u regresijskoj analizi. Regresijskom dijagnostikom ispituje se kakvoća modela s obzirom na njegov oblik i pretpostavljena svojstva varijabli [33].

Regresijski model se može primijeniti u analitičke i prognostičke svrhe tek kada su ispunjene polazne pretpostavke o regresijskom modelu.

Multikolinearnost

Problem multikolinearnosti nezavisnih varijabli se javlja kada nisu ispunjene polazne pretpostavke u linearnom regresijskom modelu [68]. Pretpostavlja se da nezavisne varijable nisu korelirane i da niti jedna varijabla nije konstanta. Ukoliko dođe do narušavanja ovih pretpostavki, nastaje problem multikolinearnosti. Multikolinearnost najčešće nastaje zbog premalog broja dostupnih podatka s obzirom na broj nezavisnih varijabli u modelu [71].

Ukoliko postoji uska linearna korelacija nezavisnih varijabli ili njihova približna linearna kombinacija, može se govoriti o multikolinearnosti. Može se reći da postoji ovaj problem kada je vrijednost koeficijenta multiple determinacije između 0,7 i 0,9 te velika vrijednost koeficijenta korelacije [33].

Postoje razne metode za otkrivanje problema multikolinearnosti, a jedna od njih je i analiza korelacijske matrice [71]. Kod analize korelacijske matrice na multikolinearnost ukazuju velike vrijednosti koeficijenta korelacije nultog reda između nezavisnih varijabli.

Neki od pokazatelja kojima se može uočiti multikolinearnost su [33, 71, 73]:

- faktor inflacije varijance,
- tolerance.

Problem multikolinearnosti postoji ukoliko je $R_j^2 > 0{,}8$, odnosno faktor inflacije varijance (VIF, engl. Variance Inflation Factor) $VIF_j > 5$, što je ekvivalentno da je tolerance (TOL, engl. Tolerance) $TOL_j < 0{,}2$. Što je TOL_j bliži nuli, to je veći stupanj kolinearnosti te varijable s ostalim nezavisnim varijablama. S druge strane što je TOL_j bliži 1, to je veći dokaz da Xj nije kolinearan s ostalim nezavisnim varijablama.

Ako se uoči problem multikolinearnosti u regresijskom modelu, tada se on može rješavati na različite načine primjenom raznih metoda, a neke od njih su:

- korištenje većeg broja podataka,
- isključivanje jedne varijable ili više nezavisnih varijabli.

Heteroskedastičnost

Za pogreške relacije (e_i) pretpostavlja se da imaju jednaku (konstantnu) varijancu odnosno da su homoskedastične. Kada pogreške relacije nemaju istu varijancu tada se govori o problemu promjenljivosti varijance odnosno heteroskedastičnosti. Problem heteroskedastičnosti se očituje u sustavnom povećavanju ili smanjivanju disperzije vrijednosti zavisne varijable oko regresije [33].

Heteroskedastičnost se može otkriti na dva načina i to analizom grafičkih prikaza i statističkim testovima. Od grafičkih prikaza koriste se razni oblici dijagrama rasipanja [64]. Najjednostavniji i uobičajeni statistički test koji se koristi za otkrivanje heteroskedastičnosti je test značajnosti Spearmanova koeficijenta korelacije ranga [33].

3.2. Analiza čimbenika koji utječu na broj paketskih pošiljaka u poštanskom prometu

Prema provedenim istraživanjima od strane UPU poštanski, ekonomski, društveni i tehnološki čimbenici utječu na tržište poštanskih usluga te na poslovanje davatelja poštanskih usluga. Napravljena je selekcija čimbenika (prilog 1.) na ekonomske, tehnološke, poštanske i društvene koji imaju utjecaj na budući razvoj i trendove na tržištu poštanskih usluga [58]. U [17] također je napravljena selekcija čimbenika (prilog 2.) u četiri skupine prema UPU (ekonomske, socijalno-kulturološke, poštanske i tehnološke) uz pretpostavku, temeljem izvještaja UPU, mogućeg utjecaja na poštanski promet. Socio-ekonomski čimbenici također su istraženi u [19]. U istraživanju njihovog utjecaja na tokove paketskih pošiljaka podijeljeni su u četiri grupe čimbenika koje se odnose na populaciju, kućanstvo, industriju i dohodak (prilog 3.). U [14] također je dan pregled ranije korištenih čimbenika za koje je dokazano uporabom Stepwise regresijske analize da utječu na potražnju paketskih pošiljaka (prilog 4.).

Ekonomska aktivnost u gospodarstvu konvencionalno je mjerena pokazateljem ukupnog proizvoda gospodarstva gdje se kao ekvivalenti nerijetko koriste bruto domaći proizvod, bruto domaći proizvod po stanovniku te bruto nacionalni dohodak po stanovniku [74]. Uz ove ekonomske pokazatelje koristi se i broj stanovnika, izvoz i uvoz robe i usluga, industrijska proizvodnja, noćenja turista, cijene, neto plaća, broj zaposlenih, nezaposlenost [75, 76, 77]. Rast BDP-a nije jedini relevantni čimbenik koji utječe na količine poštanskih usluga, stoga nije moguće predviđati količine poštanskih pošiljaka isključivo promatranjem kretanja BDP-a [58].

U [13] regresijska analiza pokazala je da BDP po glavi stanovnika ima statistički značajan pozitivan utjecaj na broj poštanskih pošiljaka po stanovniku. U [78] je istaknuto da je broj poštanskih pošiljaka po kućanstvu ili po stanovniku veći u zemljama s većom ekonomskom aktivnosti mjereno BDP-om.

Prosječne isplaćene neto plaće ekvivalent su životnog standarda stanovništva gdje povećanje prosječne neto plaće dovodi do porasta bogatstva stanovništva [79], zbog čega se može pretpostaviti da se porast prosječne plaće pozitivno odražava na obujam poštanskog prometa. Dohodak stanovništva predstavlja širi pojam od plaća budući da uključuje i ostala primanja pojedinca u koja spadaju i dohoci od samostalnog rada, dividende i sl. Pretpostavlja se da će osobe s većim dohocima ostvarivati veću potrošnju.

Broj zaposlenih u Republici Hrvatskoj obuhvaća zaposlene u pravnim osobama, zaposlene u obrtu i slobodnim profesijama te osiguranike poljoprivrednike dok se broj nezaposlenih odnosi na broj nezaposlenih koji je preuzet od Hrvatskog zavoda za zapošljavanje budući da u Republici Hrvatskoj on vodi službenu statistiku o kretanjima na tržištu rada.

Istraživanje [19] između socio-ekonomskih čimbenika i tokova paketskih pošiljaka koji se odnose na slanje i primitak paketskih pošiljaka u poštanskom sustavu promatranog područja pokazalo je da su veličina populacije, broj veleprodajnih i maloprodajnih ustanova, broj zaposlenih u veleprodaji i maloprodaji te broj kućanstava sa šest i više soba (čimbenik vezan uz dohodak) u statistički značajnoj pozitivnoj korelaciji s primitkom poštanskih pošiljaka dok su broj proizvodnih ustanova, broj zaposlenih u proizvodnji, broj veleprodajnih i maloprodajnih ustanova, broj zaposlenih u veleprodaji i maloprodaji, fiskalno opterećenje (čimbenik vezan uz dohodak) u statistički značajnoj pozitivnoj korelaciji sa slanjem paketskih pošiljaka iz promatranog područja. Istraživanje je pokazalo da sve četiri grupe socio-ekonomska čimbenika (vezanih za populaciju, kućanstvo, industriju i dohodak) imaju utjecaj na primitak paketskih pošiljaka dok samo industrijski pokazatelji utječu na slanje paketskih pošiljaka s nekog područja.

Investicije predstavljaju ulaganja od kojih se očekuje povrat u budućem razdoblju. Prema [80] investicije u dugotrajnu imovinu obuhvaćaju investicije u građevinske objekte, prostore, postrojenja i opremu, transportnu imovinu, intelektualnu imovinu i dr.

Ulaganja u imovinu su bitna i za budući razvoj hrvatskog poštanskog tržišta budući da omogućuju brži i sigurniji prijenos paketskih pošiljaka, praćenje statusa u svakom trenutku, kvalitetnije usluživanje, smanjenje emisije ispušnih plinova, smanjenje potrošnje energije, učinkovitije korištenje prijevoznih jedinica i slično, a što stvara preduvjete za ostvarenje održivog i ekološki prihvatljivog rasta i razvoja poštanskog sektora [58].

Istraživanja su pokazala korelaciju između poštanskog prometa i BDP-a kao pokazatelja gospodarskih aktivnosti s obzirom da većina poštanskog prometa nastaje od poslovnih korisnika [15, 81].

UPU je provela korelacijsku i regresijsku analizu na području SAD-a, Europe, Azije i Afrike gdje je utvrđeno da su BDP i trgovina dvije glavne ekonomske varijable koje su povezane s međunarodnim paketskim pošiljkama. Također postoji i korelacija između prekograničnog poštanskog i paketskog prometa s međunarodnim izvozom. Istraživanje je pokazalo da i Internet ima utjecaj na količinu paketskih pošiljaka. Kupovina na daljinu imala je utjecaj na

povećanje broja paketskih pošiljaka prema i iz kućanstava. U ovom istraživanju također je utvrđeno da u industrijaliziranim zemljama kućanstva sa širokopojasnim pristupom Internetu pošalju i prime oko četiri puta više paketskih pošiljaka od kućanstava bez pristupa Internetu. Ti odnosi odražavaju i korelaciju između prihoda i pristupa Internetu. Utvrđena je jaka veza između intenziteta internetske kupovine i razine prihoda [14]. U [18] za prognoziranje broja paketskih pošiljaka kao ulazne varijable također su korišteni čimbenici: broj stanovnika i trgovina putem Interneta.

U [82] istraživanje je pokazalo slabu korelaciju između broja poslanih pisama (D+1) i cijene pismovne pošiljke za rok uručenja (D+1) te nepostojanje korelacije između svih poslanih pismovnih pošiljaka (D+1 i D+2) i prosječne cijene pismovne pošiljke.

Kako je Republika Hrvatska turistička zemlja čija je ekonomija u velikoj mjeri bazirana na turizmu analiziran je broj dolazaka turista i broj noćenja turista kao uobičajene mjere turističke potražnje [83]. Prihodi od dolazaka stranih turista u Hrvatsku, kao turističkoj zemlji, u jakoj su pozitivnoj vezi s noćenjem turista, a što dovodi do porasta izvoza. Istraživanje turističke potrošnje Hrvata u inozemstvu je pokazalo srednje jaku pozitivnu vezu s hrvatskim izvozom. Također je utvrđena i srednje jaka pozitivna veza između BDP i izvoza [84]. Budući da veći izvoz doprinosi porastu životnog standarda domicilnog stanovništva može se pretpostaviti postojanje pozitivne povezanosti između broja dolazaka, te broja noćenja turista s potražnjom za uslugama u koje spadaju i poštanske usluge budući da potrošnja nerezidenata predstavlja izvoznu komponentu domicilnog gospodarstva.

U [85] istraživanje je pokazalo postojanje pozitivne i statistički značajne korelacije između broja poštanskih ureda i ekonomskog razvoja.

Za prognoziranje broja paketskih pošiljaka kao ulazne varijable korištene su minute razgovora unutar, iz i prema mobilnim mrežama i broj poslanih SMS poruka. Istraživanje je pokazalo postojanje relativno malog pozitivnog utjecaja mobilnih komunikacija na poštanski promet [15].

Prema [16] za prognoziranje broja poštanskih pošiljaka, radi optimalnog upravljanja ljudskim resursima u dostavnim poštanskim uredima, kao ulazne varijable za istraživanje također su korišteni bruto domaći proizvod, Internet korisnici, broj kućanstava te broj dostavnih poštanski ureda i prostorna pokrivenost poštanskih ureda.

Inozemno poslovanje se odvija preko uvoza i izvoza. Zbog fizičke distance između poslovnih partnera postoji potreba za korištenjem poštanskih usluga. Istraživanje je pokazalo da postoji korelacija između broja prekograničnih paketskih pošiljaka i međunarodnog izvoza [14].

Prema UPU-u broj međunarodnih praćenih poštanskih pošiljaka, koje se odnose na e-trgovinu, u poštanskim mrežama u 2013. godini iznosio je 397 milijuna, u 2014. godini iznosio je 460 milijuna što odgovara godišnjem rastu od 15,9%. U 2015. godini taj broj iznosio je 568 milijuna međunarodnih poštanskih pošiljaka što odgovara godišnjem rastu od 23,3% [86].

Istraživanje je pokazalo da postoji jaka pozitivna korelacija između razvoja telekomunikacija i BDP-a po stanovniku [87]. U [88] također je utvrđeno da postoji značajna pozitivna veza između razvoja telekomunikacijske infrastrukture i ekonomskog rasta.
Istraživanja su pokazala da starija populacija (stariji od 65) više gleda televiziju te da oglašavanje za kupnju više utječe na njih [89, 90]. Za komunikaciju starije osobe uglavnom koriste tehnologiju s kojom su odrasli, odnosno nepokretnu telefonsku mrežu [91, 92].

Istraživanja u SAD-u i Europi ukazuju da će broj potrošača koji koriste pametne telefone za kupovinu rasti [93]. Tako je na globalnoj razini u 2012. godini 210 milijuna korisnika kupilo robu na malo putem mobilnog uređaja. Ovaj broj je rastao tijekom godina i u 2017. dosegao brojku od 961 milijun korisnika [94]. Broj korisnika mobilnih uređaja u svijetu se povećava. Tako je u 2015. godini korisnika mobilnih telefona u svijetu bilo 4,15 milijardi, a u 2018. godini 4,57 milijardi [95].

U [14] je izrađen regresijski model kako bi se ispitala potražnja za paketskim uslugama, a koji je sadržavao varijable: prosječna cijena, broj stanovnika, broj kućanstava i broj korisnika Interneta.

Vrijednost prodane industrijske proizvodnje prema djelatnosti proizvoda odnosi se i na prerađivačku industriju koja čini razmjerno velik dio ukupne svjetske proizvodnje dobara i usluga, a neke od najvažnijih grana prerađivačke industrije su: proizvodnja hrane i pića, računala, odjeće, automobila i zrakoplova, kemijskih proizvoda, metala, naftnih prerađevina i drugo [96]. Stoga je za očekivati da će se koristiti paketski promet kako bi se proizvodi određenih grana prerađivačke industrije dostavili do krajnjih potrošača. Putem Interneta u 2016. najviše se kupovala sportska odjeća i oprema, kućne potrepštine, elektronička oprema te nešto manje knjige, živežne namirnice, lijekovi itd. [97] gdje se za dostavu ovakve vrste robe uglavnom koriste paketske pošiljke.

Temeljem prethodno navedenog prikazan je pregled odabranih čimbenika koji će se istražiti u ovom doktorskom radu, te upotrebom forward regresijskog postupka odabrati čimbenici koji ostvaruju značajan utjecaj na kretanje broja paketskih pošiljaka. Prema dosadašnjim istraživanjima najčešći čimbenici, koji se koriste za procjenu broja paketskih pošiljaka, prikazani su u tablici 3.

Tablica 3. Pregled čimbenika koji se analiziraju

Ekonomski čimbenici	**Tehničko-tehnološki čimbenici**	**Poštanski čimbenici**	**Demografski čimbenici**
Bruto domaći proizvod po stanovniku	Broj telefonskih linija nepokretne mreže	Broj pristupnih mjesta	Procjena ukupnog broja stanovnika
Bruto nacionalni dohodak po stanovniku	Korisnici pokretne mreže	Prostorna pokrivenost pristupnih mjesta	Gustoća stanovništva na 1 km^2
Bruto dodana vrijednost	Broj kućanstva s pristupom Internetu	Broj zaposlenih kod davatelja poštanskih i kurirskih usluga	
Prosječna neto plaća po zaposlenom	Ukupna ulaganja operatora elektroničkih komunikacija u RH	Broj poštanskih pretinaca	
Obiteljske naknade	Redoviti Internet kupci	Ukupan prihod od obavljanja poštanskih usluga	
Broj dolazaka turista		Prosječna pokrivenost stanovništva svakog pristupnog mjesta	
Broj noćenja turista			
Prosječni godišnji raspoloživi dohodak po kućanstvu			
Indeks cijena poštanskih usluga			
Bruto investicije			
Registrirane pravne osobe			
Obrt i slobodna zanimanja			
Uvoz			
Izvoz			
Prosječan broj zaposlenih			
Prosječan broj nezaposlenih			
Ukupna vrijednost prodanih industrijskih proizvoda			

Prikupljanje i analiza podataka o čimbenicima napravljena je, osim iz relevantnih dostupnih znanstvenih i stručnih izvora, iz redovitih statističkih publikacija:

- Državnog zavoda za statistiku Republike Hrvatske [98],
- Eurostata [99] ,
- HAKOM-a (Hrvatska regulatorna agencija za mrežne djelatnosti) [100],
- Hrvatske narodne banke [101],
- The World Bank [102] ,
- The Statistics Portal [103].

Podaci su prikupljeni kako bi se napravila baza podataka temeljem koje je napravljena analiza.

Kako je prije rečeno svi korišteni čimbenici prema pregledu dosadašnjih istraživanja uzeti su u obzir te su polazišni čimbenici prošireni dvama čimbenicima za koje se očekuje da bi mogli imati utjecaj na broj paketskih pošiljaka budući da je Republika Hrvatska turistički orjentirana zemlja, te su istraženi čimbenici:

- broj dolazaka turista,
- broj noćenja turista.

Analizirani su čimbenici s godišnjim podacima u dvanaestogodišnjem razdoblju od 2007. godine do 2018. godine. Nazivi istraženih čimbenika korištenih u dosadašnjim znanstvenim i stručnim istraživanjima usklađeni su s nazivima u redovitim statističkim publikacijama.

Dolazak turista jest broj osoba (turista) koje su se prijavile i ostvarile noćenje u objektu koji pruža uslugu smještaja. Zbog toga u slučaju promjene objekta u kojem boravi dolazi do njegova ponovnog registriranja i time do dvostrukosti u podacima. Prema tome, statistika evidentira broj dolazaka turista, a ne broj turista. Do 2016. podaci o turističkom prometu (broj dolazaka) prikupljali su se Mjesečnim izvještajem o dolascima i noćenjima turista. Za potrebe analize i izrade regresijskog modela iz mjesečnih podataka izračunat je godišnji broj dolazaka turista.

Noćenja turista jesu svaka registrirana noć osobe (turista) u objektu koji pruža uslugu smještaja. Do 2016. podaci o turističkom prometu (noćenja turista) prikupljali su se Mjesečnim izvještajem o dolascima i noćenjima turista. Za potrebe analize i izrade regresijskog modela iz mjesečnih podataka izračunat je godišnji broj noćenja turista.

Procjene ukupnog broja stanovnika izračunate su na temelju podataka Popisa 2011., prirodnoga kretanja i migracijskog salda. Za definiranje ukupnog stanovništva primjenjuje se koncept uobičajenog mjesta stanovanja. Uobičajenim mjestom stanovanja smatra se ono mjesto u kojem osoba provodi većinu svoga dnevnog odmora bez obzira na kratkotrajnu odsutnost iz tog mjesta (npr. zbog odlaska na odmor, putovanje, liječenje, u posjet i sl.).

Svi podaci o **izvozu i uvozu** izraženi su u vrijednostima. Vrijednost robe određena je na temelju izvornih dokumenata poslovnih subjekata (ugovori, računi). Podaci o uvozu i izvozu prikupljaju se na mjesečnoj razini. Za potrebe analize i izrade regresijskog modela iz mjesečnih podataka izračunat je godišnji iznos izvoza i uvoza u kunama.

Prosječna neto plaća po zaposlenom obuhvaća zaposlene u pravnim osobama svih oblika vlasništva, tijelima državne vlasti te tijelima jedinica lokalne i područne (regionalne) samouprave na području Republike Hrvatske. Nisu obuhvaćene isplate zaposlenih u djelatnosti obrta i slobodnih profesija ni osiguranika poljoprivrednika. Podaci o prosječnim neto plaćama po zaposlenom prikupljaju se na mjesečnoj razini. Iz mjesečnih podataka za potrebe analize i izrade regresijskog modela izračunata je godišnja prosječna neto plaća po zaposlenom.

Obiteljske naknade obuhvaćaju novčane ili nenovčane potpore, osim zdravstvene skrbi, u vezi s troškovima trudnoće, poroda i posvajanja, odgoja djece te skrbi za ostale članove obitelji.

Bruto nacionalni dohodak po stanovniku je bruto nacionalni dohodak pretvoren u američke dolare koristeći metodu Atlas Svjetske banke podijeljen s prosječnom populacijom.

Prosječan broj zaposlenih obuhvaća zaposlene u pravnim osobama, zaposlene u obrtu i slobodnim profesijama te osiguranike poljoprivrednike. Godišnji prosjek broja zaposlenih izračunava se na osnovi podataka mjesečnih stanja za tu godinu korigiranih podacima punog obuhvata sa stanjem 31. ožujka. Podaci o broju zaposlenih prikupljaju se na mjesečnoj razini. Iz mjesečnih podataka za potrebe analize i izrade regresijskog modela izračunat je godišnji prosječan broj zaposlenih.

Prosječan broj nezaposlenih odnosi se na broj nezaposlenih preuzet od Hrvatskog zavoda za zapošljavanje. Podaci o broju nezaposlenih prikupljaju se na mjesečnoj razini. Za potrebe analize i izrade regresijskog modela iz mjesečnih podataka izračunat je godišnji prosječan broj nezaposlenih.

Bruto domaći proizvod po stanovniku izračunat je na osnovi obračunatoga ukupnog bruto domaćeg proizvoda i procijenjenih podataka o broju ukupnog stanovništva sredinom godine. Državni zavod za statistiku izračunao je BDP po stanovniku na godišnjoj razini.

Bruto investicije sastoje se od bruto investicija u dugotrajnu imovinu (fiksni kapital) i promjena zaliha. Promjene zaliha računaju se za zalihe proizvodnje u tijeku, zalihe gotovih proizvoda, zalihe trgovačke robe te zalihe sirovina i materijala.

Bruto dodana vrijednost definirana je kao vrijednost proizvodnje umanjena za vrijednost intermedijarne potrošnje. Može se mjeriti bruto ili neto, tj. prije ili nakon odbijanja potrošnje fiksnog kapitala. BDV mjeri doprinos što ga bruto dodanom proizvodu (BDP-u) daje svaki pojedini proizvođač, vrsta djelatnosti ili sektor. Račun proizvodnje mjeri doprinos što ga BDP-u daju samo industrijski proizvođači, industrijske vrste djelatnosti i industrijski dio za sektor nefinancijskih poduzeća. Bruto dodana vrijednost (BDV) po djelatnostima vrednovana je u bazičnim cijenama.

Broj pristupnih mjesta odnosi se na broj fizičkih objekata svih davatelja poštanskih usluga u kojima korisnici mogu obavljati poštanske usluge. Podatke do 2012. prikupljao je Državni zavod za statistiku, a od 2013. podaci se preuzimaju od HAKOM-a.

Prostorna pokrivenost pristupnih mjesta odnosi se na prostornu pokrivenost (km^2) fizičkih objekata, poslovnica i šaltera koji služe za preuzimanje i dostavu pošiljaka od korisnika. Podaci su samostalno izračunati na temelju podatka o površini Republike Hrvatske[1] i broja pristupnih mjesta.

Broj zaposlenih kod davatelja poštanskih i kurirskih usluga je ukupan broj radnika na tržištu poštanskih usluga.

Ukupan prihod od obavljanja poštanskih usluga odnosi se na prihod davatelja poštanskih usluga (HP i ostali davatelji poštanskih i kurirskih usluga) od obavljanja poštanskih usluga.

Prosječna pokrivenost stanovništva svakog pristupnog mjesta odnosi se na broj stanovnika za koje posluje jedno pristupno mjesto. Podaci su samostalno izračunati na temelju procjene ukupnog broja stanovnika i broja pristupnih mjesta.

Broj telefonskih linija nepokretne mreže je ukupan broj priključaka koji se koriste radi pružanja javno dostupne telefonske usluge privatnim i poslovnim korisnicima u javnim

[1] Površina Republike Hrvatske iznosi 56 594 km^2

nepokretnim komunikacijskim mrežama. Sastoji se od zbroja analognih, ISDN i ostalih priključaka.

Korisnici pokretne mreže jesu svi korisnici bez pretplatničkog odnosa, kao i svi korisnici s pretplatničkim odnosom u javnoj pokretnoj komunikacijskoj mreži koji se koriste telefonskim uslugama. Jedna SIM kartica predstavlja jednoga korisnika javne pokretne komunikacijske mreže.

Ukupna ulaganja operatora elektroničkih komunikacija u RH odnosi se na ulaganja u telekomunikacijsku infrastrukturu i opremu te promicanje inovacija.

Broj poštanskih pretinaca odnosi se na broj objekata (pretinaca) koji su na raspolaganju korisnicima na njihov zahtjev, a gdje se poštanske pošiljke dostavljaju umjesto na njihovu stvarnu poštansku adresu. Smatra se privremenom adresom za poštanske pošiljke.

Registrirane pravne osobe jesu jedinice upisane u Registar poslovnih subjekata Državnog zavoda za statistiku, a odnose se na trgovačka društva, poduzeća, ustanove, zadruge, udruge, političke stranke i ostale neusklađene jedinice koje su imale pravni subjektivitet prema prije vrijedećim zakonima, tijela državne vlasti te tijela jedinica lokalne i područne (regionalne) samouprave.

Obrt i slobodna zanimanja spadaju u fizičke osobe. Fizičke osobe jesu jedinice koje obavljaju djelatnost u skladu s propisima, a odnose se na obrt i slobodna zanimanja.

Gustoća stanovništva na 1 km^2 odnosi se na broj stanovnika na 1 km^2.

Prosječni godišnji raspoloživi dohodak po kućanstvu jest ukupan novčani neto dohodak koji je primilo kućanstvo i svi njegovi članovi tijekom referentnog razdoblja koje je prethodna godina. Ukupan dohodak obuhvaća dohodak od nesamostalnog rada, dohodak od samostalnog rada, dohodak od imovine, mirovine, socijalne transfere te ostale novčane primitke koje kućanstvo prima od osoba izvan kućanstva. Podaci prikazuju prosječni godišnji raspoloživi dohodak po kućanstvu.

Indeks cijena poštanskih usluga odnosi se na serije indekasa potrošačkih cijena na bazi prethodne godine. Indeks potrošačkih cijena odražava promjene u razini cijena dobara i usluga koje u tijeku vremena nabavlja, koristi se njima ili ih plaća referentno stanovništvo (privatna kućanstva) radi osobne potrošnje.

Ukupna vrijednost prodanih industrijskih proizvoda odnosi se na ukupnu vrijednost industrijske proizvodnje koju su prodala poduzeća koja su se bavila industrijskom proizvodnjom. Vrijednost prodane industrijske proizvodnje prema djelatnosti proizvoda odnosi se na rudarstvo i vađenje, prerađivačku industriju, opskrbu električnom energijom, plinom, parom i klimatizaciju te opskrbu vodom, uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša.

Broj kućanstava s pristupom Internetu predstavlja broj kućanstava s pristupom Internetu s Dial-up, xDSL, kablovskim Internetom, mobilnim telefonom (GPRS, WAP).

Kupovina dobara ili usluga Internetom odnosi se na broj osoba koje su kupovale dobra ili usluge putem Interneta.

Analiza se radi na 30 čimbenika za koje su bili dostupni podaci na godišnjoj razini, a 2007. godina uzeta je kao početna godina za istraživanje čimbenika za izradu godišnjih modela broja paketskih pošiljaka jer su podaci u Republici Hrvatskoj za pojedine čimbenike dostupni tek od 2007. godine.

4. REGRESIJSKI MODELI UTJECAJA IZABRANIH ČIMBENIKA NA BROJ PAKETSKIH POŠILJAKA

U ovom dijelu rada korištenjem kvantitativnih metoda analizira se kretanje broja paketskih pošiljki. Koriste se podatci za dvanaestogodišnje razdoblje od 2007. do 2018. za izradu godišnjih modela za predviđanje paketskih pošiljaka. Uporabom podataka na godišnjoj razini utvrđuje se trend kretanja broja paketskih pošiljaka. Koristi se grafičko i tabelarno prikazivanje, metode deskriptivne statistike, regresijska analiza, korelacijska analiza te ANOVA test koji se temelji na analizi varijance.

Grafičkim i tabelarnim prikazivanjim prezentiraju se vrijednosti i kretanja odabranih varijabli.

Metodama deskriptivne statistike prikazuju se srednje vrijednosti i pokazatelji disperzije oko srednje vrijednosti te kretanje pojedinog čimbenika u promatranom periodu. Korelacijskom analizom se testiraju povezanosti među odabranim varijablama, dok se upotrebom ANOVA testa testira razlika u broju paketskih pošiljaka u različitim dobima promatranja. Regresijskom analizom se testira utjecaj na regresijsku varijablu, broj pošiljki u promatranom razdoblju. Uvođenjem varijable vrijeme u model, regresijski model poprima obilježja trend modela. Zaključci se donese pri razini signifikantnosti od 5% [104].

Postupak izbora varijabli prikazan je na slici 18. Plan izbora nezavisnih varijabli u višestrukoj linearnoj regresiji korišten je kod izrade svih regresijskih modela u ovom radu.

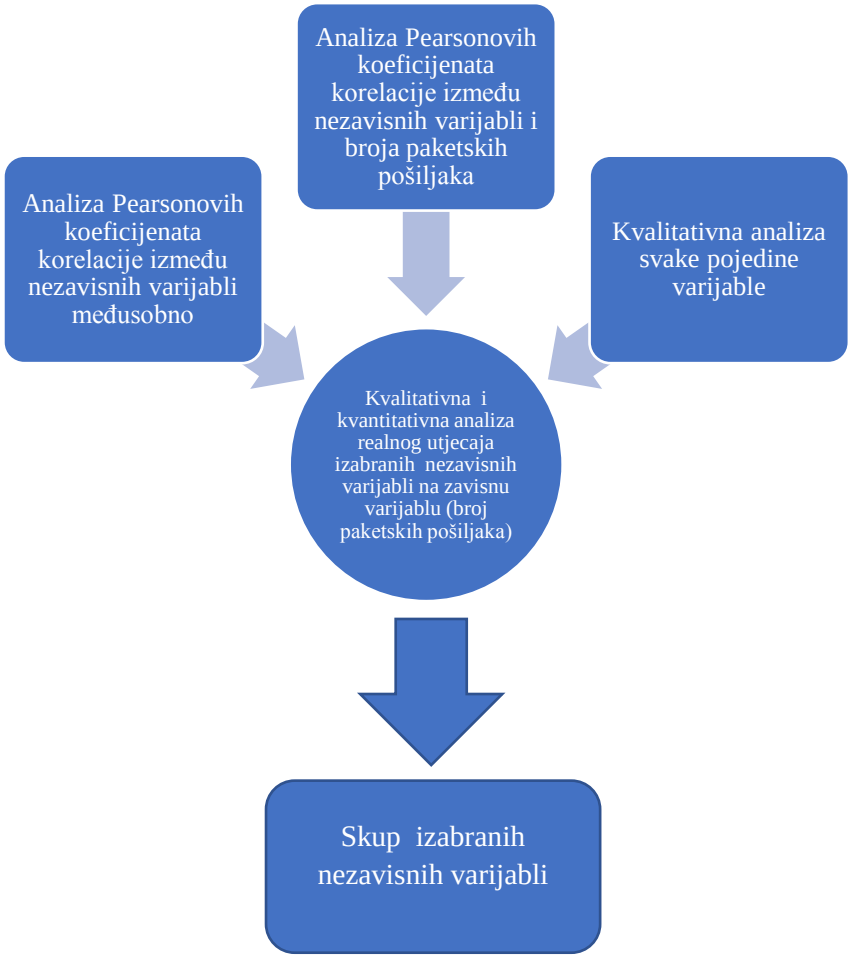

Slika 18. Plan izbora nezavisnih varijabli u višestrukoj linearnoj regresiji

Predložena su dva modela i to linearni regresijski model bez trenda i linearni regresijski model s trendom budući da se upotrebom modela s trendom opisuje promjena broja paketskih pošiljaka u vremenu u kombinaciji s odabranim varijablama za koje se očekuje postojanje utjecaja na kretanje zavisne varijable koja je u ovom slučaju broj paketskih pošiljaka, a iste su navedene u tablici 3. ovog rada. Za varijable čije se kretanje promatra u odabranom vremenskom razdoblju opravdano je korištenje trend modela budući da se vrijednosti mijenjaju između promatranih razdoblja, odnosno broj paketskih pošiljaka je zavisan o promjeni vremena promatranja. Upotrebu modela s trendom objasnio je Šošić [33], dok se modeli s trendom primjenjuju kod procjene kretanja u području meteorologije [105], te u području agrokulture [106].

4.1. Linearni regresijski model utjecaja izabranih čimbenika na broj paketskih pošiljaka upotrebom godišnjih vrijednosti

U ovom dijelu rada procjenjuju se modeli utjecaja odabranih varijabli na broj paketskih pošiljaka s podacima na godišnjoj razini. Upotrebom podataka na godišnjoj razini eliminira se utjecaj sezonskih oscilacija.

Baza podataka s godišnjim vrijednostima uključuje dolje navedene varijable. Stoga za izradu modela s godišnjim podatcima koriste se podatci o:

broju dolazaka turista, broju noćenja turista, procjeni ukupnog broja stanovnika, uvozu, izvozu, bruto nacionalnom dohotku po stanovniku, prosječnom broju zaposlenih, prosječnom broju nezaposlenih, bruto domaćem proizvodu po stanovniku, bruto investicijama, bruto dodanoj vrijednosti, prosječnoj neto plaći po zaposlenom, obiteljskim naknadama, broju pristupnih mjesta, prostornoj pokrivenost pristupnih mjesta, broju telefonskih linija nepokretne mreže, korisnicima pokretne mreže, broju kućanstava s pristupom Internetu, redovitim Internet kupcima, ukupnim ulaganjima operatora elektroničkih komunikacija u RH, broju zaposlenih kod davatelja poštanskih i kurirskih usluga, broju poštanskih pretinaca, ukupnom prihodu od obavljanja poštanskih usluga, prosječnoj pokrivenosti stanovništva svakog pristupnog mjesta, registriranim pravnim osobama, obrtima i slobodnim zanimanjima, gustoći stanovništva na 1 km^2, prosječnom godišnjem raspoloživom dohotku po kućanstvu, indeksu cijena poštanskih usluga, ukupnoj vrijednosti prodanih industrijskih proizvoda, te broju paketskih pošiljaka kao zavisnoj varijabli.

4.1.1. Deskriptivna statistika godišnjih podataka

Prvo se koriste godišnje vrijednosti, gdje je korišteni uzorak za razdoblje od 2007. do 2018. godine. Deskriptivna statistika analiziranih varijabli prikazana je u tablici 4.

Tablica 4. Deskriptivna statistika

	N	Prosjek	Medijan	Minimum	Maksimum	St. dev.	V (%)
Broj dolazaka turista (mil)	12	13,18	12,13	10,27	18,67	2,76	20,91
Broj noćenja turista (mil)	12	67,04	63,78	54,99	89,65	11,94	17,81
Procjena ukupnog broja stanovnika (mil)	12	4,23	4,25	4,08	4,31	0,08	1,92
Uvoz (mlrd kn)	12	136,50	134,42	110,30	176,22	20,38	14,93
Izvoz (mlrd kn)	12	78,65	72,49	55,27	107,91	16,31	20,74
Prosječna neto plaća po zaposlenom (kn)	12	5.521,55	5.496,38	4.839,67	6.242,00	364,98	6,61
Bruto nacionalni dohodak po stanovniku (US$)	12	13.300,00	13.465,00	12.130,00	14.050,00	674,35	5,07
Prosječan broj zaposlenih (mil)	12	1,44	1,44	1,34	1,54	0,06	4,35
Prosječan broj nezaposlenih (tis)	12	270,42	275,18	153,54	345,11	57,09	21,11
BDP po stanovniku (kn)	12	80.589,95	78.039,47	74.841,50	93.528,19	5.567,79	6,91
Bruto investicije (mlrd kn)	12	77,17	72,00	63,00	107,00	14,09	18,26
Bruto dodana vrijednost (mlrd kn)	12	286,08	282,00	273,00	315,00	12,57	4,39
Obiteljske naknade (mlrd kn)	12	2,88	2,90	2,62	3,26	0,17	5,83
Broj pristupnih mjesta	12	1.782,25	2.083,00	1.016,00	2.235,00	493,15	27,67
Broj zaposlenih kod davatelja poštanskih i kurirskih usluga	12	11.224,92	10.697,50	9.454,00	14.136,00	1.705,16	15,19
Broj poštanskih pretinaca	12	27.600,75	28.530,50	23.711,00	29.002,00	1.713,19	6,21
Ukupan prihod od obavljanja poštanskih usluga (mlrd kn)	12	1,49	1,49	1,34	1,66	0,09	5,77
Prostorna pokrivenost pristupnih mjesta (km^2)	12	34,83	27,16	25,32	55,70	12,21	35,04
Broj telefonskih linija nepokretne mreže (mil)	12	1,59	1,63	1,26	1,94	0,22	13,73
Korisnici pokretne mreže (mil)	12	5,03	4,94	4,32	6,36	0,71	14,11

Prosječna pokrivenost stanovništva svakog pristupnog mjesta (broj stanovnika)	12	2.598,33	2.053,00	1.896,00	4.041,00	877,32	33,76
Ukupna ulaganja operatora elektroničkih komunikacija u RH (mlrd kn)	12	2,25	2,33	1,57	2,67	0,34	15,05
Registrirane pravne osobe (tis)	12	275,61	272,51	252,65	312,35	19,11	6,93
Obrt i slobodna zanimanja (tis)	12	87,03	86,34	76,94	100,26	8,58	9,86
Broj kućanstava s pristupom Internetu (tis)	12	893,04	937,36	589,21	1.080,14	162,88	18,24
Redoviti Internet kupci (broj osoba u tis)	12	540,85	582,71	156,61	1.092,79	297,47	55,00
Gustoća stanovništva na 1 km^2	12	75,81	75,30	72,20	78,40	2,30	3,03
Prosječni godišnji raspoloživi dohodak po kućanstvu (tis kn)	12	84,38	82,75	77,44	97,87	6,09	7,21
Indeks cijena poštanskih usluga	12	103,03	100,65	90,40	115,70	6,82	6,62
Ukupna vrijednost prodanih industrijskih proizvoda (mlrd kn)	12	126,83	123,85	116,94	140,82	7,16	5,64
Broj paketa (tis)	12	11.768,33	9.664,00	6.461,00	20.950,00	4.992,89	42,43

- Prosječan broj dolazaka turista je 13,18 milijuna s prosječnim odstupanjem od aritmetičke sredine 2,76 milijuna dolazaka. Riječ je o maloj disperziji u promatranom razdoblju (V=20,91% < 30%). U promatranom razdoblju od 2007. do 2018. bilježi se povećanje broja dolazaka turista s iznimkom u 2008. kada nastaje svjetska kriza i dolazi do pada broja dolazaka turista. Tek u drugoj polovici 2010. dolazi do broja dolazaka turista koji je bio prije 2008. Od druge polovice 2010. broj dolazaka turista konstantno raste. Može se zaključiti da broj dolazaka turista i broj paketskih pošiljaka imaju isti trend kretanja i da se korelacijskom analizom očekuje visoki stupanj povezanosti između ove dvije varijable (Slika 19.).

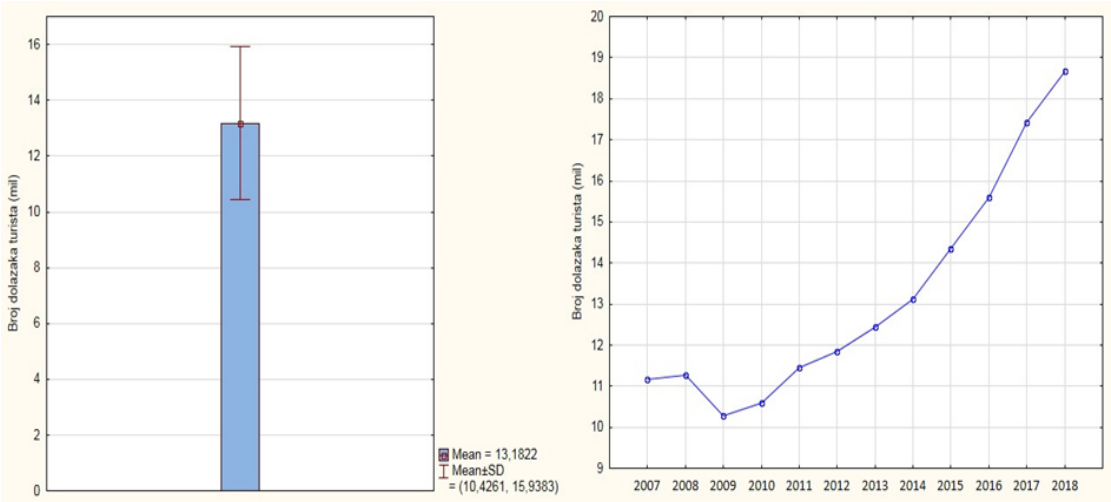

Slika 19. Broj dolazaka turista

- Prosječan broj noćenja turista je 67,04 milijuna s prosječnim odstupanjem od aritmetičke sredine 11,94 milijuna noćenja. Riječ je o maloj disperziji u promatranom razdoblju (V=17,81% < 30%). Kao i kod prethodne varijable broja dolazaka turista tako je i za broj noćenja turista zabilježen isti trend kretanja broja noćenja (Slika 20.).

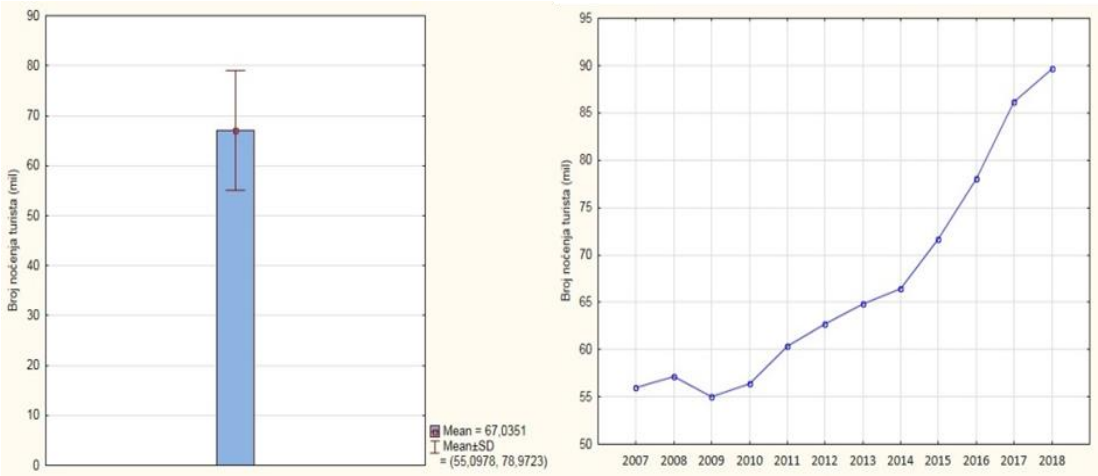

Slika 20. Broj noćenja turista

- U prosjeku je procijenjen ukupan broj stanovnika 4.23 milijuna s prosječnim odstupanjem od aritmetičke sredine 0,08 milijuna stanovnika odnosno 80.000 tisuća. Riječ je o vrlo maloj disperziji u promatranom razdoblju (V=1,92% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Iz grafikona se može vidjeti konstantan pad broja stanovnika u promatranom razdoblju (Slika 21.).

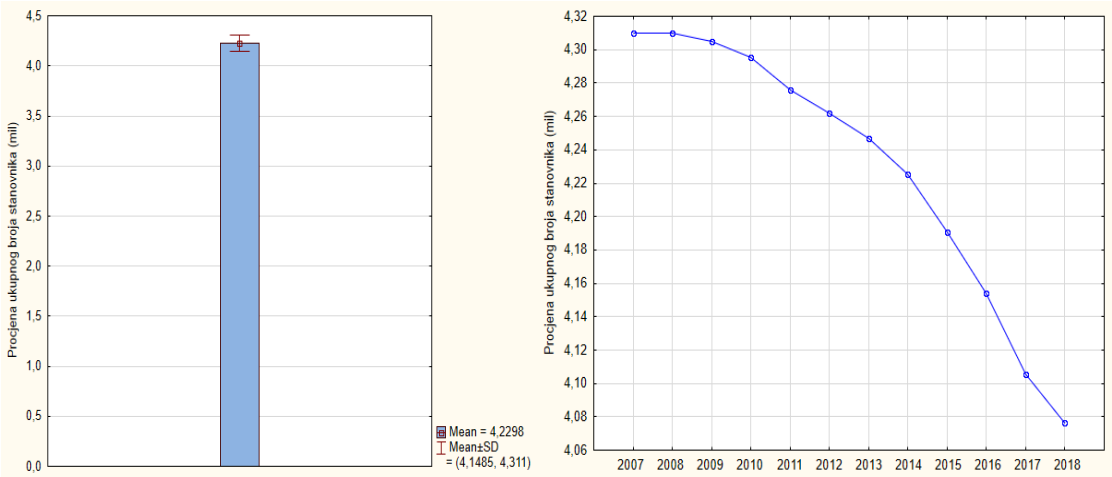

Slika 21. Broj stanovnika

- Prosječna vrijednost uvoza u promatranom razdoblju je 136,50 milijardi kuna s prosječnim odstupanjem od aritmetičke sredine 20,38 milijardi kuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=14,93% < 30%). Zamjetan pad uvoza zabilježen je u 2008. i nastavio se do 2010. Od 2010. uvoz kao i broj paketskih pošiljaka konstantno rastu što sugerira da spomenuta varijabla ima utjecaj na promet paketskih pošiljaka, a što će se dodatno ispitati regresijskom analizom (Slika 22.).

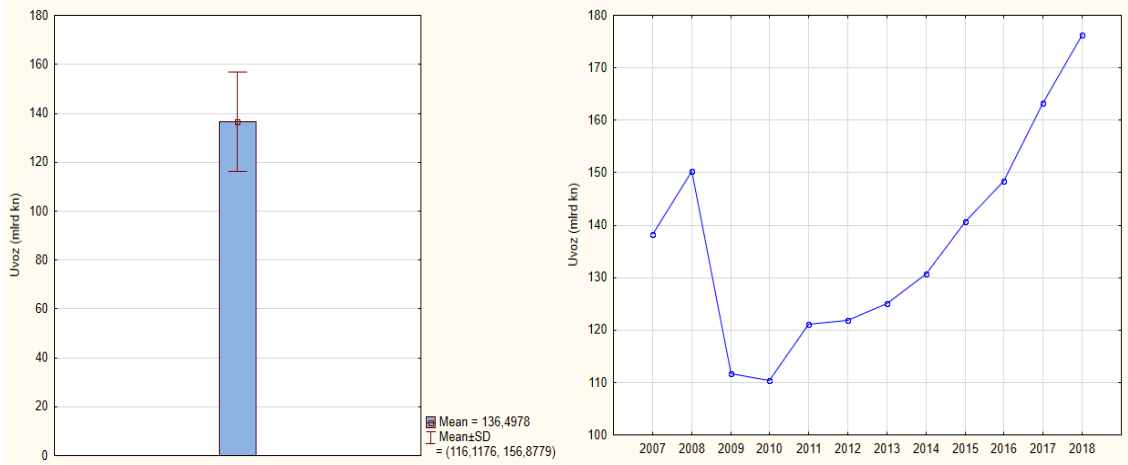

Slika 22. Uvoz

- Prosječna vrijednost izvoza u promatranom razdoblju je 78,65 milijardi kuna s prosječnim odstupanjem od aritmetičke sredine 16,31 milijardi kuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=20,74% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Nastankom ekonomske krize u 2008. godini dolazi do pada izvoza. Tijekom ekonomske krize u 2009. zabilježena je

najmanja vrijednost izvoza. Od 2010. godine utvrđeno je povećanje izvoza. Kako se i broj paketskih pošiljaka od 2010. povećava, ovdje se kao i kod uvoza može pretpostaviti da će ova varijabla imati utjecaj na broj paketskih pošiljaka, a što će se još naknadno ispitati korelacijskom i regresijskom analizom (Slika 23.).

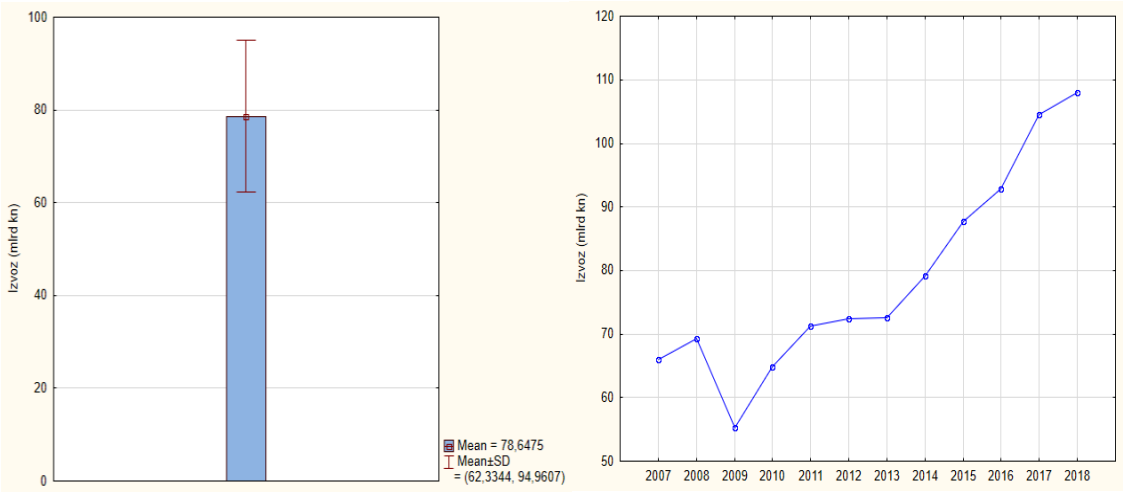

Slika 23. Izvoz

- Iz grafičkog prikaza se može utvrditi da su prosječne plaće u promatranom razdoblju 5.521,55 kuna s prosječnim odstupanjem od aritmetičke sredine 364,98 kuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=6,61% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju, odnosno nije došlo do značajnijih promjena plaća. U promatranom razdoblju utvrđena je tendencija povećanja prosječnih plaća, izuzev 2016., što je i u skladu s povećanjem broja paketskih pošiljaka. Stoga se može pretpostaviti da će ova varijabla utjecati na broj paketskih pošiljaka, a što se kasnije dodatno analizira (Slika 24.).

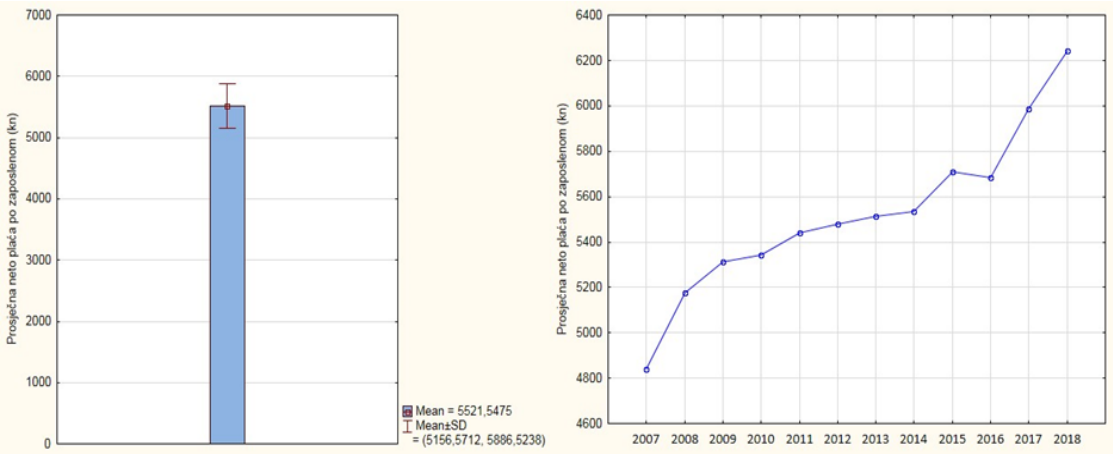

Slika 24. Neto plaća

- Prosječna vrijednost bruto nacionalnog dohotka po stanovniku u promatranom razdoblju iznosi 13.300,00 američkih dolara s prosječnim odstupanjem od aritmetičke sredine 674,35 američkih dolara. Riječ je o manjoj disperziji u promatranom razdoblju (V=5,07% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju, odnosno nije došlo do značajnijih promjena u bruto nacionalnom dohotku po stanovniku. Nastankom ekonomske krize 2008. godine dolazi do pada bruto nacionalnog dohotka po stanovniku s iznimkom u 2011., tek je 2018. bruto nacionalni dohodak dostigao vrijednost veću nego 2008. (Slika 25.).

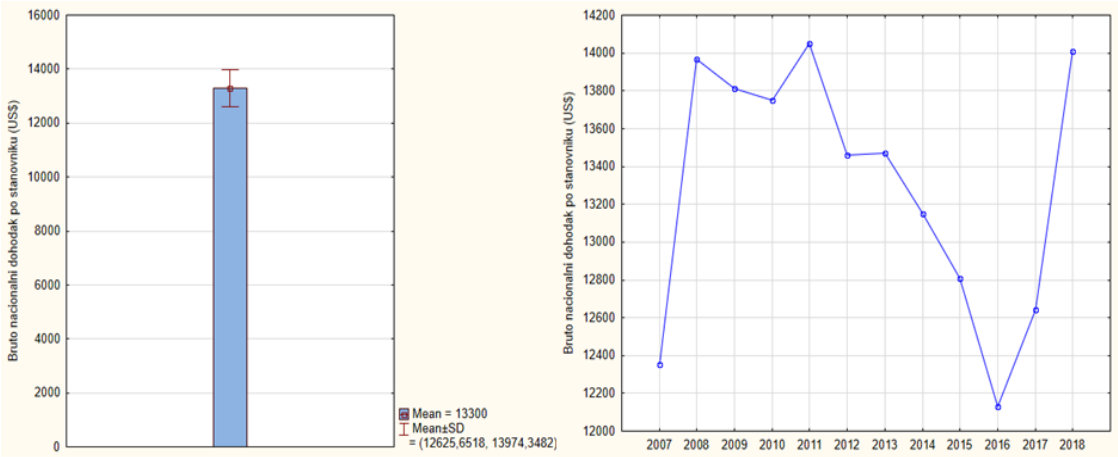

Slika 25. Bruto nacionalni dohodak po stanovniku

- Prosječan je broj zaposlenih u promatranom razdoblju 1,44 milijuna zaposlenih osoba s prosječnim odstupanjem od aritmetičke sredine 0,06 milijuna, odnosno 60.000 zaposlenih. Riječ je o manjoj disperziji u promatranom razdoblju (V=4,35% < 30%).

Može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Od nastanka ekonomske krize 2008. zabilježen je konstantan pad broja zaposlenih sve do 2014. kada broj zaposlenih počinje ponovno rasti. Najmanji broj zaposlenih u iznosu 1,34 milijuna zabilježen je u 2014. godini. Dok je najveći broj zaposlenih iznosio 1,53 milijuna što je zabilježeno u 2008. godini (Slika 26.).

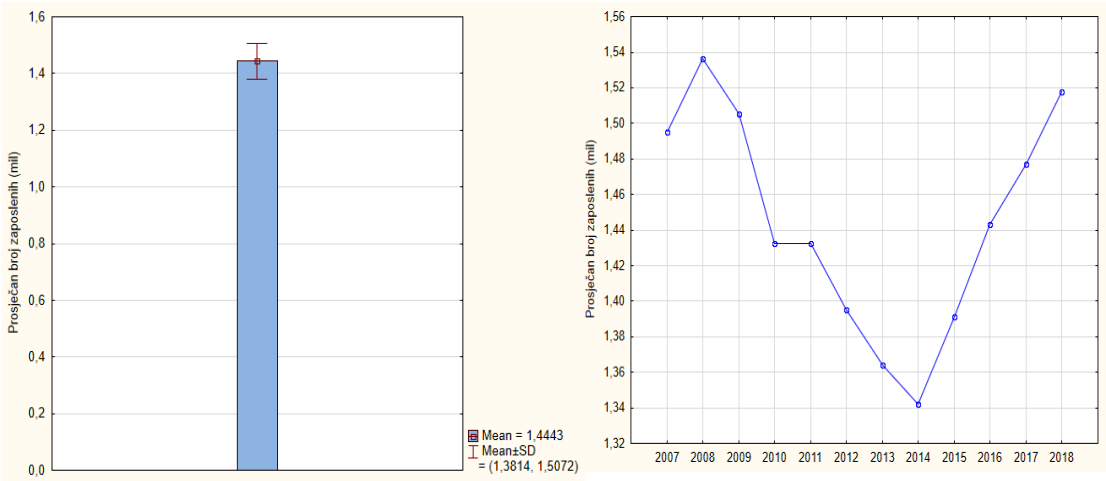

Slika 26. Zaposleni

- Prosječan je broj nezaposlenih u promatranom razdoblju 270,42 tisuće s prosječnim odstupanjem od aritmetičke sredine 57.090 osoba. Riječ je o manjoj disperziji u promatranom razdoblju (V=21,11% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Minimalni broj nezaposlenih osoba u promatranom razdoblju, zabilježen na kraju 2008., iznosio je 236.740. Nastankom svjetske krize u 2008. broj nezaposlenih kontinuirano raste do 2013. kada je broj u promatranom razdoblju dostigao svoj maksimum od 345.112 nezaposlenih osoba. Od 2013. dolazi do kontinuiranog pada broja nezaposlenih osoba (Slika 27.).

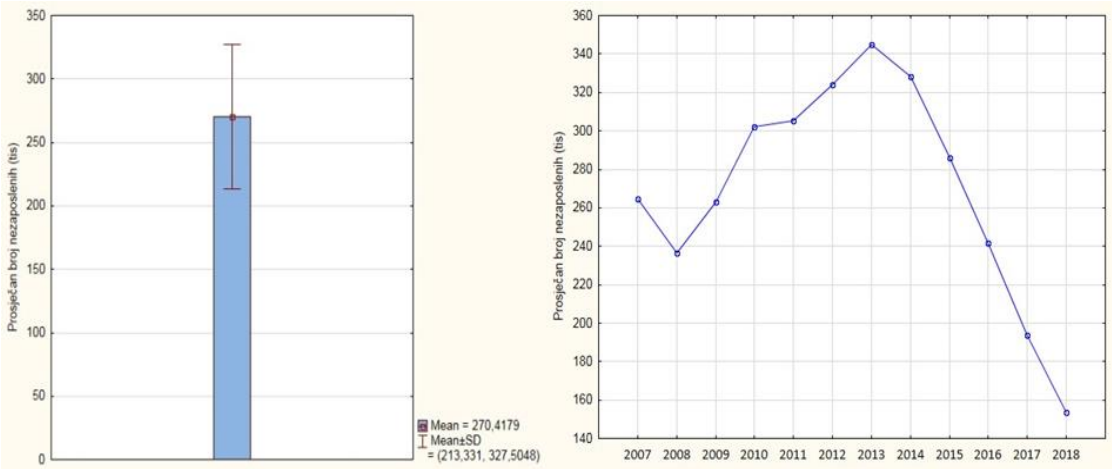

Slika 27. Nezaposleni

- Prosječan ostvaren BDP po stanovniku u promatranom razdoblju je 80.589,95 kuna s prosječnim odstupanjem od aritmetičke sredine 5.567,79 kuna. Riječ je o vrlo maloj disperziji u promatranom razdoblju (V=6,91% < 30%). Može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Iz grafičkog prikaza može se vidjeti da u promatranom razdoblju pad BDP po stanovniku nastaje u 2009. godini što je povezano s nastankom svjetske krize. Pad se nastavio do 2010. nakon čega slijedi njegov rast s iznimkom u 2012. Minimalna vrijednost BDP-a po stanovniku u promatranom razdoblju iznosila je 74.841,50 kuna dok je maksimalna vrijednost iznosila 93.528,19. Globalna kriza dovodi do šestogodišnjeg pada BDP-a, do 2014. godine, u odnosu na 2008. Tek 2015. BDP dostiže vrijednosti iz 2008. i nastavlja rasti. U periodu globalne krize došlo je i do pada državne potrošnje, osobne potrošnje, vrijednosti investicija u fiksni kapital, robnog izvoza, industrijske proizvodnje, prometa u trgovini na malo, fizičkog obujma građevinskih radova. Takve trendove u proizvodnji roba i usluga pratio je i pad broja zaposlenih, odnosno povećanje broja nezaposlenih. U kriznim godinama je došlo do tek skromnog rasta neto plaća [107]. Za očekivati je da će povećanjem BDP po stanovniku doći do povećanja broja paketskih pošiljaka što će se dodatno ispitati korelacijskom i regresijskom analizom (Slika 28.).

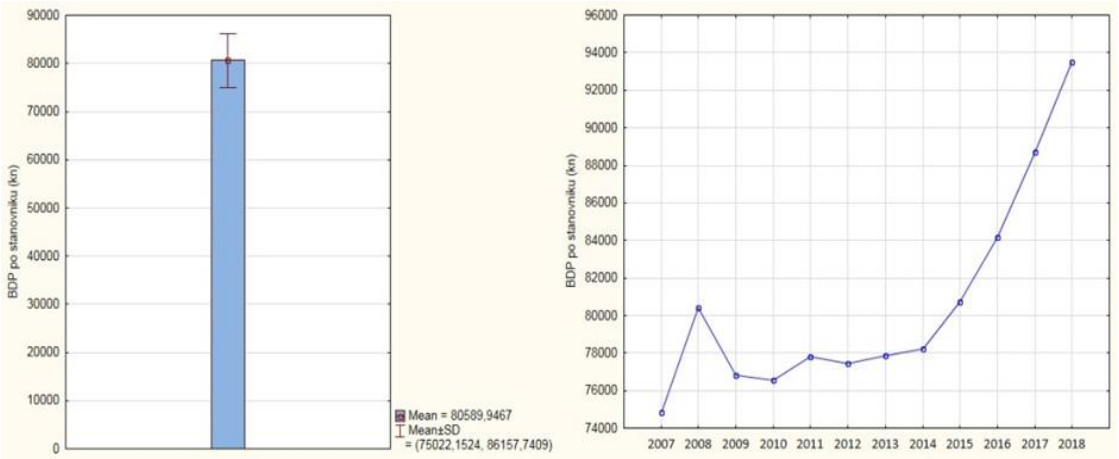

Slika 28. BDP po stanovniku

- Prosječna vrijednost bruto investicija u promatranom razdoblju je 77,17 milijardi kuna s prosječnim odstupanjem od aritmetičke sredine 14,09 milijardi kuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=18,26% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Svjetska kriza ovdje također ima utjecaj na bruto investicije. U promatranom razdoblju pad bruto investicija nastaje od 2009. i nastavlja se do 2013. Nakon 2014. dolazi do rasta bruto investicija. U promatranom razdoblju minimalna vrijednost bruto investicija iznosila je 63,00 milijardi kuna dok je maksimalna vrijednost investicija iznosila 107,00 milijardi kuna (Slika 29.).

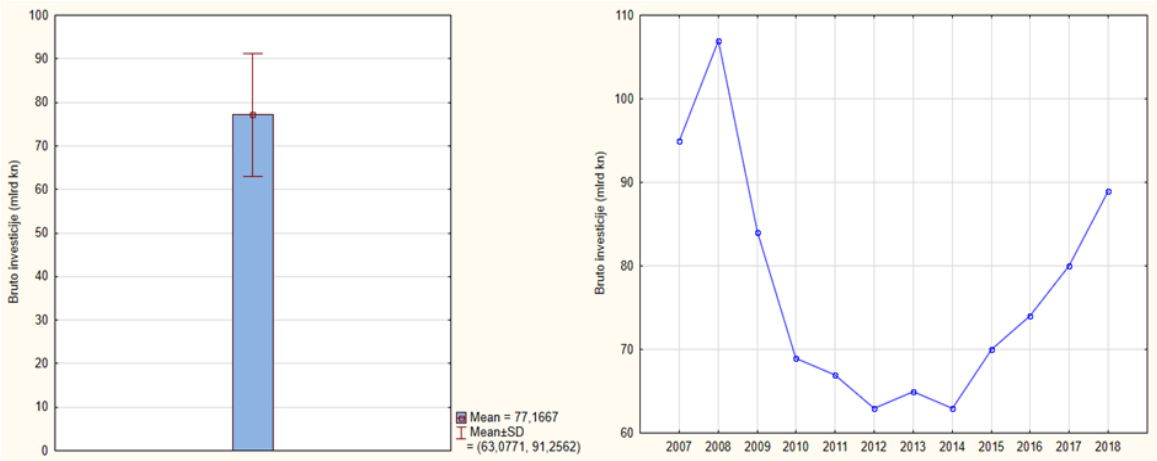

Slika 29. Bruto investicije

- Prosječna vrijednost bruto dodane vrijednosti u promatranom razdoblju je 286,08 milijardi kuna s prosječnim odstupanjem od aritmetičke sredine 12,57 milijardi kuna.

Riječ je o vrlo maloj disperziji u promatranom razdoblju (V=4,39% < 30%). Može se utvrditi da su postojale manje varijacije u promatranom razdoblju. U promatranom razdoblju svjetska kriza 2008. uzrokuje pad BDV-a do 2013. s iznimkom u 2011. Od 2015. ponovno dolazi do povećanja BDV-a (Slika 30.).

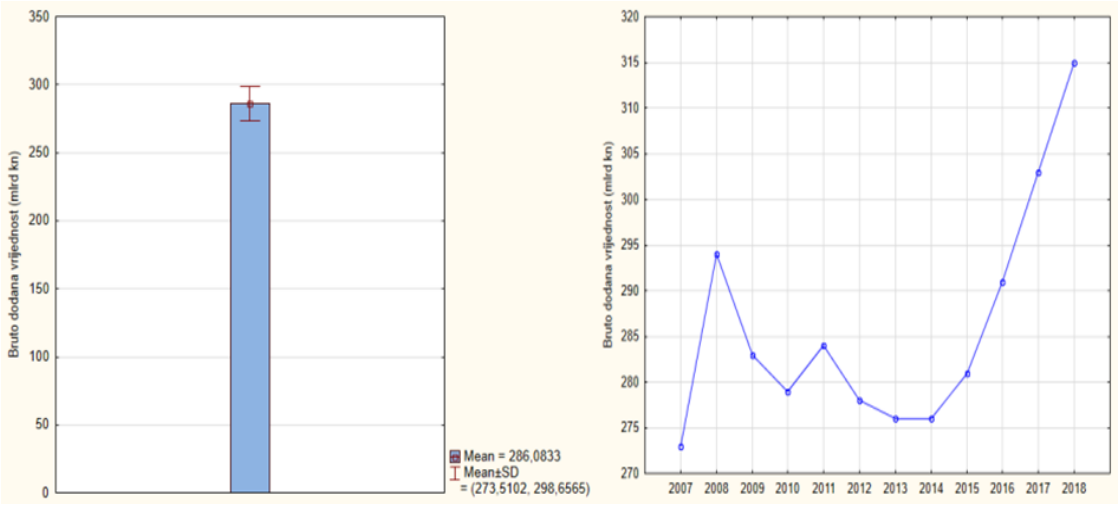

Slika 30. Bruto dodana vrijednost

- Prosječna vrijednost obiteljskih naknada u promatranom razdoblju je 2,88 milijardi kuna s prosječnim odstupanjem od aritmetičke sredine 170 milijuna kuna. Riječ je o vrlo maloj disperziji u promatranom razdoblju (V=5,83% < 30%). Može se utvrditi da su postojale manje varijacije u promatranom razdoblju. U promatranom razdoblju nastankom svjetske krize 2008. dolazi do pada obiteljskih naknada s iznimkom 2009., 2010. i 2015. Tek 2017. obiteljske naknade počinju ponovno rasti, te nisu dostigle vrijedenosti prije svjetske krize (Slika 31.).

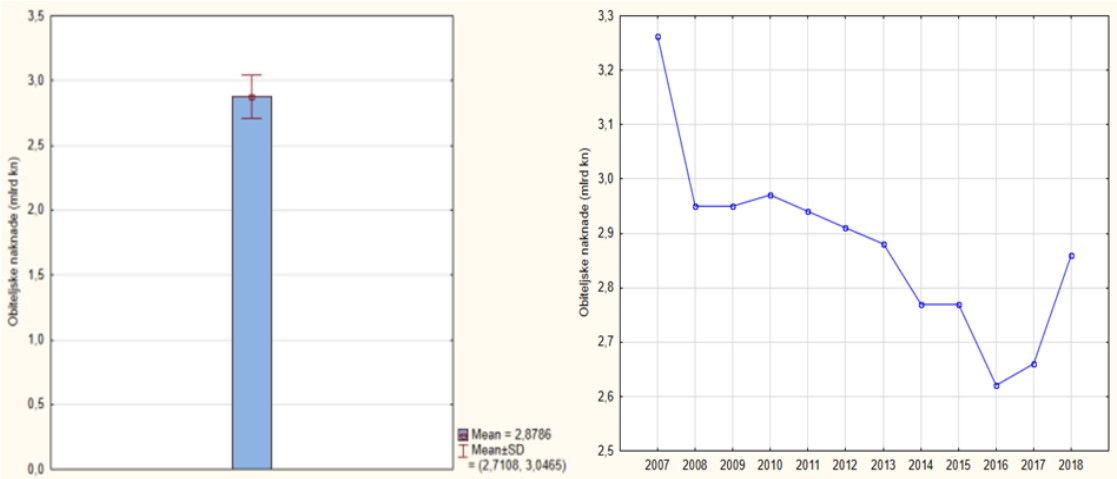

Slika 31. Obiteljske naknade

- Prosječan broj pristupnih mjesta u promatranom razdoblju 1.782,25 s prosječnim odstupanjem od aritmetičke sredine 493,15. Riječ je o manjoj disperziji u promatranom razdoblju (V=27,67% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. U promatranom razdoblju 2009. došlo je do naglog povećanja broja pristupnih mjesta nakon čega je bilo manjih varijacija do 2013. U 2014. opet dolazi do povećanja broja pristupnih mjesta do čijeg pada je došlo već 2015. U 2016. ponovno dolazi do povećanja broja pristupnih mjesta, a nakon čega je opet uslijedio njihov pad (Slika 32.).

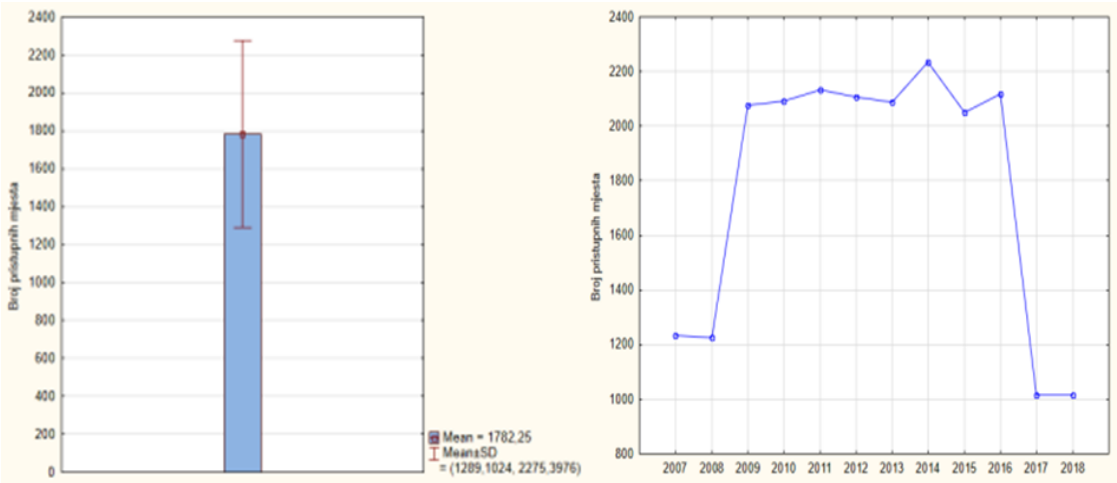

Slika 32. Pristupna mjesta

- Prosječan broj zaposlenih kod davatelja poštanskih i kurirskih usluga u promatranom razdoblju je 11.224,92 osoba s prosječnim odstupanjem od aritmetičke sredine

1.705,16 osoba. Riječ je o manjoj disperziji u promatranom razdoblju (V=15,19% < 30%). Može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Od nastanka ekonomske krize 2008. zabilježen je pad broja zaposlenih do 2011. kada broj zaposlenih počinje ponovno rasti. U 2013. i 2014. dolazi do ponovnog pada broja zaposlenih dok od 2015. dolazi do ponovnog rasta (Slika 33.).

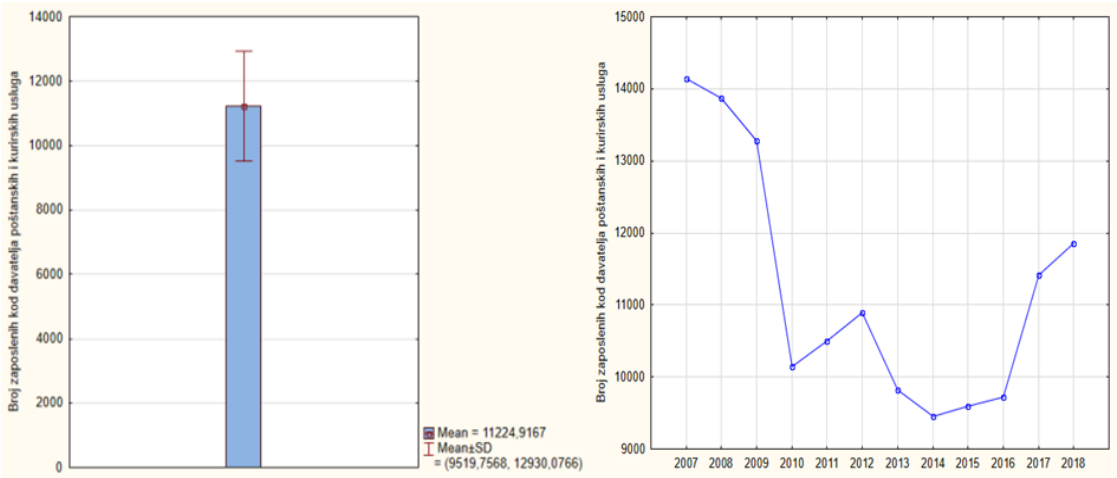

Slika 33. Zaposleni kod davatelja poštanskih i kurirskih usluga

- Prosječan broj poštanskih pretinaca u promatranom razdoblju je 27.600,75 s prosječnim odstupanjem od aritmetičke sredine 1.713,19. Riječ je o manjoj disperziji u promatranom razdoblju (V=6,21% < 30%). Dakle može se utvrditi da su postojale manje varijacije u promatranom razdoblju, odnosno nije došlo do značajnijih promjena u broju poštanskih pretinaca. U promatranom razdoblju od 2008. do 2012. utvrđen je trend smanjenja broja poštanskih pretinaca s iznimkom u 2009. U 2012. ponovno dolazi do povećanja broja poštanskih pretinaca gdje već 2013. dolazi do ponovnog pada. U 2014. ponovno raste njihov broj dok je već 2015. i 2016. opet uslijedio njihov pad. U 2017. opet dolazi do rasta broja poštanskih pretinaca dok 2018. ponovno do smanjenja i to u većem broju (Slika 34.).

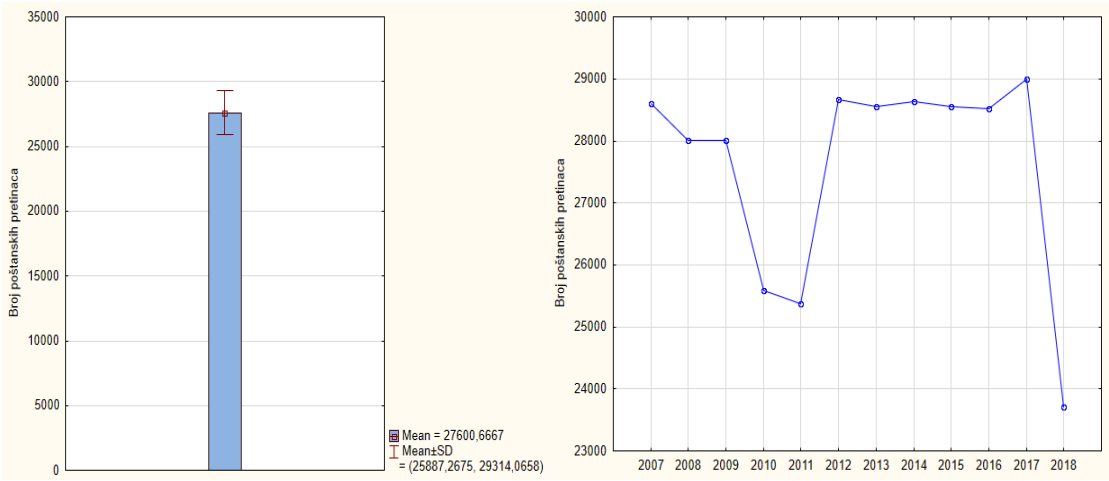

Slika 34. Poštanski pretinci

- Prosječna vrijednost ukupnog prihoda (HP i ostali davatelji poštanskih i kurirskih usluga) od obavljanja poštanskih usluga u promatranom razdoblju iznosi 1,49 milijardi kuna s prosječnim odstupanjem od aritmetičke sredine 90 milijuna kuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=5,77% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju, odnosno nije došlo do značajnijih promjena u ukupnom prihodu od obavljanja poštanskih usluga. U promatranom razdoblju 2010. dolazi do pada ukupnih prihoda koji se nastavio do 2014. kada ukupni prihodi počinju ponovno rasti (Slika 35.).

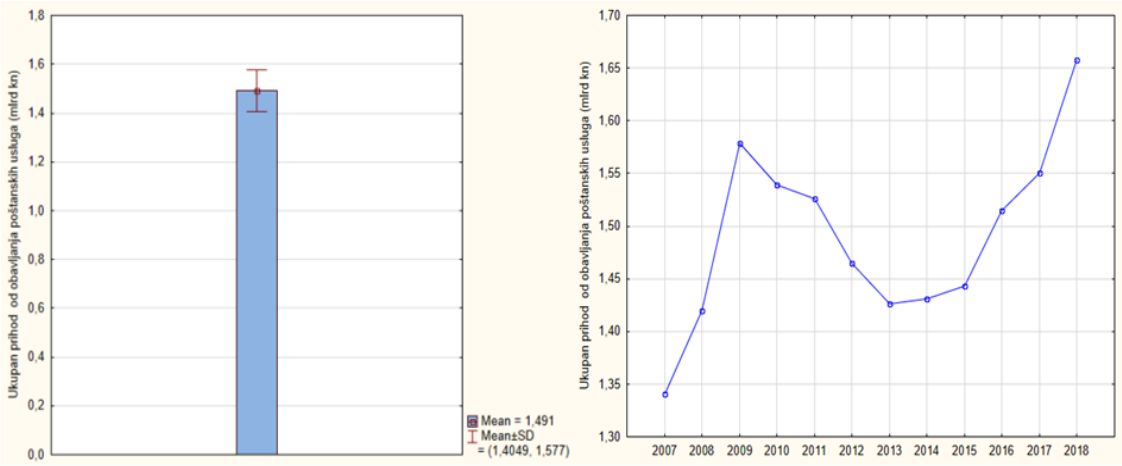

Slika 35. Prihod od obavljanja poštanskih usluga

- Prosječna prostorna pokrivenost pristupnih mjesta u promatranom razdoblju je 34,83 km^2 s prosječnim odstupanjem od aritmetičke sredine 12,21 km^2. Riječ je o velikoj

disperziji u promatranom razdoblju (V=35,04% > 30%). Dakle, utvrđene su velike disperzije u promatranom razdoblju. Disperzija je velika ukoliko je disperzija veća od 30% [108]. Nastankom svjetske krize od 2008. do 2009. dolazi do naglog opadanja prostorne pokrivenosti pristupnih mjesta, nakon čega se pad nastavio do 2011. Od 2012. godini dolazi do povećanja prostorne pokrivenosti pristupnih mjesta s iznimkom u 2014. i 2016. godini. U promatranom razdoblju minimalna prostorna pokrivenost pristupnih mjesta iznosila je 25,32 km^2 dok je maksimalna iznosila 55,70 km^2 (Slika 36.).

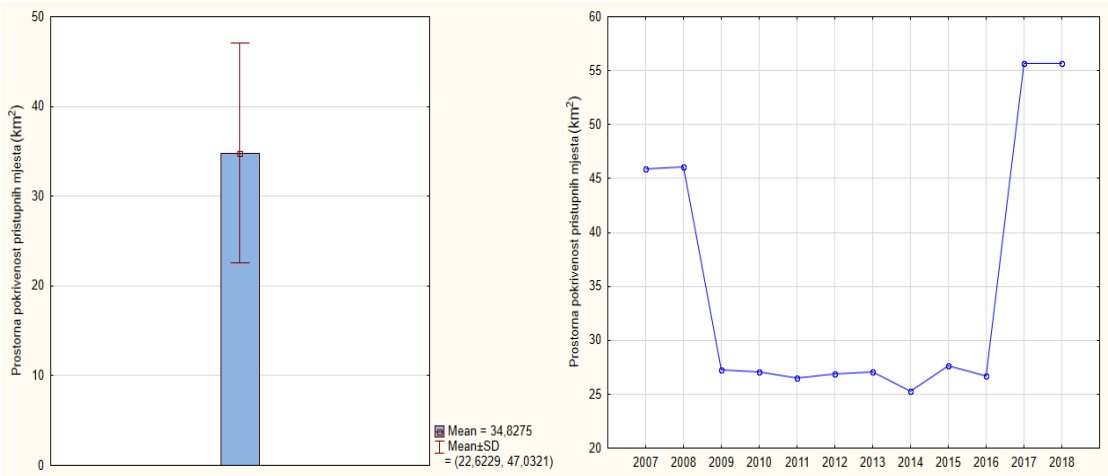

Slika 36. Prostorna pokrivenost pristupnih mjesta

- Prosječan broj telefonskih linija nepokretne mreže u promatranom razdoblju 1,59 milijuna s prosječnim odstupanjem od aritmetičke sredine 0,22 milijuna odnosno 220 tisuća. Riječ je o manjoj disperziji u promatranom razdoblju (V=13,73% < 30%). Dakle može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Broj telefonskih linija nepokretne mreže je imao tendenciju kontinuiranog pada nakon 2010. godine. Ovo je i za očekivati s obzirom da se proteklih godina konstantno povećava udio korisnika širokopojasnog pristupa Internetu putem pokretne mreže, odnosno putem mobilnih telefona [109], koja omogućava telefoniranje privatnim i poslovnim korisnicima putem IP protokola kao što su OTT (eng. Over the Top) usluge poput Skype-a ili Viber-a (Slika 37.).

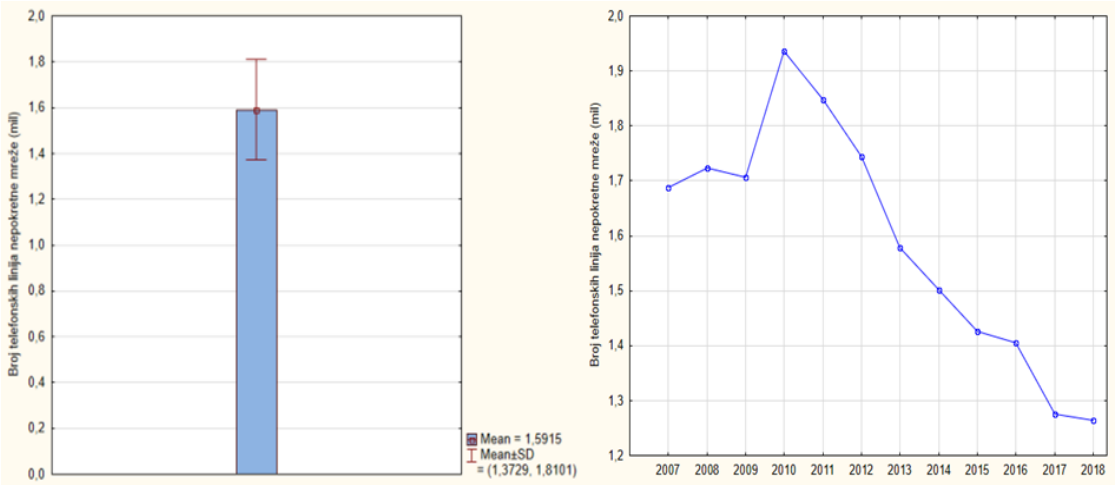

Slika 37. Telefonske linije nepokretne mreže

- Prosječan broj korisnika pokretne mreže u promatranom razdoblju je 5,03 milijuna s prosječnim odstupanjem od aritmetičke sredine 0,71 milijuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=13,73% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. U promatranom razdoblju od 2007. do 2010. broj korisnika pokretne mreže je rastao nakon čega je uslijedio kontinuirani pad do 2017, nakon čega je 2018. godine došlo do blagog porasta. U promatranom razdoblju minimalan broj korisnika pokretne mreže iznosio je 4,31 milijuna dok je maksimalan broj iznosio 6,36 milijuna (Slika 38.).

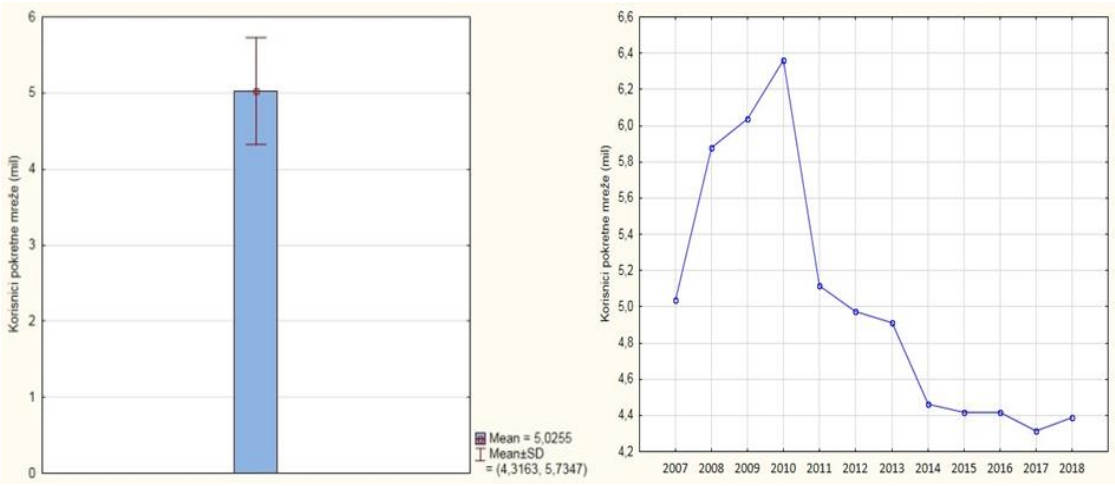

Slika 38. Korisnici pokretne mreže

- Prosječna pokrivenost stanovništva svakog pristupnog mjesta u promatranom razdoblju je 2.598,33 s prosječnim odstupanjem od aritmetičke sredine 877,32 osobe.

Riječ je o velikoj disperziji u promatranom razdoblju (V=33,76% > 30%). Dakle, može se utvrditi da su postojale velike varijacije u promatranom razdoblju u pokrivenosti stanovništva svakog pristupnog mjesta. Svjetska kriza 2008. dovela je do pada pokrivenost stanovništva svakog pristupnog mjesta 2009. godine. Pad se nastavio do 2011. nakon čega dolazi do rasta pokrivenosti stanovništva. U 2014., 2016. i 2018. dolazi do pada pokrivenosti (Slika 39.).

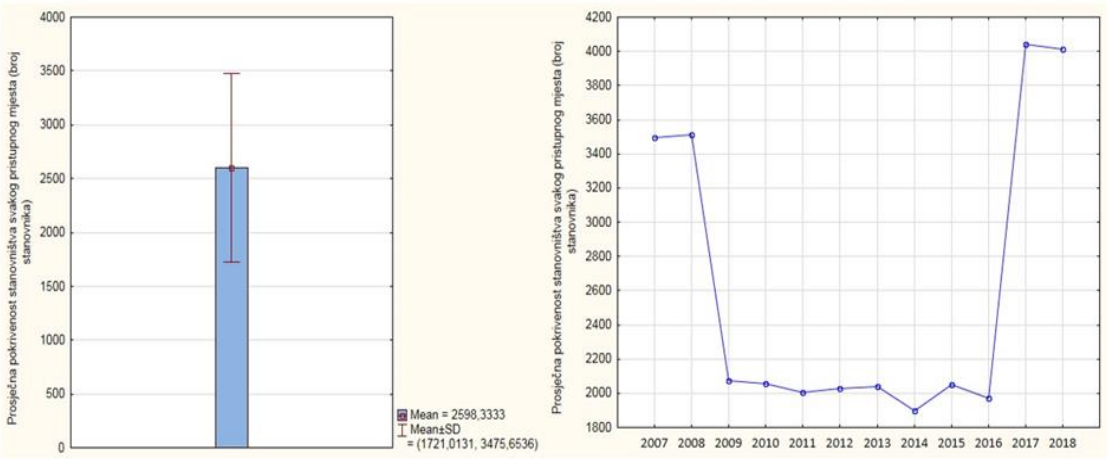

Slika 39. Pokrivenost stanovništva svakog pristupnog mjesta

- Prosječna vrijednost ukupnih ulaganja operatora elektroničkih komunikacija u RH u promatranom razdoblju iznosi 2,25 milijardi kuna s prosječnim odstupanjem od aritmetičke sredine 0,34 milijarde kuna, odnosno 340 milijuna kuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=15,05% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Nastankom ekonomske krize 2008. godine dolazi do pada ukupnih ulaganja operatora elektroničkih komunikacija u RH do 2011. kada dolazi do povećanja ukupnih ulaganja operatora elektroničkih komunikacija u RH. Do ponovnog smanjenja ulaganja opet dolazi 2014. godine, dok od 2015. ponovno dolazi do povećanja ukupnih ulaganja operatora elektroničkih komunikacija u RH. U 2018. dolazi do pada ulaganja. Za očekivati je da ova varijabla neće imati značajan utjecaj na broj paketskih pošiljaka što će se kasnije naknadno ispitati (Slika 40.).

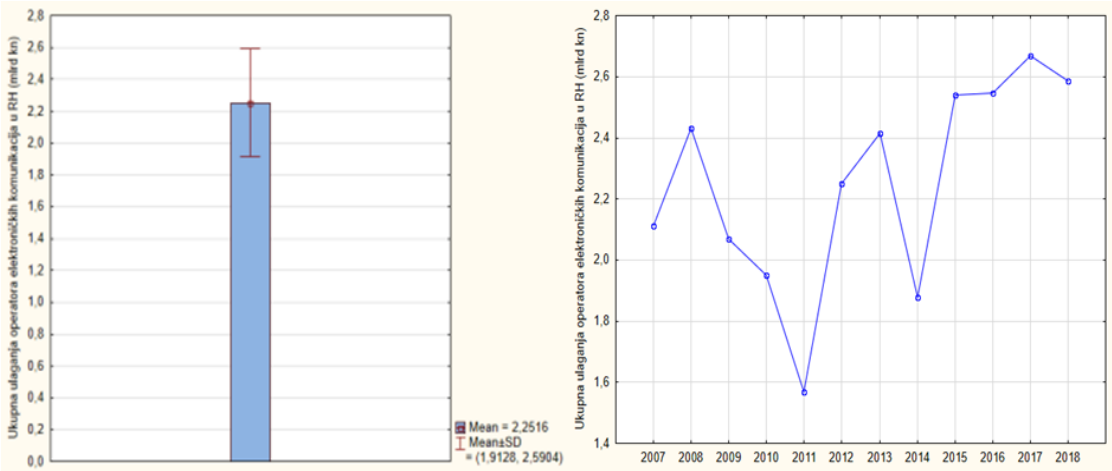

Slika 40. Ulaganja operatora elektroničkih komunikacija

- Prosječan broj registriranih pravnih osoba u promatranom razdoblju 275.610 s prosječnim odstupanjem od aritmetičke sredine iznosi 19.110. Riječ je o manjoj disperziji u promatranom razdoblju (V=6,93% < 30%). Može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Može se uočiti da je u promatranom razdoblju broj registriranih pravnih osoba usprkos svjetskoj krizi rastao, s iznimkom u 2013. te u 2016. kada dolazi do naglog pada broja registriranih pravnih osoba koji se nastavio do 2018. kada opet počinje njihov rast. Minimalan broj registriranih pravnih osoba iznosio je 252.650 dok je maksimalan iznosio 312.350 (Slika 41.).

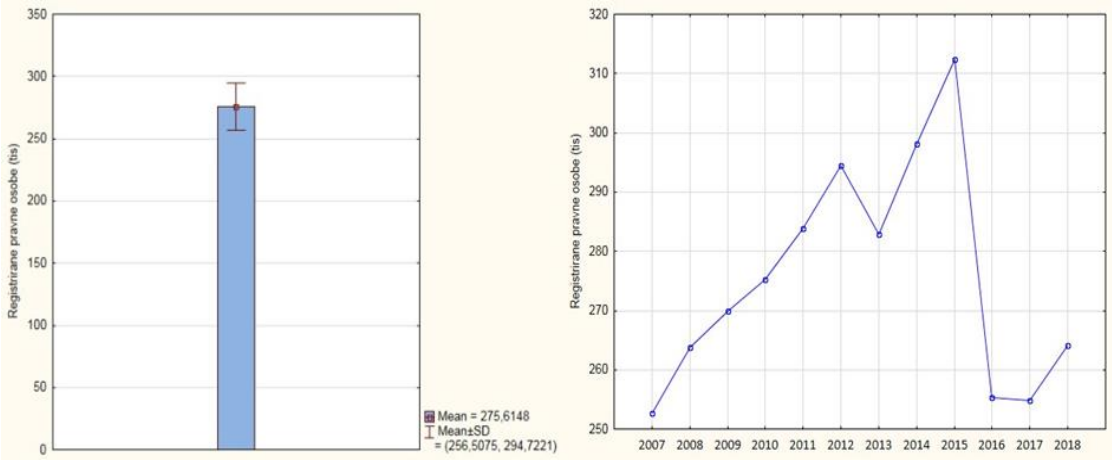

Slika 41. Pravne osobe

- Prosječan broj obrta i slobodnih zanimanja u promatranom razdoblju je 87.030 s prosječnim odstupanjem od aritmetičke sredine 8.580. Riječ je o manjoj disperziji u promatranom razdoblju (V=9,86% < 30%). Dakle može se utvrditi da su postojale manje varijacije u promatranom razdoblju odnosno nije došlo do značajnijih promjena u broju obrta i slobodnih zanimanja. U promatranom razdoblju od 2008. utvrđen je trend smanjenja broja obrta i slobodnih zanimanja, s iznimkom u 2017. i 2018., što nije u skladu s povećanjem broja paketskih pošiljaka. Za očekivati je da će se smanjenjem broja obrta i slobodnih zanimanja smanjivati i broj paketskih pošiljaka, a što se u ovom slučaju ne događa. Stoga se može zaključiti da je ovdje riječ o slučajnim kretanjima (Slika 42.).

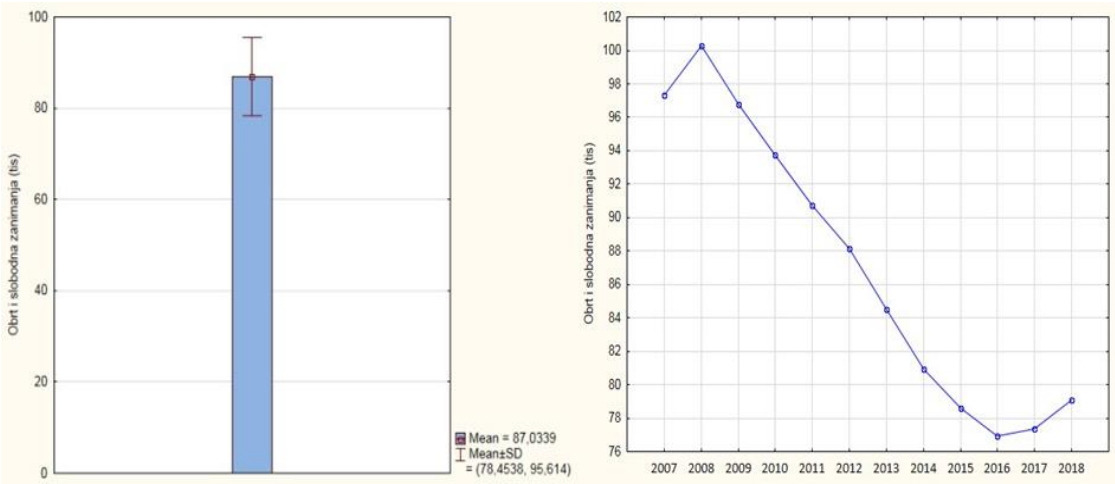

Slika 42. Obrt i slobodna zanimanja

- Prosječan broj kućanstava s pristupom Internetu u promatranom razdoblju je 893.040 s prosječnim odstupanjem od aritmetičke sredine 162.880. Riječ je o manjoj disperziji u promatranom razdoblju (V=18,24% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. U promatranom razdoblju utvrđen je trend povećanja broja kućanstava s pristupom Internetu, s iznimkom u 2014. i 2017., što je u skladu s povećanjem broja paketskih pošiljaka. Stoga se očekuje da će ova varijabla značajno utjecati na broj paketskih pošiljaka što će se dodatno ispitati regresijskom i korelacijskom analizom (Slika 43.).

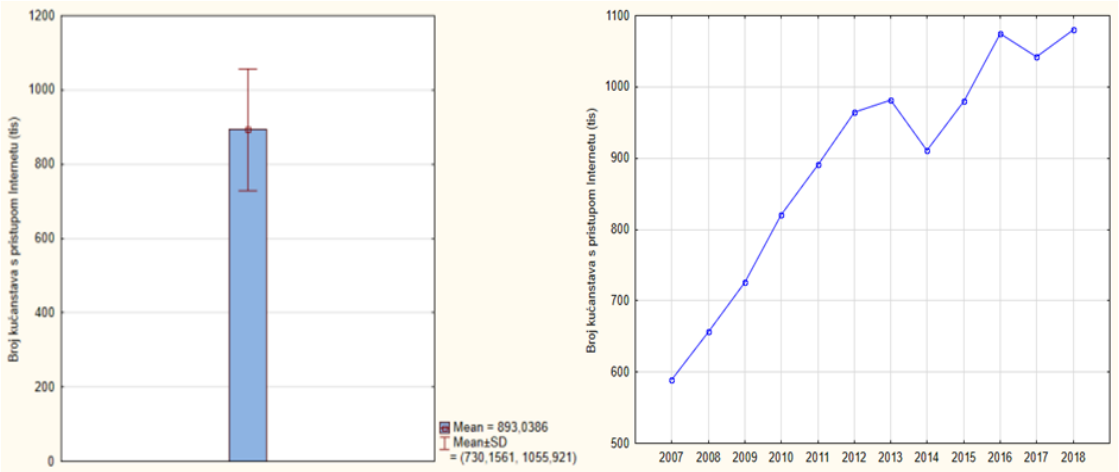

Slika 43. Kućanstva s pristupom Internetu

- Prosječan broj osoba koje su kupovale dobra ili usluge putem Interneta u promatranom razdoblju je 540.850 s prosječnim odstupanjem od aritmetičke sredine 297.470 osoba. Riječ je o velikoj disperziji u promatranom razdoblju (V=55,00% > 30%). Dakle, može se utvrditi da su postojale velike varijacije u promatranom razdoblju u broju osoba koje su kupovale dobra ili usluge putem Interneta. U promatranom razdoblju utvrđen je trend povećanja broja osoba koje su kupovale dobra ili usluge putem Interneta s iznimkom u 2016. i 2017. godini (Slika 44.).

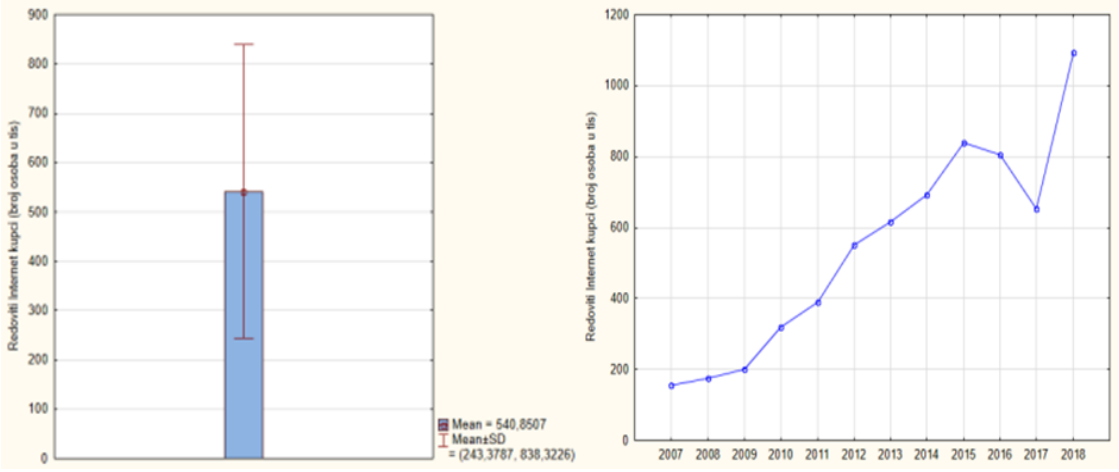

Slika 44. Internet kupci

- Prosječna gustoća stanovništva na 1 km^2 u promatranom razdoblju je 75,81 s prosječnim odstupanjem od aritmetičke sredine 2,30. Riječ je o manjoj disperziji u promatranom razdoblju (V=3,03% < 30%). Dakle, može se utvrditi da su postojale

manje varijacije u promatranom razdoblju, odnosno nije došlo do značajnijih promjena u gustoći stanovništva na 1 km^2. U promatranom razdoblju utvrđen je trend smanjenja gustoće stanovništva na 1 km^2 što nije u skladu s povećanjem broja paketskih pošiljaka (Slika 45.).

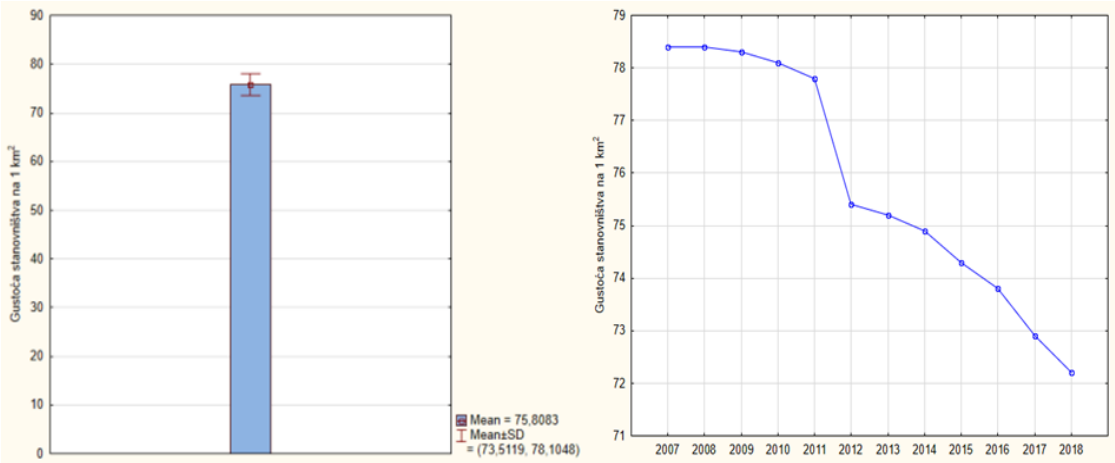

Slika 45. Gustoća stanovništva na 1 km^2

- Prosječan godišnji raspoloživi dohodak po kućanstvu u promatranom razdoblju je 84.380 kuna s prosječnim odstupanjem od aritmetičke sredine 6.090 kuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=7,21% < 30%). Može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Može se uočiti da je u promatranom razdoblju prosječan godišnji raspoloživi dohodak po kućanstvu usprkos svjetskoj krizi rastao do 2010. i onda počeo padati do 2013. Od 2014. dolazi do njegovog ponovnog rasta. Minimalan prosječan godišnji raspoloživi dohodak po kućanstvu iznosio je 77.440 kuna, dok je maksimalan iznosio 97.870 kuna (Slika 46.).

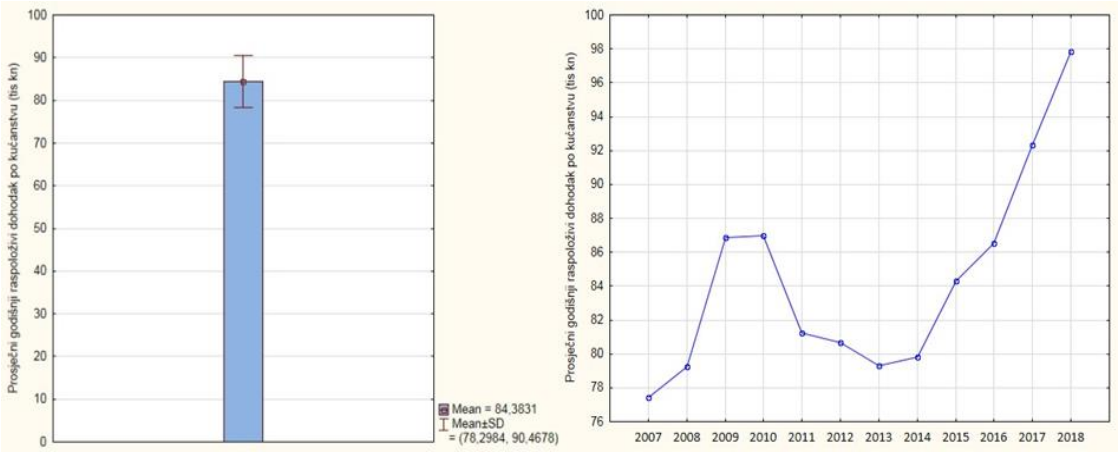

Slika 46. Godišnji raspoloživi dohodak po kućanstvu

- Iz grafičkog prikaza se može utvrditi da je prosječna vrijednosti indeksa potrošačkih cijena za poštanske usluge 103,03 s prosječnim odstupanjem od aritmetičke sredine 6,82. Riječ je o manjoj disperziji u promatranom razdoblju (V=6,62% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju (Slika 47.).

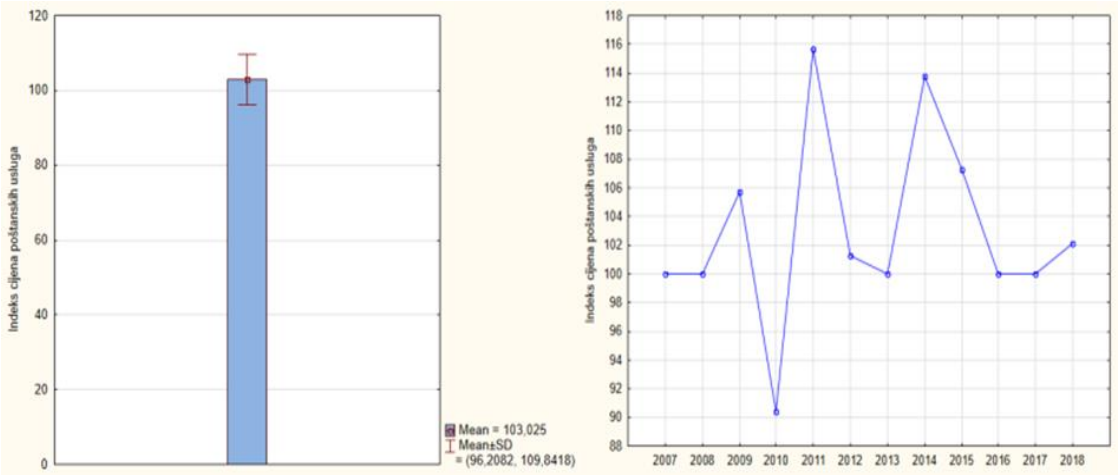

Slika 47. Indeks potrošačkih cijena za poštanske usluge

- Prosječna vrijednosti prodanih industrijskih proizvoda 126,83 milijardi kuna s prosječnim odstupanjem od aritmetičke sredine 7,16 milijarde kuna. Riječ je o manjoj disperziji u promatranom razdoblju (V=5,64% < 30%). Dakle, može se utvrditi da su postojale manje varijacije u promatranom razdoblju. Kao i kod većine varijabli svjetska kriza uzrokuje pad vrijednosti industrijskih proizvoda koje su prodala poduzeća što su se bavila industrijskom proizvodnjom. U promatranom razdoblju od

2007. do 2016. maksimalna vrijednost ostvarena je 2008. i iznosila je 134,40 milijardi kuna dok je minimalna vrijednost ostvarena 2009. i iznosila je 116,94 milijardi kuna. Od 2009. do 2012. rasla je vrijednost prodanih industrijskih proizvoda. Od 2013. do 2016. opet dolazi do pada vrijednosti prodanih industrijskih proizvoda s iznimkom u 2015. Od 2016. ponovno dolazi do rasta vrijednosti prodanih industrijskih proizvoda kada je dostignuta vrijednost iz 2008. (Slika 48.).

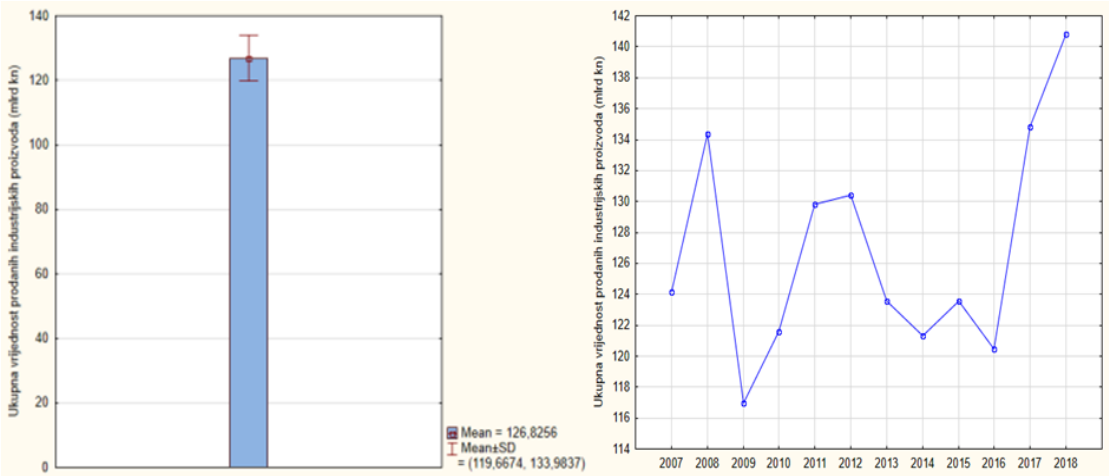

Slika 48. Vrijednost prodanih industrijskih proizvoda

- U promatranom razdoblju ostvaren je promet paketskim pošiljkama u prosjeku 11.768.330 paketskih pošiljaka s prosječnim odstupanjem od aritmetičke sredine 4.992.890. Dakle, utvrđene su velike disperzije u promatranom razdoblju (V=42,43%>30%). Značajnije odstupanje od prosječne vrijednosti posljedica je postojanja trenda u kretanju. Nastankom svjetske krize došlo je do pada broja paketskih pošiljaka, ali već 2010. dolazi do ponovnog pozitivnog trenda u kretanju broja paketskih pošiljaka koji se nastavio kroz čitavo promatrano razdoblje. U promatranom razdoblju minimalna vrijednost broja paketskih pošiljaka iznosila je 6.461.000 komada dok je maksimalna vrijednost iznosila 20.950.000 komada (Slika 49.).

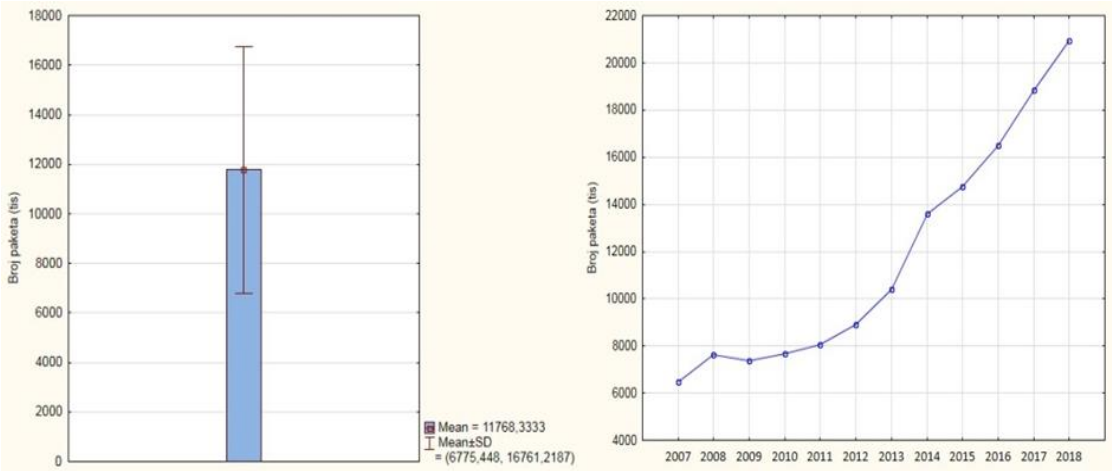

Slika 49. Paketske pošiljke

4.1.2. Polazne pretpostavke linearnog regresijskog modela

U nastavku rada testira se utjecaj nezavisnih ekonomskih, tehničko-tehnoloških, poštanskih i demografski varijabli na promet paketskim pošiljkama. Varijabla broj paketskih pošiljaka ima tendenciju porasta u promatranom razdoblju, zbog čega se procjenjuje model s trend kompomentom. Trend komponenta predstavlja varijablu vremena s vrijednostima t = 0, 1, 2, 3, 4, 5, 6, …. T.

Broj paketskih pošiljaka = f(trend, broj dolazaka turista, broj noćenja turista, procjena ukupnog broja stanovnika, uvoz, izvoz, prosječna neto plaća po zaposlenom, bruto nacionalni dohodak po stanovniku, prosječan broj zaposlenih, prosječan broj nezaposlenih, bruto domaći proizvod po stanovniku, bruto investicije, bruto dodana vrijednost, obiteljske naknade, broj pristupnih mjesta, prostorna pokrivenost pristupnih mjesta, broj telefonskih linija nepokretne mreže, redoviti Internet kupci, broj zaposlenih kod davatelja poštanskih i kurirskih usluga, broj poštanskih pretinaca, ukupan prihod od obavljanja poštanskih usluga, prosječna pokrivenost stanovništva svakog pristupnog mjesta, korisnici pokretne mreže, ukupna ulaganja operatora elektroničkih komunikacija u RH, registrirane pravne osobe, obrt i slobodna zanimanja, broj kućanstva s pristupom Internetu, gustoća stanovništva na 1 km^2, prosječni godišnji raspoloživi dohodak po kućanstvu, indeks cijena poštanskih usluga, ukupna vrijednost prodanih industrijskih proizvoda).

Temeljem dosadašnjih spoznaja o poštanskom prometu paketskim pošiljkama u tablici 5. dane su polazne pretpostavke linearnog regresijskog modela gdje je preliminarno procijenjen

očekivani utjecaj svake pojedine varijable. Utjecaj svake nezavisne varijable će se detaljno istražiti korelacijskom i regresijskom analizom.

Tablica 5. Polazne pretpostavke linearnog regresijskog modela

Varijabla	**Jedinica mjere**	**Očekivan utjecaj**
Trend	Godišnje razdoblje	+
Broj dolazaka turista	U milijunima turista	+
Broj noćenja turista	U milijunima noćenja	+
Procjena ukupnog broja stanovnika	U milijunima stanovnika	+
Uvoz	Mlrd. Kn	+
Izvoz	Mlrd. Kn	+
Prosječna neto plaća po zaposlenom	Kuna	+
Bruto nacionalni dohodak po stanovniku	USD	+
Prosječan broj zaposlenih	U milijunima zaposlenih	+
Prosječan broj nezaposlenih	U tisućama nezaposlenih	-
BDP po stanovniku	Kuna	+
Bruto investicije	Mlrd. Kn	+
Bruto dodana vrijednost	Kuna	+
Obiteljske naknade	Mlrd. Kn	+
Broj pristupnih mjesta	Broj mjesta	+
Broj zaposlenih kod davatelja poštanskih i kurirskih usluga	Broj zaposlenih	+
Broj poštanskih pretinaca	Broj pretinaca	+
Ukupan prihod od obavljanja poštanskih usluga	Mlrd. Kn	+
Prostorna pokrivenost pristupnih mjesta	Km^2/pristupno mjesto	+
Broj telefonskih linija nepokretne mreže	U milijunima linija	+
Korisnici pokretne mreže	U milijunima korisnika	+
Prosječna pokrivenost stanovništva svakog pristupnog mjesta	Stanovnici/pristupno mjesto	+
Ukupna ulaganja operatora elektroničkih komunikacija u RH	Mlrd. Kn	+
Registrirane pravne osobe	U tisućama pravnih osoba	+
Obrt i slobodna zanimanja	U tisućama fizičkih osoba	+
Broj kućanstva s pristupom Internetu	U tisućama kućanstva	+
Redoviti Internet kupci	U tisućama kupaca	+
Gustoća stanovništva na 1 km^2	Stanovnici/km^2	+
Prosječni godišnji raspoloživi dohodak po kućanstvu	Kuna	+
Indeks cijena poštanskih usluga	-	-
Ukupna vrijednost prodanih industrijskih proizvoda	Mlrd. Kn	+

Iz polaznih pretpostavki može se utvrditi da se očekuje pozitivan utjecaj na kretanje broja paketskih pošiljaka od strane skoro svih varijabli izuzev broja nezaposlenih i kretanja cijena

poštanskih usluga gdje se očekuje da će porast vrijednosti ovih varijabli posljedično imati pad broja paketskih pošiljaka.

4.1.3. Korelacijska analiza

U prvom koraku analize testira se povezanost između broja paketskih pošiljaka i odabranih nezavisnih varijabli. Povezanost sa zavisnom varijablom broj paketskih pošiljaka se testira Pearsonovom korelacijom. Na pojedinim mjestima radi preglednijeg prikaza korištene su skraćenice varijabli prikazane u tablici 6.

Tablica 6. Skraćenice naziva varijabli

Naziv varijable	**Oznaka**
Trend	Trend
Broj dolazaka turista	Dolasci
Broj noćenja turista	Noćenja
Procjena ukupnog broja stanovnika	Stanovništvo
Uvoz	Uvoz
Izvoz	Izvoz
Prosječna neto plaća po zaposlenom	Plaća
Bruto nacionalni dohodak po stanovniku	BND po stanovniku
Prosječan broj zaposlenih	Zaposleni
Prosječan broj nezaposlenih	Nezaposleni
BDP po stanovniku	BDP po stanovniku
Bruto investicije	Investicije
Bruto dodana vrijednost	BDV
Obiteljske naknade	Naknade
Broj pristupnih mjesta	Pristupna mjesta
Broj zaposlenih kod davatelja poštanskih i kurirskih usluga	Zaposleni kod davatelja
Broj poštanskih pretinaca	Pretinci
Ukupan prihod od obavljanja poštanskih usluga	Prihod davatelja
Prostorna pokrivenost pristupnih mjesta	Prostorna pokrivenost
Broj telefonskih linija nepokretne mreže	Telefonske linije
Korisnici pokretne mreže	Pokretna mreža
Prosječna pokrivenost stanovništva svakog pristupnog mjesta	Pokrivenost stanovništva
Ukupna ulaganja operatora elektroničkih komunikacija u RH	Ulaganja operatora
Registrirane pravne osobe	Pravne osobe
Obrt i slobodna zanimanja	Obrt
Broj kućanstva s pristupom Internetu	Kućanstva s Internetom
Redoviti Internet kupci	Internet kupci
Gustoća stanovništva na 1 km^2	Gustoća stanovnika
Prosječni godišnji raspoloživi dohodak po kućanstvu	Dohodak
Indeks cijena poštanskih usluga	ICPU
Ukupna vrijednost prodanih industrijskih proizvoda	Industrija

Tablica 7. Pearsonova korelacija između broja paketskih pošiljaka i odabranih varijabli

Varijabla	Koeficijent korelacije	P
Trend	0,9336	<0,001
Dolasci	0,9628	<0,001
Noćenja	0,9644	<0,001
Stanovništvo	-0,9783	<0,001
Uvoz	0,4706	0,170
Izvoz	0,9196	<0,001
Plaća	0,8032	0,005
BND po stanovniku	-0,5892	0,073
Zaposleni	-0,5459	0,103
Nezaposleni	0,0169	0,963
BDP po stanovniku	0,7816	0,008
Investicije	-0,4330	0,211
BDV	0,1792	0,620
Naknade	-0,8739	0,001
Pristupna mjesta	0,4797	0,161
Zaposleni kod davatelja	-0,7054	0,023
Pretinci	0,4098	0,240
Prihod davatelja	0,0154	0,966
Prostorna pokrivenost	-0,4714	0,169
Telefonske linije	-0,8626	0,001
Pokretna mreža	-0,7609	0,011
Pokrivenost stanovništva	-0,4967	0,144
Ulaganja operatora	0,4588	0,182
Pravne osobe	0,3447	0,329
Obrt	-0,9374	<0,001
Kućanstva s Internetom	0,7769	0,008
Internet kupci	0,9277	<0,001
Gustoća stanovnika	-0,9141	<0,001
Dohodak	0,2843	0,426
ICPU	0,2321	0,519
Industrija	-0,3249	0,360

Iz tablice 7. može se utvrditi postojanje statistički značajne povezanosti ($p<0,05$) između broja paketskih pošiljaka i sljedećih nezavisnih varijabli:

- Trend - jaka pozitivna veza koja je statistički značajna,
- Dolasci (mil) - jaka pozitivna veza koja je statistički značajna,
- Noćenja (mil) - jaka pozitivna veza koja je statistički značajna,
- Stanovništvo (mil) - jaka negativna veza koja je statistički značajna,
- Izvoz (mlrd kn) - jaka pozitivna veza koja je statistički značajna,
- Plaća (kn) - jaka pozitivna veza koja je statistički značajna,

- BND po stanovniku (USD) - srednje jaka negativna veza koja je statistički značajna, ali pri razini signifikantnosti od 10%
- BDP po stanovniku (kn) - srednje jaka pozitivna veza koja je statistički značajna,
- Telefonske linije (mil) - jaka negativna veza koja je statistički značajna,
- Pokretna mreža (mil) - srednje jaka negativna veza koja je statistički značajna,
- Obrt (tis) - jaka negativna veza koja je statistički značajna,
- Kućanstva s Internetom (tis) - srednje jaka pozitivna veza koja je statistički značajna,
- Internet kupci (tis) - jaka pozitivna veza koja je statistički značajna,
- Obiteljske naknade (mlrd kn) - jaka negativna veza koja je statistički značajna,
- Zaposleni kod davatelja - srednje jaka negativna veza koja je statistički značajna,
- Gustoća stanovnika - jaka negativna veza koja je statistički značajna.

Utvrđeno je i postojanje korelacija između broja paketskih pošiljaka i nezavisnih ekonomskih varijabli koje nisu statistički značajne:

- Zaposleni (mil) - srednje jaka negativna veza koja nije statistički značajna,
- Uvoz (mlrd kn) - slaba pozitivna veza koja nije statistički značajna,
- Nezaposleni (tis) - odsustvo povezanosti, veza nije statistički značajna,
- Investicije (mlrd kn) - srednje jaka negativna veza koja nije statistički značajna,
- BDV (kn) - slaba pozitivna veza koja nije statistički značajna,
- Pristupna mjesta - slaba pozitivna veza koja nije statistički značajna,
- Prostorna pokrivenost (km^2) - slaba negativna veza koja nije statistički značajna,
- Ulaganja operatora (mlrd kn) - slaba pozitivna veza koja nije statistički značajna,
- Pravne osobe (tis) - slaba pozitivna veza koja nije statistički značajna,
- Dohodak (kn) - slaba pozitivna veza koja nije statistički značajna,
- ICPU - slaba pozitivna veza koja nije statistički značajna,
- Pretinci - slaba pozitivna veza koja nije statistički značajna,
- Prihod davatelja - odsustvo povezanosti, veza koja nije statistički značajna,
- Pokrivenost stanovništva - slaba negativna veza koja nije statistički značajna,
- Industrija (mlrd kn) - slaba negativna veza koja nije statistički značajna.

U nastavku je dan grafički prikaz svih izračunatih korelacija između zavisne varijable paketske pošiljke i svih nezavisnih varijabli (Slika 50.).

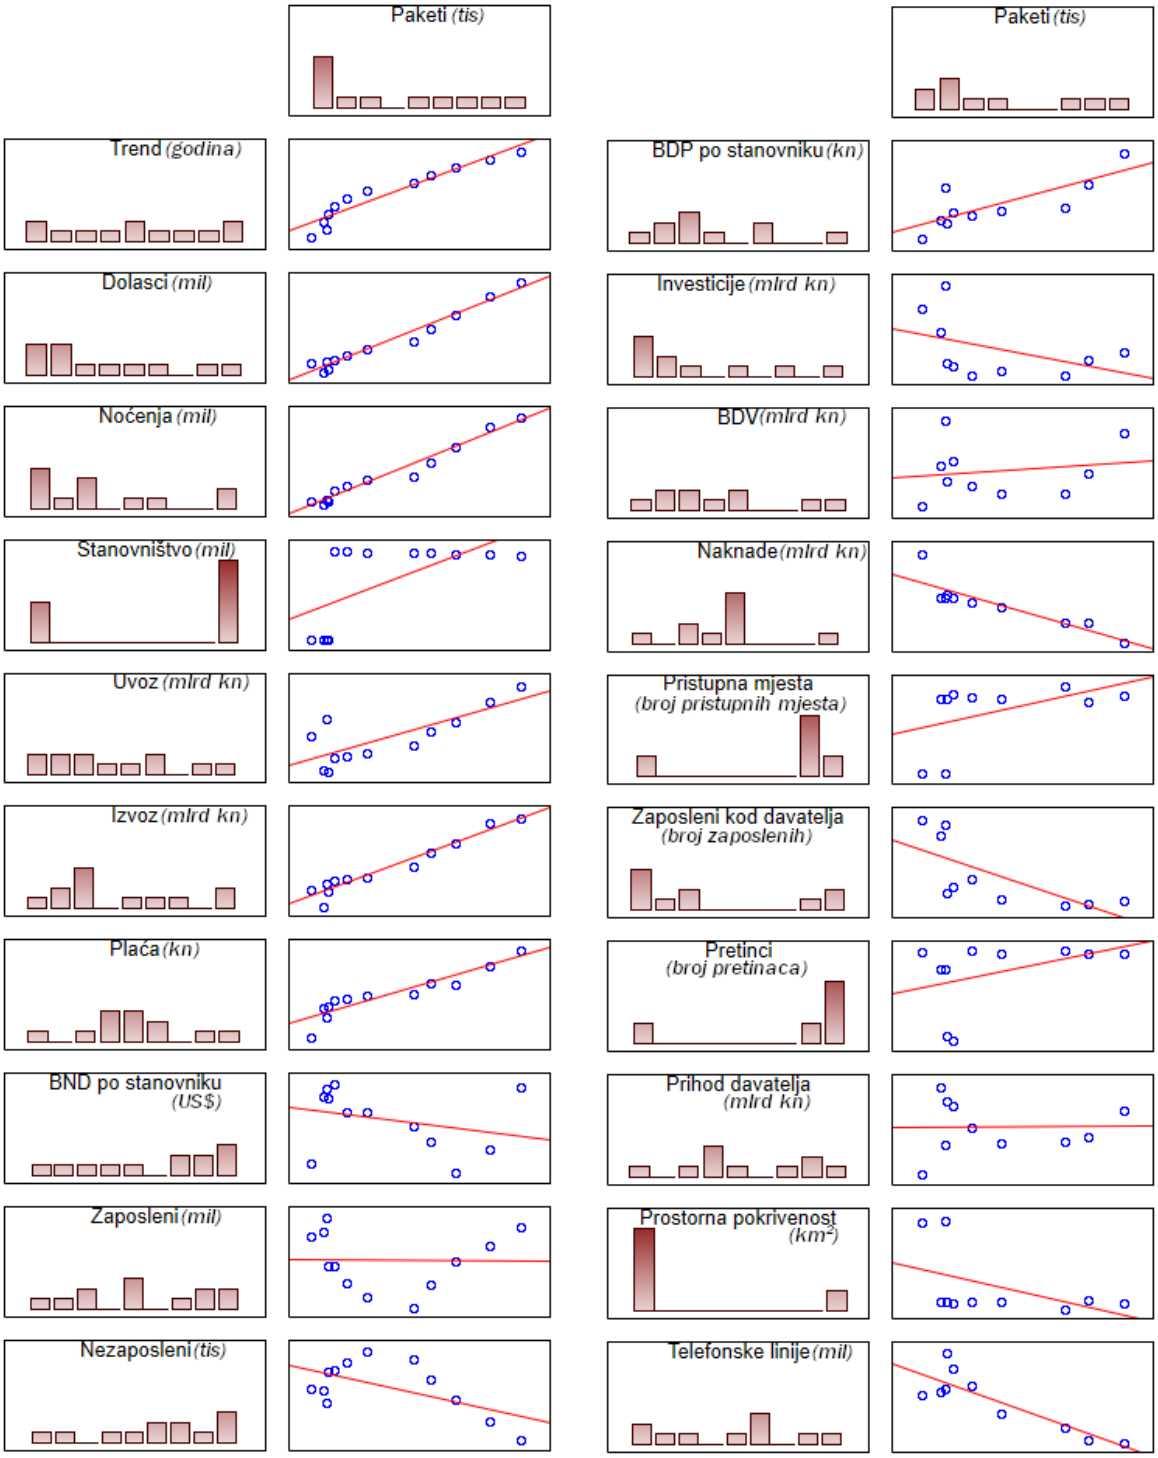
Paketi (tis)
Paketi (tis)
Trend (godina)
BDP po stanovniku (kn)
Dolasci (mil)
Investicije (mlrd kn)
Noćenja (mil)
BDV (mlrd kn)
Stanovništvo (mil)
Naknade (mlrd kn)
Uvoz (mlrd kn)
Pristupna mjesta (broj pristupnih mjesta)
Izvoz (mlrd kn)
Zaposleni kod davatelja (broj zaposlenih)
Plaća (kn)
Pretinci (broj pretinaca)
BND po stanovniku (US$)
Prihod davatelja (mlrd kn)
Zaposleni (mil)
Prostorna pokrivenost (km²)
Nezaposleni (tis)
Telefonske linije (mil)

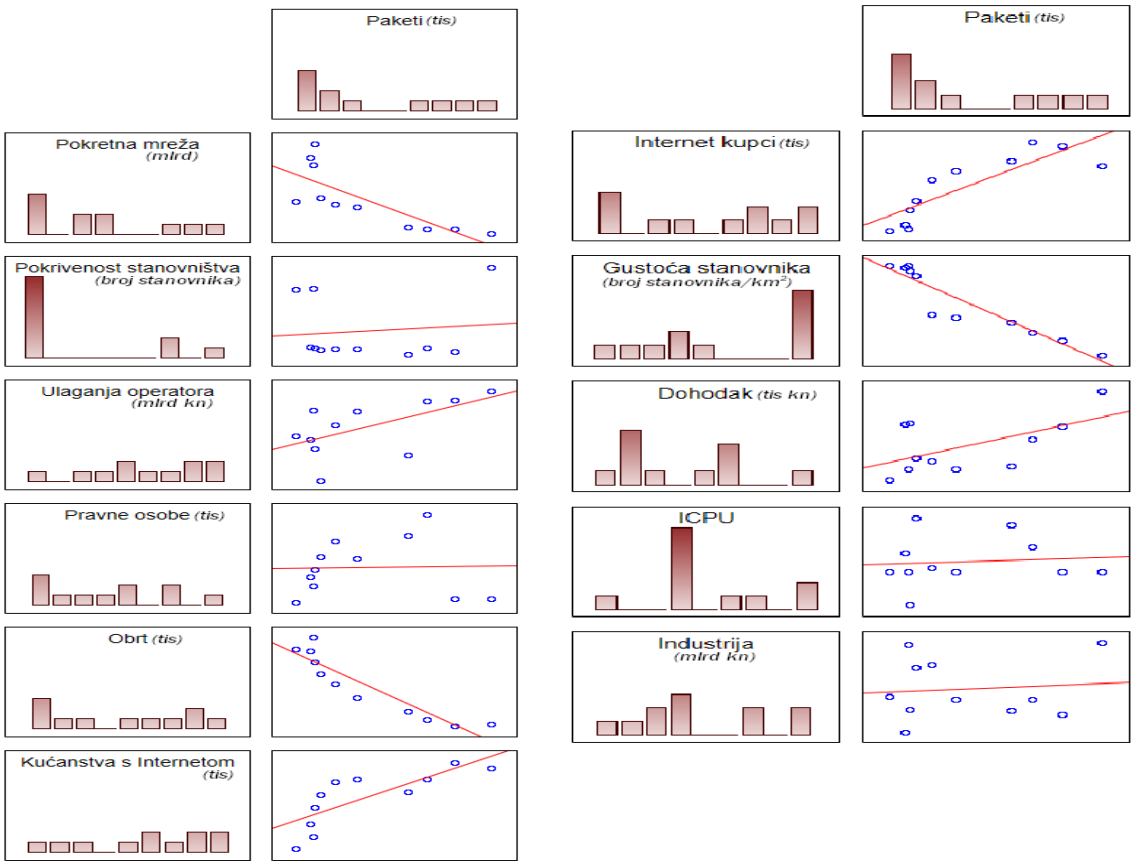

Slika 50. Grafički prikaz korelacija između paketskih pošiljaka i nezavisnih varijabli

Ovdje se na grafikonima nalaze linearni regresijski pravci (crveni pravac) međusobnih utjecaja promatranih varijabli. Veliko pozicioniranje točaka oko pravaca regresije upućuje na visoku korelaciju i linearnu funkcijsku vezu između promatranih varijabli dok veća raspršenost točaka oko regresijskih pravaca upućuje na niži stupanj koreliranosti između nezavisnih varijabli. Histogrami frekvencija nezavisnih slučajnih varijabli prikazani su u lijevom stupcu grafikona. U gornjem dijelu grafikona dan je histogram frekvencija zavisne slučajne varijable, odnosno paketskih pošiljaka. Zatim su pomoću dijagrama raspršenosti grafički prikazane dobivene korelacije između broja paketskih pošiljaka i ostalih nezavisnih varijabli. Na dijagramima je ucrtan pravac linearne regresije (crveni) koji ukazuje na smjer korelacije. Rastući pravci ukazuju na pozitivnu korelaciju dok padajući pravci ukazuju na negativnu korelaciju.

Zatim je napravljena matrica korelacije između svih nezavisnih varijabli (Tablica 8.). Iz matrice korelacija može se uočiti da postoji statistički značajna korelacija između skupina varijabli (Pearsonov koeficijent korelacija označen je s r dok je njegova statistička značajnost označena s p). Korelacije nisu statistički značajne kada je $p>0,05$.

Tablica 8. Matrica korelacije između odabranih varijabli

	Trend	Dolasci	Noćenja	Stanovništvo	Uvoz	Izvoz	Plaća	BND po stanovniku	Zaposleni	Nezaposleni	BDP po stanovniku	Investicije	BDV	Naknade	Pristupna mjesta	Zaposleni kod davatelja	Pretinci	Prihod davatelja	Prostorna pokrivenost	Telefonske linije	Pokretna mreža	Pokrivenost stanovništva	Ulaganja operatora	Pravne osobe	Obrt	Kućanstva s Internetom	Internet kupci	Gustoća stanovnika	Dohodak	ICPU	Industrija	Paketi
	1,000																															
Trend	p= ---																															
	0,882	1,000																														
Dolasci	p=,001	p= ---																														
	0,935	0,987	1,000																													
Noćenja	p=,000	p=,000	p= ---																													
	0,846	0,691	0,756	1,000																												
Stanovništvo	p=,002	p=,027	p=,011	p= ---																												
	0,213	0,615	0,504	0,124	1,000																											
Uvoz	p=,555	p=,059	p=,138	p=,733	p= ---																											
	0,856	0,973	0,956	0,715	0,637	1,000																										
Izvoz	p=,002	p=,000	p=,000	p=,020	p=,048	p= ---																										
	0,932	0,710	0,794	0,787	0,024	0,695	1,000																									
Plaća	p=,000	p=,021	p=,006	p=,007	p=,948	p=,026	p= ---																									
	-0,405	-0,690	-0,622	-0,213	-0,558	-0,621	-0,085	1,000																								
ND po stanovni	p=,246	p=,027	p=,055	p=,555	p=,093	p=,055	p=,815	p= ---																								
	-0,737	-0,457	-0,524	-0,798	0,201	-0,482	-0,668	0,133	1,000																							
Zaposleni	p=,015	p=,184	p=,120	p=,006	p=,578	p=,159	p=,035	p=,714	p= ---																							
	0,301	-0,069	0,020	0,539	-0,551	-0,026	0,320	0,263	-0,841	1,000																						
Nezaposleni	p=,399	p=,850	p=,957	p=,108	p=,099	p=,944	p=,368	p=,463	p=,002	p= ---																						
	0,670	0,813	0,806	0,420	0,664	0,798	0,650	-0,342	-0,049	-0,409	1,000																					
DP po stanovni	p=,034	p=,004	p=,005	p=,227	p=,036	p=,006	p=,042	p=,334	p=,894	p=,241	p= ---																					
	-0,698	-0,332	-0,446	-0,753	0,473	-0,346	-0,715	0,002	0,896	-0,795	-0,009	1,000																				
Investicije	p=,025	p=,349	p=,196	p=,012	p=,168	p=,327	p=,020	p=,996	p=,000	p=,006	p=,981	p= ---																				
	0,057	0,218	0,206	-0,102	0,471	0,228	0,194	0,158	0,523	-0,694	0,734	0,436	1,000																			
BDV	p=,875	p=,545	p=,569	p=,779	p=,169	p=,526	p=,592	p=,663	p=,121	p=,026	p=,016	p=,208	p= ---																			
	-0,897	-0,784	-0,839	-0,660	-0,245	-0,747	-0,927	0,181	0,486	-0,062	-0,826	0,490	-0,418	1,000																		
Naknade	p=,000	p=,007	p=,002	p=,038	p=,495	p=,013	p=,000	p=,617	p=,154	p=,865	p=,003	p=,151	p=,229	p= ---																		
	0,708	0,321	0,447	0,639	-0,517	0,279	0,805	0,098	-0,720	0,580	0,161	-0,908	-0,175	-0,651	1,000																	
Pristupna mjest	p=,022	p=,366	p=,195	p=,047	p=,126	p=,434	p=,005	p=,788	p=,019	p=,079	p=,656	p=,000	p=,628	p=,041	p= ---																	
	-0,877	-0,618	-0,699	-0,788	0,129	-0,650	-0,864	0,138	0,871	-0,592	-0,377	0,887	0,155	0,732	-0,824	1,000																
osleni kod dava	p=,001	p=,057	p=,025	p=,007	p=,723	p=,042	p=,001	p=,704	p=,001	p=,071	p=,283	p=,001	p=,669	p=,016	p=,003	p= ---																
	0,267	0,445	0,395	0,196	0,515	0,333	0,076	-0,574	-0,131	-0,089	0,244	0,144	-0,122	-0,188	-0,179	0,110	1,000															
Pretinci	p=,456	p=,198	p=,259	p=,588	p=,128	p=,347	p=,835	p=,083	p=,719	p=,806	p=,496	p=,691	p=,738	p=,604	p=,621	p=,763	p= ---															
	0,153	-0,121	-0,010	-0,014	-0,568	-0,174	0,404	0,411	0,072	-0,057	0,152	-0,316	0,353	-0,372	0,625	-0,246	-0,537	1,000														
Prihod davatelj	p=,673	p=,740	p=,978	p=,969	p=,087	p=,630	p=,246	p=,238	p=,843	p=,876	p=,676	p=,374	p=,317	p=,290	p=,053	p=,493	p=,110	p= ---														
	-0,704	-0,316	-0,444	-0,629	0,526	-0,272	-0,808	-0,099	0,706	-0,569	-0,163	0,903	0,170	0,645	-0,998	0,818	0,183	-0,639	1,000													
storna pokrive	p=,023	p=,373	p=,198	p=,051	p=,118	p=,447	p=,005	p=,785	p=,023	p=,086	p=,653	p=,000	p=,638	p=,044	p=,000	p=,004	p=,612	p=,047	p= ---													
	-0,714	-0,866	-0,824	-0,518	-0,625	-0,765	-0,521	0,700	0,356	0,110	-0,643	0,128	-0,081	0,627	-0,163	0,352	-0,749	0,288	0,157	1,000												
Telefonske linij	p=,020	p=,001	p=,003	p=,125	p=,053	p=,010	p=,122	p=,024	p=,313	p=,763	p=,045	p=,725	p=,825	p=,052	p=,652	p=,319	p=,013	p=,420	p=,665	p= ---												
	-0,737	-0,828	-0,809	-0,813	-0,500	-0,816	-0,506	0,665	0,601	-0,221	-0,435	0,414	0,174	0,484	-0,262	0,513	-0,541	0,405	0,246	0,800	1,000											
Pokretna mreža	p=,015	p=,003	p=,005	p=,004	p=,141	p=,004	p=,136	p=,036	p=,066	p=,540	p=,209	p=,234	p=,630	p=,156	p=,465	p=,129	p=,107	p=,246	p=,493	p=,005	p= ---											
	-0,724	-0,345	-0,471	-0,643	0,502	-0,300	-0,822	-0,076	0,712	-0,561	-0,187	0,904	0,162	0,663	-0,998	0,829	0,168	-0,630	1,000	0,182	0,269	1,000										
venost stanova	p=,018	p=,330	p=,170	p=,045	p=,140	p=,400	p=,004	p=,834	p=,021	p=,092	p=,605	p=,000	p=,656	p=,037	p=,000	p=,003	p=,643	p=,051	p=,000	p=,614	p=,453	p= ---										
	0,333	0,540	0,505	0,086	0,616	0,474	0,257	-0,462	0,063	-0,336	0,597	0,237	0,313	-0,356	-0,218	-0,007	0,679	-0,284	0,193	-0,618	-0,275	0,173	1,000									
laganja operato	p=,347	p=,107	p=,136	p=,814	p=,058	p=,166	p=,473	p=,179	p=,864	p=,342	p=,069	p=,509	p=,379	p=,312	p=,545	p=,986	p=,031	p=,426	p=,593	p=,057	p=,441	p=,633	p= ---									
	0,514	0,224	0,275	0,607	-0,217	0,292	0,613	0,204	-0,739	0,653	0,004	-0,659	-0,326	-0,376	0,567	-0,612	0,045	0,020	-0,565	-0,199	-0,369	-0,567	-0,065	1,000								
Pravne osobe	p=,129	p=,533	p=,442	p=,063	p=,547	p=,414	p=,060	p=,573	p=,015	p=,041	p=,990	p=,038	p=,357	p=,285	p=,088	p=,060	p=,902	p=,956	p=,089	p=,581	p=,294	p=,088	p=,858	p= ---								
	-0,982	-0,902	-0,938	-0,845	-0,248	-0,872	-0,856	0,528	0,767	-0,321	-0,596	0,690	0,073	0,812	-0,652	0,855	-0,330	-0,023	0,645	0,763	0,821	0,667	-0,318	-0,499	1,000							
Obrt	p=,000	p=,000	p=,000	p=,002	p=,489	p=,001	p=,002	p=,117	p=,010	p=,366	p=,069	p=,027	p=,841	p=,004	p=,041	p=,002	p=,351	p=,950	p=,044	p=,010	p=,004	p=,035	p=,370	p=,142	p= ---							
	0,944	0,744	0,837	0,877	0,022	0,736	0,934	-0,233	-0,748	0,426	0,576	-0,801	0,044	-0,838	0,788	-0,903	0,108	0,282	-0,790	-0,497	-0,615	-0,806	0,253	0,502	-0,899	1,000						
anstva s Intern	p=,000	p=,014	p=,003	p=,001	p=,952	p=,015	p=,000	p=,518	p=,013	p=,219	p=,082	p=,005	p=,904	p=,002	p=,007	p=,000	p=,766	p=,431	p=,007	p=,144	p=,058	p=,005	p=,481	p=,140	p=,000	p= ---						
	0,984	0,893	0,932	0,855	0,268	0,880	0,887	-0,466	-0,772	0,335	0,622	-0,680	-0,035	-0,830	0,633	-0,855	0,349	0,006	-0,630	-0,749	-0,798	-0,652	0,386	0,571	-0,988	0,913	1,000					
Internet kupci	p=,000	p=,000	p=,000	p=,002	p=,454	p=,001	p=,001	p=,175	p=,009	p=,344	p=,055	p=,030	p=,923	p=,003	p=,049	p=,002	p=,323	p=,987	p=,051	p=,013	p=,006	p=,041	p=,270	p=,084	p=,000	p=,000	p= ---					
	-0,951	-0,899	-0,933	-0,829	-0,334	-0,863	-0,821	0,538	0,727	-0,298	-0,623	0,605	0,042	0,802	-0,552	0,761	-0,519	0,084	0,547	0,807	0,824	0,570	-0,495	-0,480	0,961	-0,879	-0,975	1,000				
stoća stanovni	p=,000	p=,000	p=,000	p=,003	p=,346	p=,001	p=,004	p=,109	p=,017	p=,404	p=,054	p=,064	p=,909	p=,005	p=,098	p=,011	p=,124	p=,818	p=,102	p=,005	p=,003	p=,085	p=,146	p=,161	p=,000	p=,001	p=,000	p= ---				
	0,299	0,160	0,225	-0,103	-0,304	0,083	0,447	-0,007	0,080	-0,267	0,337	-0,221	0,327	-0,456	0,515	-0,292	-0,299	0,833	-0,539	-0,013	0,273	-0,540	0,084	-0,015	-0,210	0,313	0,194	-0,114	1,000			
Dohodak	p=,402	p=,659	p=,532	p=,778	p=,393	p=,820	p=,195	p=,984	p=,826	p=,455	p=,342	p=,539	p=,357	p=,185	p=,128	p=,414	p=,402	p=,003	p=,108	p=,972	p=,446	p=,107	p=,818	p=,968	p=,560	p=,378	p=,592	p=,754	p= ---			
	0,261	0,179	0,181	0,512	0,028	0,184	0,279	0,113	-0,289	0,207	0,055	-0,258	-0,027	-0,227	0,302	-0,186	0,008	0,032	-0,276	-0,262	-0,479	-0,277	-0,436	0,461	-0,279	0,174	0,249	-0,180	-0,230	1,000		
ICPU	p=,466	p=,622	p=,618	p=,131	p=,938	p=,611	p=,436	p=,756	p=,418	p=,567	p=,880	p=,473	p=,940	p=,528	p=,396	p=,608	p=,982	p=,930	p=,440	p=,465	p=,161	p=,438	p=,208	p=,180	p=,436	p=,630	p=,488	p=,618	p=,523	p= ---		
	-0,278	-0,182	-0,203	0,064	0,316	-0,007	-0,202	0,380	0,192	-0,023	0,041	0,280	0,311	0,215	-0,455	0,242	-0,137	-0,352	0,460	0,334	0,056	0,461	0,006	0,060	0,325	-0,167	-0,229	0,217	-0,581	0,058	1,000	
Industrija	p=,436	p=,616	p=,574	p=,861	p=,374	p=,985	p=,576	p=,278	p=,595	p=,949	p=,911	p=,433	p=,382	p=,550	p=,186	p=,501	p=,706	p=,319	p=,181	p=,346	p=,877	p=,180	p=,987	p=,870	p=,360	p=,645	p=,524	p=,548	p=,078	p=,873	p= ---	
	0,934	0,963	0,964	0,681	0,471	0,920	0,803	-0,589	-0,546	0,017	0,782	-0,433	0,179	-0,874	0,480	-0,705	0,410	0,015	-0,471	-0,863	-0,761	-0,497	0,459	0,345	-0,937	0,777	0,928	-0,914	0,284	0,232	-0,325	1,000
Paketi	p=,000	p=,000	p=,000	p=,030	p=,170	p=,000	p=,005	p=,073	p=,103	p=,963	p=,008	p=,211	p=,620	p=,001	p=,161	p=,023	p=,240	p=,966	p=,169	p=,001	p=,011	p=,144	p=,182	p=,329	p=,000	p=,008	p=,000	p=,000	p=,426	p=,519	p=,360	p= ---

Iz matrice korelacije može se zaključiti da postoje parovi nezavisnih varijabli koji su u gotovo funkcionalnoj vezi (aposlutne vrijednosti koeficijenata korelacije blizu vrijednosti 1) te parovi nezavisnih varijabli koji jako međusobno koreliraju (apsolutne vrijednosti koeficijenata korelacije veće od 0,80) što upućuje na mogući problem multikolinearnosti u regresijskoj analizi.

4.1.4. Regresijski model s trendom

Na temelju deskriptivne statističke analize u poglavlju 4.1.1. utvrđeno je ponašanje svake pojedine varijable. Također, načinjena je i korelacijska analiza te su analizirani Pearsonovi koeficijenti korelacija između varijable „paketske pošiljke“ i ostalih varijabli. S ciljem izgradnje višestrukog linearnog regresijskog modela načinjena je selekcija nezavisnih varijabli, koja je provedena u nekoliko koraka. U prvom koraku varijable su selekcionirane kako bi se izbjegla multikorelacija varijabli u regresijskom modelu. Izabrane su one varijable koje međusobno jako ne koreliraju (koeficijent korelacije <0,8). Također, izabrane su varijable koje statistički značajno koreliraju sa zavisnom varijablom „paketske pošiljke“. Sve preostale varijable detaljno su kvalitativno analizirane, te su na kraju izabrane one za koje se utvrdilo da realno utječu na broj paketskih pošiljaka.

Pomoću izabranih nezavisnih varijabli, upotrebom stepwise forward metode izgrađen je višestruki linearni regresijski model oblika:

Paketske pošiljke = f (Trend, Telefonske linije, BDP po stanovniku)+ε (10)

gdje je f linearna funkcija od 3 varijable dok je ε statistička pogreška.

Precizno su proračunati koeficijenti linearne regresijske jednadžbe

$$Paketi = \alpha + \beta_1 \cdot Trend + \beta_2 \cdot Telefonske\ linije + \beta_3 \cdot BDP\ po\ stanovniku \quad (11)$$

gdje $\alpha, \beta_i \in \mathbb{R}: i = 1, \dots, 3$.

Spomenuta metoda je primijenjena da bi se dobio model za prognoziranje broja paketskih pošiljaka sa što kvalitetnijim svojstvima. To se prvenstveno odnosi na model u kojem su sve varijable ispunjavale kriterije statističke značajnosti (p<0,05) i u kojem nije izražen problem multikolinearnosti (Tablica 9.).

Tablica 9. Forward regresijski postupak na godišnjim podatcima

Procijenjeni model						
	b*	**Std. pogreška od b***	**b**	**Std. pogreška od b**	**t(36)**	**p**
Intercept			-1226,81	7376,24	-0,17	0,872
Trend	0,48	0,08	666,03	114,69	5,81	<0,001
BDP po stanovniku	0,28	0,08	0,25	0,07	3,63	0,007
Telefonske linije	-0,30	0,08	-6785,92	1927,67	-3,52	0,008

Utvrđeno je da najveći utjecaj na broj paketskih pošiljaka ima varijabla trend gdje je apsolutna vrijednost standardiziranog parametra beta 0,48.

Varijabla trend ima regresijski koeficijent iznosa b=666,03, odnosno, modelom se procjenjuje godišnje povećanje broja paketskih pošiljaka u prosjeku za 666.030 paketskih pošiljaka. Promatrani utjecaj je statistički značajan s empirijskom p vrijednošću <0,001. Standardna pogreška regresijskog koeficijenta ove varijable je relativno mala i iznosi 114,69.

Regresijski koeficijent uz varijablu broj telefonskih linija nepokretne mreže (mil) iznosi b= -6.785,92. Ovaj koeficijent je statistički značajan s empirijskom p-vrijednošću p=0,008 < 0,050. Standardna pogreška regresijskog koeficijenta ove varijable iznosi 1.927,67. Povećanje broja telefonskih linija nepokretne mreže za jednu jedinicu uzrokovat će smanjenje broja paketskih pošiljaka u prosjeku za 6,79 paketa. To znači da će pad od milijun priključaka uzrokovati rast prometa od 6.786.920 paketskih pošiljaka. Naime u Republici Hrvatskoj dolazi do pada broja priključaka nepokretne mreže jer se ova vrsta mreže sve manje koristi za komunikaciju. Usprkos tome dolazi do porasta broja paketskih pošiljaka zbog povećanja broja priključaka širokopojasnog pristupa Internetu koji danas predstavlja glavni način komunikacije u prometu paketskim pošiljkama.

Varijabla BDP po stanovniku ima regresijski koeficijent iznosa b=0,25. Koeficijent je statistički značajan s empirijskom p-vrijednošću p=0,007<0,050. Porast BDP po stanovniku za jednu jedinicu uzrokovat će povećanje broja paketskih pošiljaka u prosjeku za 250 pošiljaka. To znači da će porast BDP po stanovniku od jedne kune uzrokovati rast prometa od 250 paketskih pošiljaka. Standardna pogreška regresijskog koeficijenta ove varijable iznosi 0,07.

Višestruka linearna regresijska jednadžba ima oblik:

$$\widehat{Paketi} = -1.226{,}81 + 666{,}03 \cdot Trend - 6.785{,}92 \cdot Telefonske\ linije + 0{,}250 \cdot BDP\ po\ stanovniku \quad (12)$$

U nastavku je izvršena validacija modela pomoću parametara ANOVE (Tablica 10.).

Tablica 10. ANOVA tablica svih efekata linearnog regresijskog modela

Procijenjeni model	
Statistika	**Vrijednosti**
R	0,993
Koef. determinacije R^2	0,986
Adjusted R^2	0,981
Fisher F	F(3,8)=190,33
P vrijednost modela	<0,001
Std. pogreška procjene	688,20

Reprezentativnost konačnog modela koji sadrži 3 varijable potvrđena je vrlo visokim koeficijentom determinacije koji iznosi čak $R^2 = 0{,}986$, što znači da je čak 98,6% kvadrata pogrešaka moguće protumačiti modelom, dok samo 1,4% otpada na rezidualno rasipanje. Prethodna validacija modela pokazuje njegovu vrlo visoku kvalitetu. Vrlo visoku vrijednost ima i korigirani koeficijent determinacije koji iznosi Adjusted R^2=0,981. Prema ovom parametru model tumači i dalje vrlo visokih 98,1% kvadrata pogrešaka. Fisherova F-statistika ovog modela ima vrijednost F(3,8)=190,33. P-vrijednost modela iznosi p<0,001 što pokazuje da je koeficijent determinacije R^2 statistički značajan, pa je i model statistički značajan. Standardna pogreška iznosi 688,20.

Između nezavisnih varijabli nema izraženog problema multikolinearnosti što je utvrđeno pomoću razine tolerancije (TOL). Izračunati su i pripadni koeficijenti determinacija za svaku pojedinu regresijsku varijablu. Prethodno spomenuti parametri navedeni su u tablici 11.

Tablica 11. Tablica razine tolerancija i pripadnih koeficijenata determinacije

Procijenjeni model		
Variable	**Toleran.**	**R^2**
Trend	0,252	0,748
Telefonske linije	0,293	0,757
BDP po stanovniku	0,243	0,707

Vrijednosti razine tolerancije za nezavisne varijable redom iznose TOL_1=0,243, TOL_2=0,252 i TOL_3=0,293, što znači da je ispunjen kriterij TOL_j>0,2, j=1,…,3. Posljedično, i koeficijenti determinacija koji redom iznose $R_1^2 = 0{,}748, R_2^2 = 0{,}757\ i\ R_3^2 = 0{,}707$ također ispunjavaju kriterij $R_j^2 < 0{,}8, j = 1, \dots, 3$. U skladu s prethodno navedenim smije se zaključiti da u konačnom modelu nema efekta multikolinearnosti.

U nastavku je prezentirana i detaljna grafička analiza reziduala, koja je provedena pomoću dva grafička prikaza (Slika 51. i 52.). Također, testirana je i kvaliteta raspodjele reziduala pomoću dijagrama rasipanja (Slika 53.) te homoskedastičnost pomoću tablice korelacije nezavisnih varijabli s nestandardiziranim rezidualima (Tablica 12.).

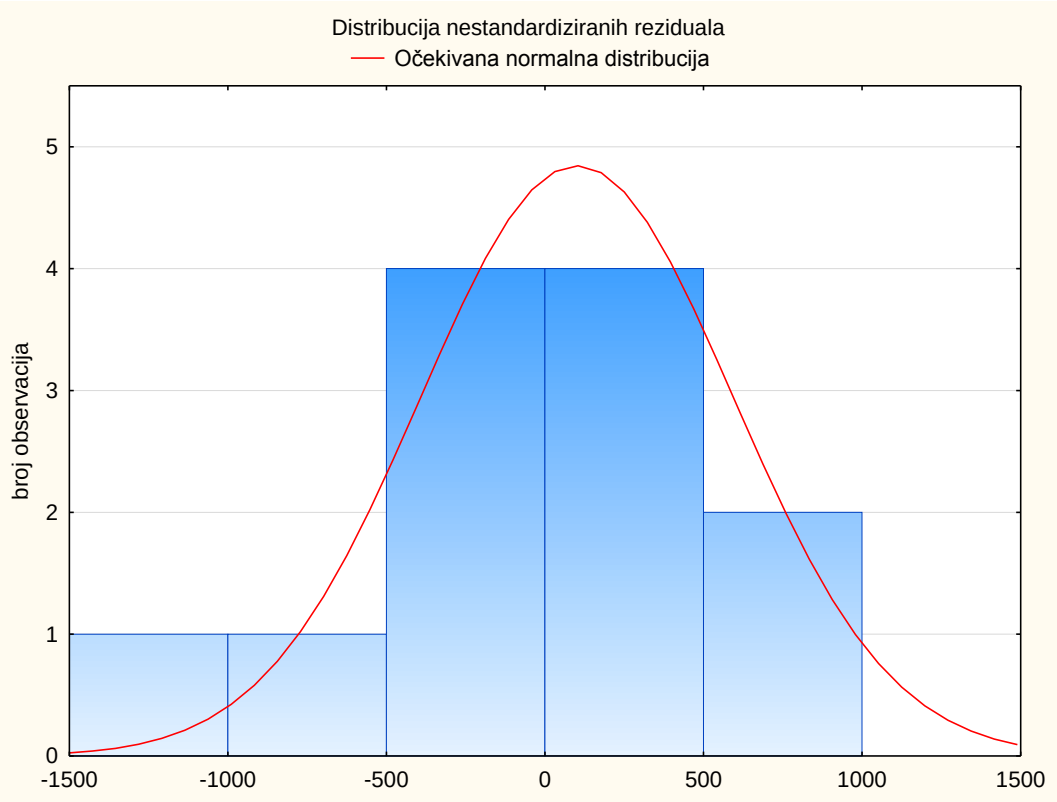

Slika 51. Histogram reziduala

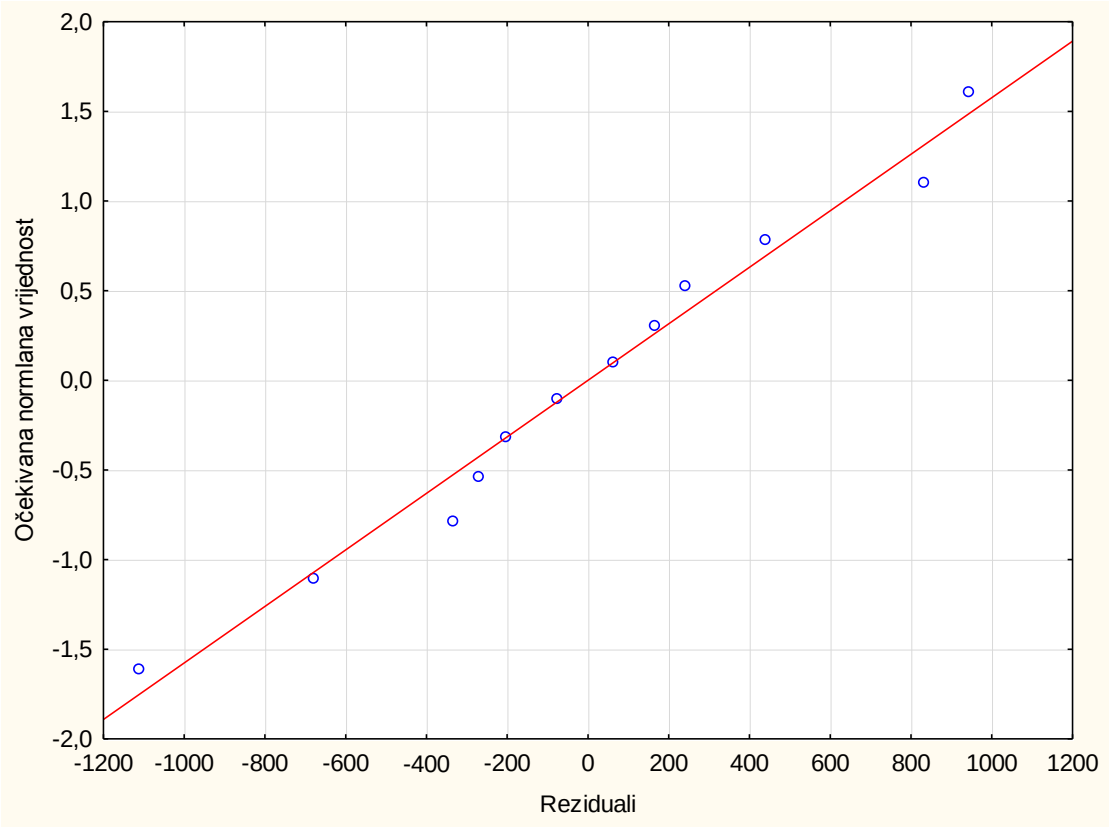

Slika 52. Grafički prikaz reziduala u odnosu na normalnu razdiobu

Histogram reziduala pokazuje gotovo savršenu usklađenost sa zakonom normalne razdiobe (Slika 51.). Naime, broj opservacija po pojedinim intervalima se gotovo idealno prilagođava krivulji gustoće normalne razdiobe. Nadalje, grafikon rasipanja (Slika 52.) ukazuje da je veza između nestandardiziranih reziduala i očekivanih teorijskih percentila normalne razdiobe gotovo linearna te ravnomjerno raspoređena. Što je još jedna potvrda normalne distribuiranosti reziduala.

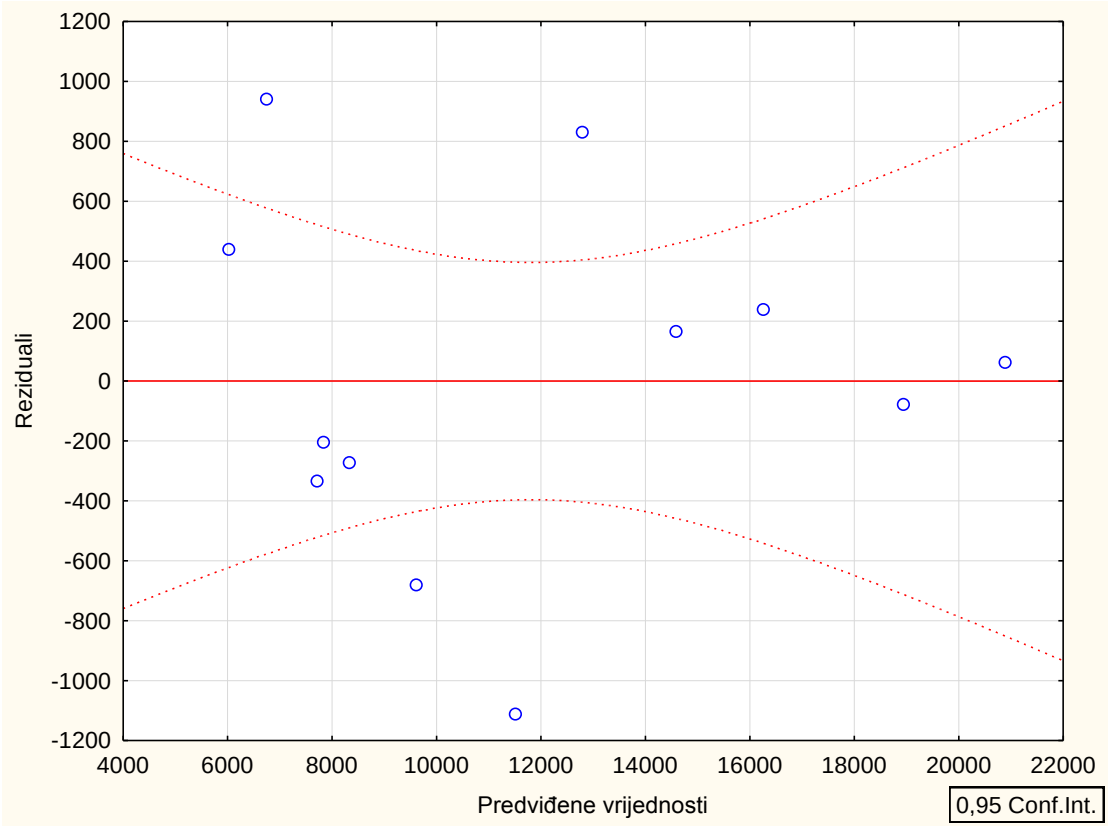

Slika 53. Dijagram raspršenosti reziduala i vrijednosti modela

Pretpostavka linearnosti veze između izabranih nezavisnih varijabli i zavisne varijable je ispunjena ukoliko su rezidualni podaci simetrično raspoređeni na grafikonu, te su podaci grupirani oko nule bez značajnih vidljivih odstupanja [110]. Pomoću dijagrama raspršenosti i vrijednost modela utvrđeno je da ne postoji linearnost u rasporedu točaka. Vrijednosti su raspoređene nepravilno te previše ne odstupaju od 0. Samim tim iz grafičkog prikaza je vidljivo da u modelu nije prisutan problem heteroskedastičnosti (Slika 53.). Prethodni zaključak potvrđen je i korelacijskom analizom u kojoj su određeni Spearmanovi koeficijenti korelacija između nezavisnih varijabli i nestandardiziranih reziduala, što je prikazano tablicom 12.

Tablica 12. Korelacijska analiza nezavisnih varijabli i nestandardiziranih reziduala

Variable	Trend	BDP po stanovniku	Telefonske linije
Nestandardizirani reziduali	0,063	-0,007	0,147

Spearmanovi koeficijenti korelacija između nestandardiziranih reziduala i tri izabrane nezavisne varijable nisu statistički značajni. Također njihova vrijednost je približno 0 iz čega slijedi zaključak da ne postoji korelacija između nestandardiziranih reziduala i izabranih nezavisnih varijabli. Posljedično, u modelu ne postoji problem heteroskedastičnosti.

4.1.5. Regresijski model

Napravljena je deskriptivna statistička analiza kojom je utvrđeno ponašanje svake pojedine nezavisne varijable. Načinjena je i kvalitativna analiza i procjena svih nezavisnih varijabli i njezin odnos prema poštanskom prometu paketskim pošiljkama. Na taj način su izabrane one varijable za koje se pretpostavlja da bi realno mogle utjecati na poštanski promet paketskim pošiljkama. U sklopu korelacijske analize izračunati su Pearsonovi koeficijenti korelacija između varijable paketske pošiljke i svih ostalih nezavisnih varijabli. Izabrane su one varijable koje međusobno jako ne koreliraju. Također, slijedeći kriterij koji je korišten u selekciji nezavisnih varijabli bio je da iste srednje jako ili jako koreliraju sa zavisnom varijablom paketske pošiljke.

Na taj način, nakon detaljno provedene kvalitativne i kvantitativne analize nezavisnih varijabli, izabrane su one varijable za koje se pretpostavilo da imaju realno značajan utjecaj na zavisnu varijablu paketske pošiljke.

U stepwise forward postupku utvrđeno je da dvije nezavisne varijable imaju statistički značajan utjecaj na kretanje broja paketskih pošiljaka, i to BDP po stanovniku te Internet kupci odnosno vrijedi funkcija:

Paketske pošiljke = f (BDP po stanovniku, Internet kupci) +ε (13)

gdje je f linearna funkcija od 2 varijable dok je ε statistička pogreška.

Precizno, pronađeni su β −koeficijenti linearne regresijske jednadžbe oblika

$$Paketi = \alpha + \beta_1 \cdot BDP\ po\ stanovniku + \beta_2 \cdot Internet\ kupci \quad (14)$$

gdje $\alpha, \beta_i \in \mathbb{R}: i = 1, \dots, 2$.

Upotrebom stepwise forward metode procijenjen je model koji sadrži dvije izabrane varijable: Internet kupaci i BDP po stanovniku, te je predložen kao alat kojim se mogu vršiti predviđanja broja paketskih pošiljaka pomoću izabranih varijabli u narednim razdobljima.

U nastavku je dana tablica regresijskih koeficijenata i njihovih pripadnih parametara na godišnjim podacima (Tablica 13.).

Tablica 13. Forward regresijski postupak na godišnjim podacima

Procijenjeni model						
	b*	**Std. pogreška od b***	**b**	**Std. pogreška od b**	**t(36)**	**p**
Intercept			-31442,05	7966,56	-3,95	0,003
Internet kupci	0,53	0,10	8,51	2,03	4,20	0,002
BDP po stanovniku	0,51	0,09	0,48	0,11	4,43	0,002

Utvrđeno je da veći utjecaj na broj paketskih pošiljaka ima varijabla Internet kupaci gdje je apsolutna vrijednost standardiziranog parametra beta 0,53.

Nezavisna varijabla Internet kupci ima p-vrijednost iznosa p=0,002<0,050, pa je statistički značajna. Regresijski koeficijent ove varijable iznosi b=8,51, odnosno, svakim porastom internetskih kupca za jednu tisuću može se očekivati porast prometa paketskih pošiljki u prosjeku za 8,51 tisuća.

Varijabla BDP po stanovniku ima empirijsku p-vrijednost iznosa p=0,002<0,050, pa je statistički značajna. Regresijski koeficijent ove varijable iznosi b=0,48, a to znači da se svakim porastom BDP-a po stanovniku za jednu kunu može očekivati porast prometa paketskim pošiljkama u prosjeku za 0,48 tisuća.

Ovaj rezultat je u skladu sa prethodnim saznanjima.

Godišnja linearna regresijska jednadžba linearna je funkcija dvije varijable:

$$\widehat{Paketi} = -31.442{,}05 + 0{,}479 \cdot BDP\ po\ stanovniku + 8{,}514 \cdot Internet\ kupci \qquad (15)$$

U nastavku izvršena je validacija modela pomoću parametara ANOVE (Tablica 14.).
Empirijska F vrijednost je 69,26, dok je empirijska razina signifikantnosti <0,001, te se može donijeti zaključak da je procijenjeni model kao cjelina statistički značajan.

Tablica 14. ANOVA tablica svih efekata linearnog regresijskog modela

Procijenjeni model	
Statistika	**Vrijednosti**
R	0,969
Koef. determinacije R^2	0.939
Adjusted R^2	0,925
Fisher F	F(2,9)=69,264
P vrijednost modela	<0,001
Std. pogreška procjene	1.363,36

Vrijednost koeficijenta determinacije 0,939 znači da je 93,9% sume kvadrata odstupanja broja paketa od aritmetičke sredine protumačeno procijenjenim modelom.

Reprezentativnost konačnog modela koji sadrži 2 varijable potvrđena je vrlo visokim koeficijentom determinacije koji iznosi čak $R^2 = 0{,}939$, što znači da je 93,9% kvadrata odstupanja u broju paketskih pošiljaka moguće protumačiti modelom, dok 6,1% otpada na rezidualno rasipanje. Prethodna validacija modela pokazuje njegovu visoku kvalitetu. Visoku vrijednost ima i korigirani koeficijent determinacije koji iznosi Adjusted R^2=0,925. Prema ovom parametru model tumači i dalje visokih 92,5% sume kvadrata odstupanja broja paketskih pošiljaka. Standardna pogreška iznosi 1.363,36.

Multikolinearnost između nezavisnih varijabli Internet kupci i BDP po stanovniku je testirana pomoću nivoa tolerancije (TOL). Također su izračunati i odgovarajući koeficijenti determinacija te su svi rezultati prezentirani u tablici 15.

Tablica 15. Tablica nivoa tolerancija i pripadnih koeficijenata determinacije

Procijenjeni model		
Variable	**Toleran.**	**R^2**
BDP po stanovniku	0,465	0,404
Internet kupci	0,465	0,404

Parametar tolerancije varijable BDP po stanovniku iznosi TOL_1=0,465>0,2, dok je njegov koeficijent determinacije R_1^2=0,404<0,8. Prema tome, ova varijabla jasno ispunjava kriterij TOL>0,2 i R^2<0,8. Vrijednost parametra tolerancije varijable Internet kupci također je viša od definirane granične vrijednosti TOL>0,2, te iznosi TOL_2=0,465>0,2. Koeficijent determinacije iznosi R_2^2=0,404<0,8 i niži je od definirane granice R^2<0,8. Stoga i ova

varijabla jasno ispunjava kriterij TOL>0,2 i R^2<0,8. Prema ovim rezultatima u modelu nije izražen problem multikolinearnosti, te se prema provedenom testu model može smatrati kvalitetnim.

Načinjena je i grafička analiza reziduala kako bi se utvrdila njihova svojstva. U tu svrhu dani su histogram reziduala i grafički prikaz vrijednosti reziduala u odnosu na očekivane vrijednosti normalne razdiobe (Slika 54. i Slika 55.). Također, načinjen je i dijagram raspršenosti reziduala i vrijednosti modela (Slika 56.).

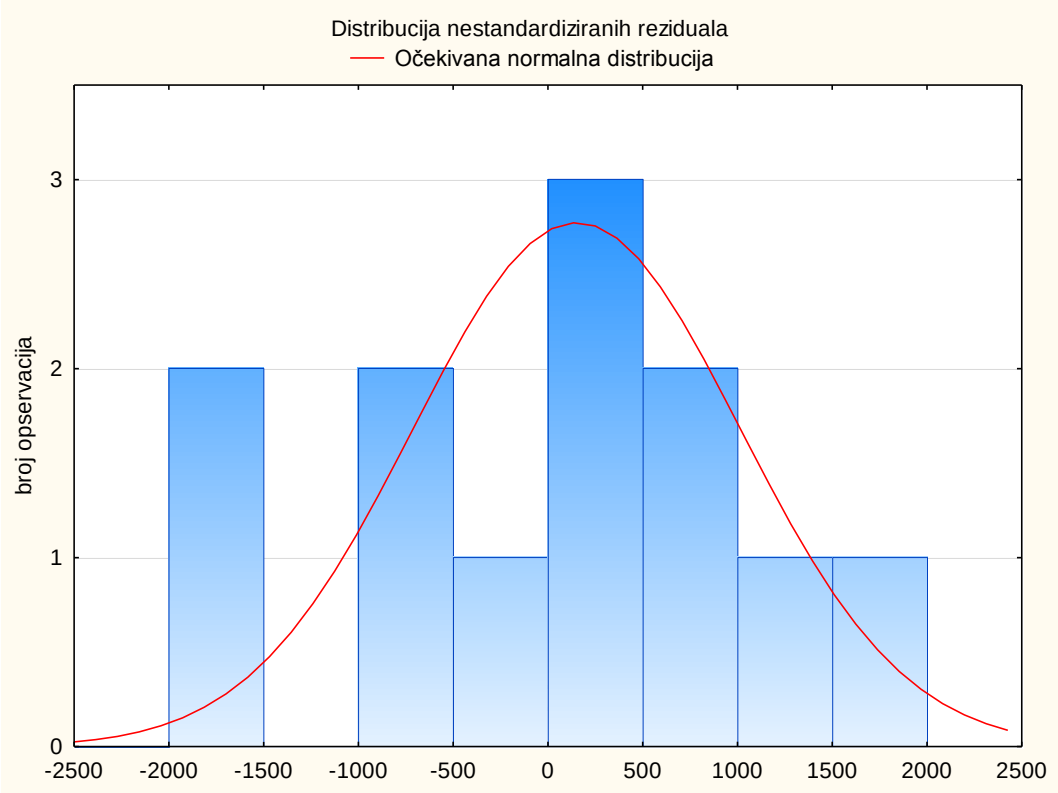

Slika 54. Histogram reziduala

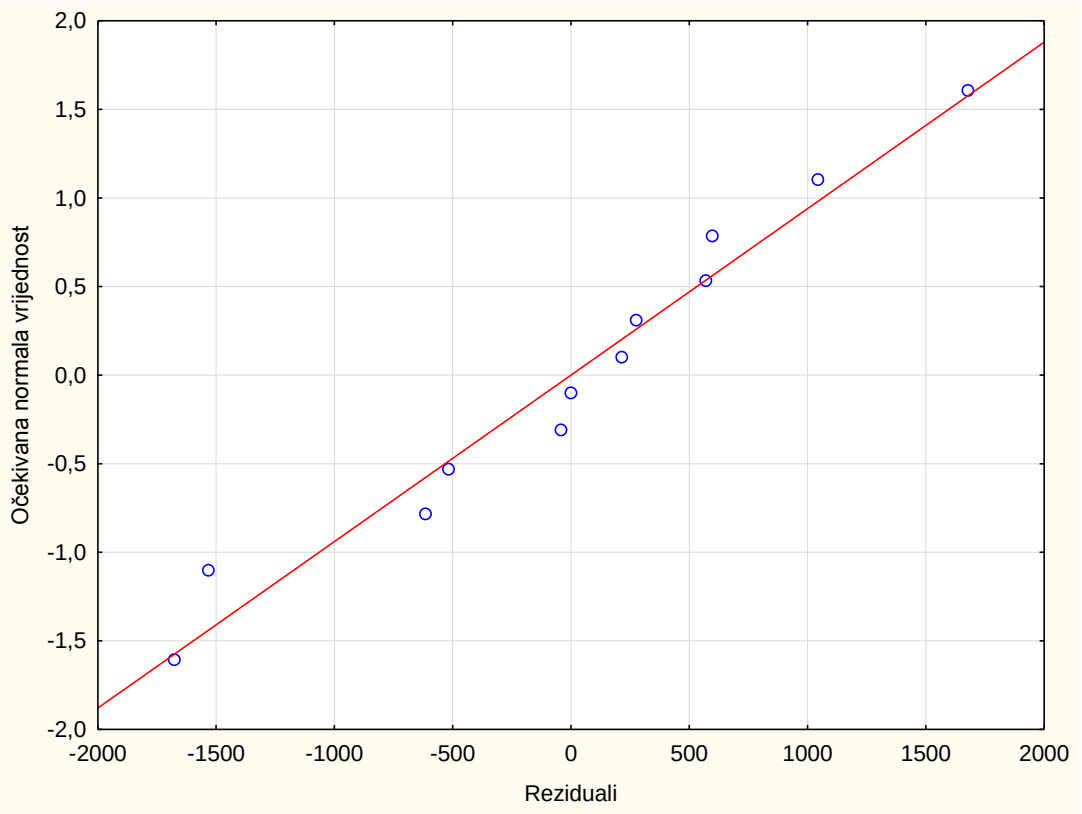

Slika 55. Grafički prikaz reziduala u odnosu na normalnu razdiobu

Analiza histograma reziduala (Slika 54.) pokazuje dosta visoki stupanj usklađenosti reziduala s normalnom razdiobom. Naime, stupci histograma reziduala ne odstupaju značajno od krivulje gustoće normalne razdiobe. S grafičkog prikaza reziduala u odnosu na normalnu razdiobu (Slika 55.) može se uočiti izrazita pravilna raspoređenost vrijednosti na dijagramu. To je još jedna potvrda izuzetno pravilnog ponašanja reziduala koji slijede zakon normalne razdiobe.

Kako bi se ispitalo ponašanje reziduala za sve vrijednosti koje se dobiju pomoću modela, načinjen je sljedeći dijagram rasipanja (Slika 56.).

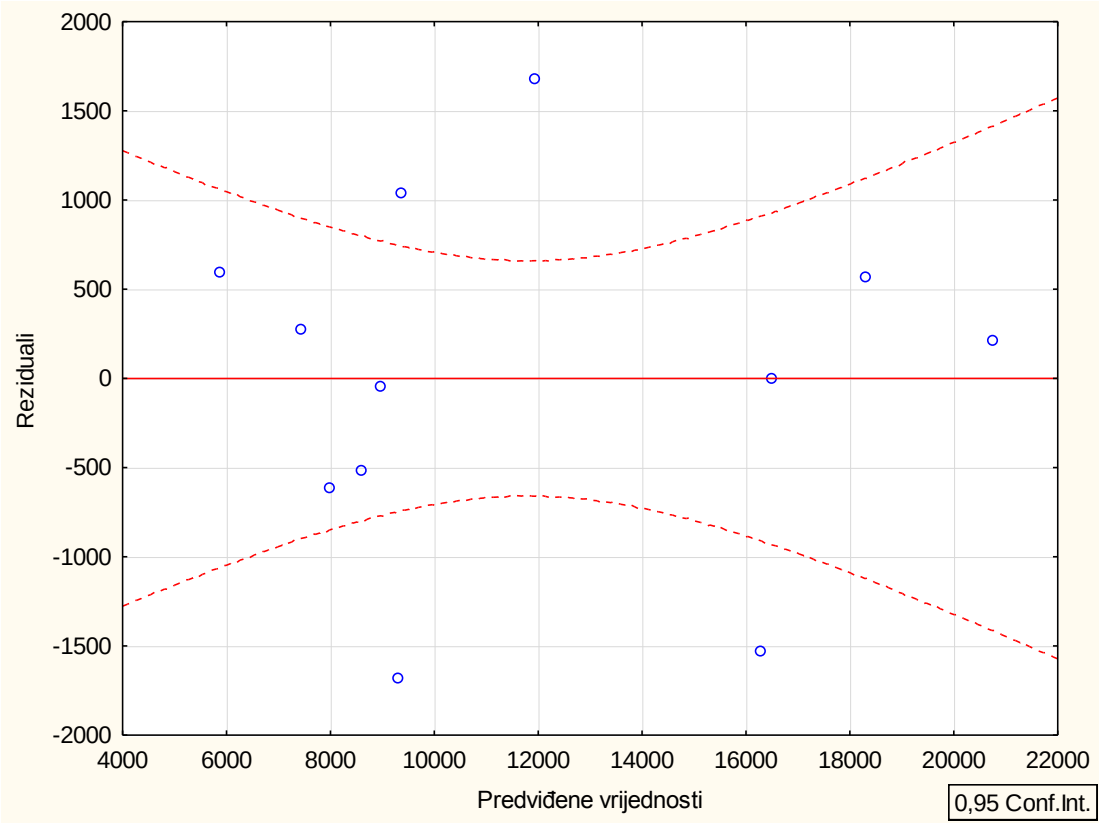

Slika 56. Dijagram raspršenosti reziduala i vrijednosti modela

Analizom dijagrama raspršenosti reziduala i vrijednosti modela (Slika 56.) utvrđeno je nelinearno ponašanje, te se reziduali približno jednako ponašaju na čitavom području vrijednosti modela. Samim time ne postoje ni problemi s heteroskedastičnosti odnosno s neravnomjernom distribucijom varijanci. Prethodna tvrdnja biti će dodatno potvrđena pomoću korelacijske analize u kojoj su izračunati Spearmanovi koeficijenti korelacije ranga između nestandardiziranih reziduala i nezavisnih varijabli. Dobiveni rezultati prezentirani su u tablici 16.

Tablica 16. Korelacijska analiza nezavisnih varijabli i nestandardiziranih reziduala

Variable	Internet kupci	BDP po stanovniku
Nestandardizirani reziduali	0,091	0,084

Spearmanovi koeficijenti korelacija između nestandardiziranih reziduala i dvije izabrane nezavisne varijable nisu statistički značajni. Također njihova vrijednost je približno 0 iz čega

slijedi zaključak da ne postoji korelacija između nestandardiziranih reziduala i izabranih nezavisnih varijabli. Posljedično, u modelu ne postoji problem heteroskedastičnosti.

4.2. Usporedba procijenjenih regresijskih modela

Nakon procjene regresijskih modela napravljena je usporedba pokazatelja statističke značajnosti i reprezentativnosti u svrhu odabira najreprezentativnijeg modela za procjene budućih kretanja paketskih pošiljaka. Usporedba rezultata prikazana je u tablici 17.

Tablica 17. Usporedba rezultata regresijskih modela

Modeli	**Koef. determinacije R^2**	**Fisher F**	**p -vrijednost modela**
Godišnji regresijski model s trendom	98,62%	F(3,8)=190,33	<0,001
Godišnji regresijski model	93,90%	F(2,9)=69,264	<0,001

Ukoliko je koeficijent determinacije > 70%, model je reprezentativan [111]. Iz tablice se može vidjeti da su oba modela reprezentativna, a što je i potvrđeno koeficijentima determinacije koji su vrlo visoki. Na temelju empirijske p-vrijednosti <0,001 može se donijeti zaključak da su oba modela kao cjeline statistički značajni.

Veću preciznost procjene ima regresijski model temeljen na godišnjim podacima s trendom kojim se može protumačiti 98,62% sume kvadrata odstupanja. Na temelju empirijske F-vrijednosti F(3,8)=190,33 može se donijeti zaključak da je model kao cjelina statistički značajan pri empirijskoj razini signifikantnosti <0,001.

Uz statistički kriterij preciznosti procjene modela opravdanost primjene modela se pojašnjava i teorijski. Upotrebom forward stepwise postupka odabrane su dvije varijable koje precizno pojašnjavaju kretanje broja paketskih pošiljaka, i to Internet kupci, te BDP po stanovniku. Broj redovitih Internet kupaca ima očekivano pozitivan utjecaj na kretanje broja paketskih pošiljaka budući da se proizvodi kupljeni putem e-trgovine isporučuju u paketskim pošiljkama s udaljenih lokacija prema dogovorenom mjestu preuzimanja. Procijenjeni parametar ima

pozitivan predznak, odnosno porast broja Internet kupaca dovodi do porasta prometa paketskih pošiljaka i suprotno.

Veći životni standard, mjeren BDP-om po stanovniku, omogućuje zadovoljenje većeg broja potreba u koje spada i razonoda koja implicira veću potrošnju stanovnika, što dovodi do porasta obujma trgovine, a što posljedično dovodi do porasta potražnje za poštanskim uslugama. Procijenjeni parametar ima pozitivan predznak, odnosno porast razine BDP-a povećava broj paketskih pošiljaka i suporotno.

Procijenjeni model s trendom u forward stepwise postupku koristi 3 varijable kojima se pojašnjava utjecaj na kretanje broja paketskih pošiljaka, i to trend varijablu, telefonske linije, te BDP po stanovniku.

Fiksne telefonske linije imaju tendenciju smanjenja upotrebe budući da se kao komunikacijski alat sve više koristi mobilna mreža. Fiksne telefonske linije u Republici Hrvatskoj se u većoj mjeri vezuju uz starije stanovništvo. Trenutna je tendencija smanjenja broja fiksnih telefonskih linija budući da je riječ o starijoj tehnologiji koja se sve manje koristi uz istovremeni porast broja paketskih pošiljaka. Korištenje modela koji sadrži varijablu koja ima tendenciju opadanja na važnosti radi tehnološke zastarjelosti nije primjerena za korištenje unatoč većoj reprezentativnosti modela, što je argument za odabir regresijskog modela bez trenda. Procijenjeni model bez trenda upućuje na važnost korištenja suvremenih tehnologija, pa koristi varijablu Internet kupaci, te BDP-a po stanovniku koji predstavlja temeljnu ekonomsku varijablu, zbog čega je primjereniji za korištenje. Varijabla Internet kupci se vezuje uz upotrebu suvremene informacijsko-komunikacijske tehnologije i korištenje Interneta koji ima tendenciju rasta na važnosti, te se očekuje i rast u budućnosti.

4.3. Analiza reprezentativnosti prognostičkog modela broja paketskih pošiljaka

Kako bi se utvrdila preciznost procijenjenog prognostičkog modela, napravljena je prognoza broja paketskih pošiljki u 2019. godini. Podatci su uspoređeni s ostvarenim brojem paketskih pošiljaka, te je utvrđena preciznost procijenjenog modela (Slika 57).

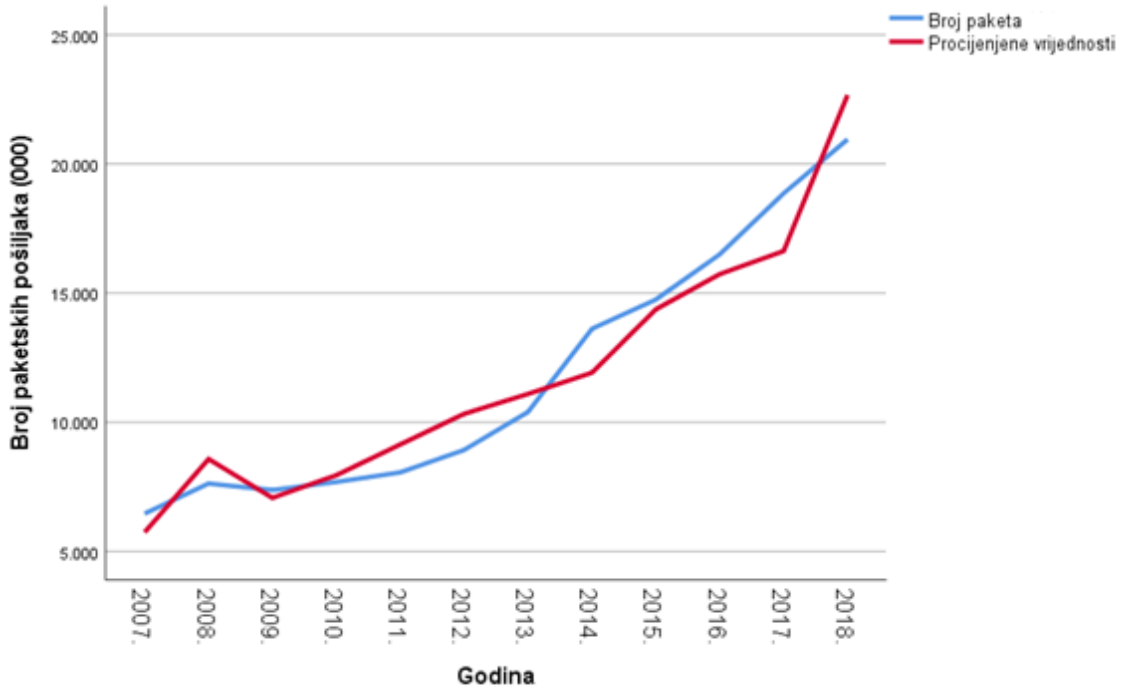

Slika 57. Ostvaren i procijenjen promet paketskim pošiljkama u promatranom razdoblju od 2007. do 2018. godine

Konačni godišnji regresijski model bez trenda je testiran korištenjem podataka koji su prikupljeni s Državnog zavoda za statistiku i HAKOM-a za 2019. godinu. Rezultat predviđanja i njegov pripadni 95%-tni interval pouzdanosti dan je tablicom 18.

Tablica 18. Rezultati prognoziranja pomoću godišnjeg modela

	Očekivana vrijednost za 2019. (000)
Procjena	23.325,1
-95,0%CI*	20.619,5
+95,0%CI*	26.030,7

*Interval pouzdanosti

Prema procijenjenom modelu u 2019. godini se očekuje promet od 23,325 milijuna paketa, dok je prema dostupnim podatcima HAKOM-a ostvareno 23,927 milijuna paketa, te se pri razini pouzdanosti od 95% može očekivati da će se stvarni broj paketa kretati u rasponu od 20,62 do 26,03 milijuna paketskih pošiljaka (Tablica 18).

Model je procijenio 97,59% ostvarenog broja paketskih pošiljaka, odnosno prema prethodnim podacima model je predvidio promet paketskim pošiljkama za 2,41% manji od ostvarenog prometa u 2019. godini.

Testiranje upotrebom stvarnih podataka iz 2019. godine koji su prikupljeni sa DSZ-a i HAKOM-a utvrđeno je da je konačni godišnji model bez trenda precizan u predviđanju broja paketskih pošiljaka. Testiranje modela upotrebom stvarnih podataka iz 2019. godine i detaljno provedene validacije modela pokazali su da je konačni godišnji višestruki linearni regresijski model reprezentativan prema svim dobivenim parametrima. Stoga se sa sigurnošću smije tvrditi da je model prikladan za korištenje kod predviđanja količine broja paketskih pošiljaka u ovisnosti o dvije izabrane varijable, u budućim razdobljima. Prema tome, preporučuje se korištenje regresijske jednadžbe (15) za proračunavanje broja paketskih pošiljaka u budućim godišnjim razdobljima, te predloženi model predstavlja doprinos u području poštanskog prometa.

5. UČINKOVITOST PRIJEVOZA PAKETSKIH POŠILJAKA

Upotrebom pokazatelja učinkovitosti prijevoza moguće je vrednovati učinkovitost prijevoza paketskih pošiljaka. Prikazani su izrazi kojima se može izračunati učinkovitost prijevoza paketskih pošiljaka među poštanskim entitetima, a koje zajedno s prognostičkim modelom i predloženom metodologijom omogućavaju unaprjeđenje prijevoza paketskih pošiljaka.

5.1. Pokazatelji učinkovitosti prijevoza

U cestovnom su prijevozu istraživani razni pokazatelji koji se koriste za mjerenje operativne učinkovitosti, a pri tom se posebno izdvajaju masa i volumen kao pokazatelji natovarenosti vozila. U [23] istraživanje je pokazalo da je jedan od šest najčešće korištenih pokazatelja učinkovitosti prijevoza (ukupni godišnji kilometri po vozilu, ukupni godišnji tonski kilometri po vozilu, kilometri praznog vozila u ukupnim prijeđenim kilometrima, prosječna stvarna natovarenost u odnosu na maksimalnu natovarenosti, godišnji broj kilometara po vozaču, potrošnja goriva po tipu vozila) masena iskorištenost vozila koja predstavlja prosječnu stvarnu natovarenost u odnosu na maksimalnu natovarenosti. Za ocjenu učinkovitosti vozila za prijevoz tereta u [25] koriste se pokazatelji potrošnje goriva, cijene goriva, troška rada, troška potrošnog materijala, porez, osiguranje, prijeđena udaljenost, te prevezena količina tereta u tonama. U [27] istražena je stopa punjenja vozila kao pokazatelj učinkovitosti prijevoza gdje su kao pokazatelje koristili udio površine vozila prekrivenog teretom, masu i volumen. U transportnom i distribucijskom sektoru koriste se sljedeći pokazatelji: troškovi po vozilu, plaća po vozaču, broj radnih sati po vozilu, broj radnih sati po vozaču, prosječne brzine, vrijeme utovara/istovara, promet (izražen u novčanim jedinicama) po vozilu, udio kilometara praznog vozila u ukupnim prijeđenim kilometrima, kilometri po vozilu, te prosječna natovarenost vozila kao pokazatelj za mjerenje učinkovitosti [24]. U [28] istražen je problem prijevoza između distribucijskih centara u kojem su kao pokazatelj koristili potrošnju goriva, cijenu goriva, vrijeme iskorištenosti vozila, prijeđenu udaljenost te masu prevezenog tereta i volumensku iskorištenost vozila.

U [112] također je istražena učinkovitost prijevoza tereta gdje je kao pokazatelj učinkovitosti uzeta iskorištenost vozila koja je definirana kao omjer stvarnog iskorištenog kapaciteta s ukupnim raspoloživim kapacitetom. U slučaju teretnih vozila neke od mjera učinkovitosti koje se primjenjuju pokazatelj su opterećenja temeljen na masi, a predstavlja omjer stvarne

mase robe koja se prevozi prema maksimalnoj masi tereta koja se mogla prevesti te volumetrijski pokazatelj opterećenja što predstavlja kubični udio prostora u vozilu zauzet teretom.

Kako je ranije rečeno, davatelji prijevoznih usluga primjenjuju različite pokazatelje za mjerenje učinkovitosti prijevoza. U [29] istražena je učinkovitost prijevoza paketskih pošiljaka upotrebom kilometara praznog vozila, vremena iskorištenosti vozila, potrošnje goriva te pokazatelja popunjenosti vozila. Istraživanje je provedeno na davateljima poštanskih usluga u Velikoj Britaniji.

Temeljem provedenih istraživanja i relevantnosti za daljnje korake istraživanja odabrani su masa i volumen za izračun pokazatelja učinkovitosti prijevoza budući da masa paketskih pošiljaka utječe na opterećenje vozila, dok volumen paketskih pošiljaka utječe na popunjavanje teretnog prostora u vozilu.

Masa i volumen poštanskih pošiljaka koristit će se za izračun učinkovitosti prijevoza čime će biti određen maseni odnosno volumenski udjel natovarenosti vozila.

Stoga je za daljnje korake istraživanja istražena prosječna masa i volumen paketskih pošiljaka.

Prosječna masa paketskih pošiljaka može se izračunati temeljem slijedećeg obrasca:

$$\bar{m} = \frac{m_{uk}}{n} \tag{29}$$

pri čemu je:

m_{uk} – zbroj vrijednosti promatranog obilježja
n – broj članova skupa.

Prosječni volumen paketskih pošiljaka može se izračunati temeljem sljedećeg obrasca:

$$\bar{V} = \frac{V_{uk}}{n} \tag{30}$$

pri čemu je:

V_{uk}- zbroj vrijednosti promatranog obilježja
n – broj članova skupa.

Na uzorku od 105 paketskih pošiljaka napravljena je analiza mase i volumena paketskih pošiljaka. Riječ je o velikom uzorku [72, 113]. Korištena je metoda slučajnog uzorka pri odabiru paketa u poštanskom središtu gdje je od 352 paketa slučajnim odabirom odabrano 105 paketa. Dakle, odabrano je 29,83% paketa, odnosno uzorak je reprezentativan. Rezultati analize prikazani su u tablici 19.

Tablica 19. Deskriptivna statistika paketskih pošiljaka

	N	**Prosječna vrijednost**	**Medijan**	**Minimalna vrijednost**	**Maksimalna vrijednost**	**St. devijacija**
Masa (kg)	105	3,77	1,44	0,20	38,10	6,07
Volumen (cm^3)	105	29.600,73	15.694,00	2.102,50	244.800,00	43.913,50

Prosječna masa paketskih pošiljaka je 3,77 kilograma s prosječnim odstupanjem od aritmetičke sredine 6,07 kg. Riječ je o velikim odstupanjima budući da je standardna devijacija veća od aritmetičke sredine. Vrijednost medijana 1,44 znači da je polovica paketskih pošiljaka težila do 1,44 kilograma, dok je masa polovice paketskih pošiljaka bila jednaka ili veća od 1,44 kilograma. Masa paketskih pošiljaka se kretala u rasponu od 0,20 kg do 38,10 kilograma.

Volumen paketskih pošiljaka je u prosjeku 29.600,73 cm kubičnih s prosječnim odstupanjem od aritmetičke sredine 43.913,50 cm kubičnih. Vrijednost medijana 15.694 znači da je polovica paketskih pošiljaka imala obujam do 15.694 cm^3 ili manje, dok je polovica paketskih pošiljaka imala obujam 15.694 cm^3 ili više. Obujam promatranih paketskih pošiljaka se kretao u rasponu od 2.102,50 cm^3 do 244.800 cm^3.

Napravljen je Kolmogorov-Smirnov test [33] kako bi se ispitalo jesu li varijable masa i volumen paketskih pošiljaka normalno distribuirane. Rezultat testa prikazan je u tablici 20.

Tablica 20. Testiranje razdiobe paketa u uzorku u odnosu na Gaussovu krivulju

	N	**Max. D**	**P**
Masa (kg)	105	0,29	$p < 0,050$
Volumen (cm^3)	105	0,27	$p < 0,050$

Testiranjem razdiobe paketa u uzorku u odnosu na Gaussovu krivulju može se utvrditi da varijable masa i volumen značajno odstupaju od normalne distribucije ($p<0,050$).

U nastavku je prikazana struktura mase i volumena paketskih pošiljaka (Slika 58. i 59.).

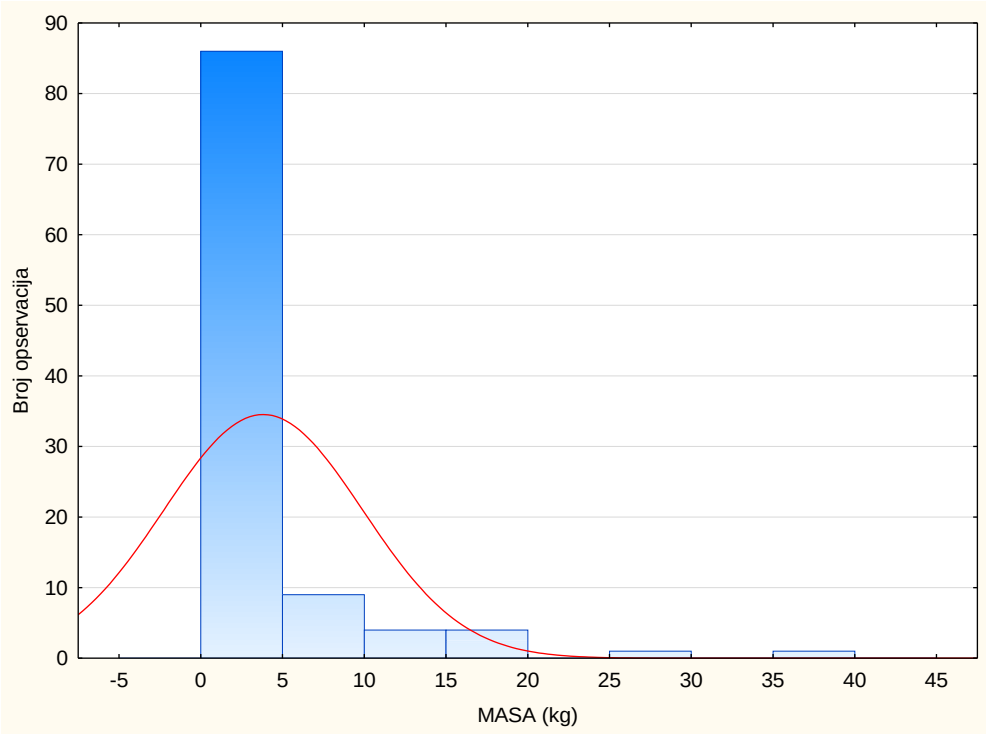

Slika 58. Histogram mase paketskih pošiljaka

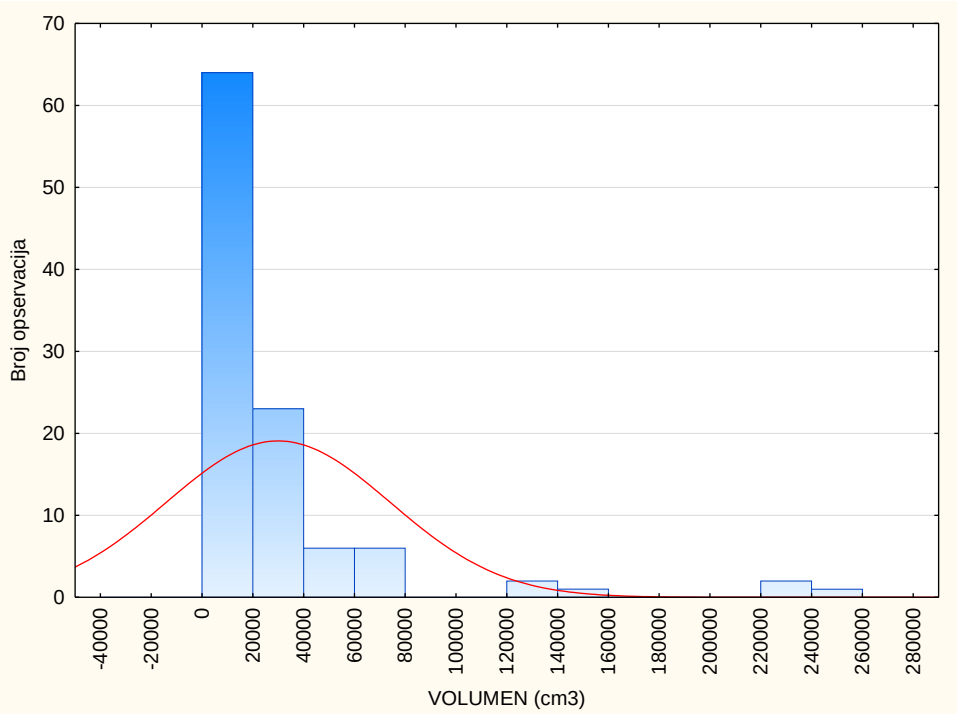

Slika 59. Histogram volumena paketskih pošiljaka

Svrha je ove analize utvrditi razdiobu paketa prema masi i volumenu u Republici Hrvatskoj. Histogram mase i histogram volumena paketskih pošiljaka (Slika 58. i 59.) pokazuju da varijable masa i volumen značajno odstupaju od normalne distribucije te je riječ o pozitivno simetričnoj distribuciji, odnosno može se vidjeti da dolazi do ekstremne akumulacije paketskih pošiljaka mase do 5 kilograma i obujma do 20.000 cm^3, dok se paketi veće mase i većeg obujma tek rjeđe pojavljuju. U uzorku je 56,19% paketskih pošiljaka imalo masu manju od 2 kg., dok je 25,71% paketskih pošiljaka imalo masu od 2 do 5 kg, odnosno masu do 5 kg je imalo 81,90% paketskih pošiljaka.

Prema istraživanju UPU-a na tržištu paketa Sjeverne Amerike 41% paketskih pošiljaka imalo je maje od 2 kg, od 2 do 5 kg bilo je 15% paketskih pošiljaka dok je 44% paketskih pošiljaka imalo masu od 5 do 31 kg [14], iz čega se može utvrditi da distribucija odstupa od Gausove budući da je centralna položajna vrijednost 15,50 kilograma pa bi u sluačju Gausove razdiobe 50% paketskih pošiljaka bilo lakše od 15,50 kg, dok je kod primjernog istraživanja 56% paketskih pošiljaka imalo težinu do 5 kilograma. Riječ je o pozitivno simetričnoj distribuciji što je u skladu s dobivenom razdiobom kod provedenog istraživanja u Republici Hrvatskoj.

5.2. Validacija prognostičkog modela u svrhu unaprjeđenja učinkovitosti prijevoza paketskih pošiljaka

Validacija prognostičkog modela se provodi nakon procjene broja paketskih pošiljaka upotrebom odabranog prognostičkog modela na godišnjoj razini. Radi se usporedba između prognoziranog broja paketskih pošiljaka i ostvarenog broja paketskih pošiljaka u Republici Hrvatskoj. Zatim se uspoređuje planirani broj paketskih pošiljaka od strane jednog davatelja poštanskih usluga i ostvarenog broja paketskih pošiljaka. Ukoliko prognostički model daje preciznije procjene broja paketskih pošiljaka u odnosu na procjenu odabranog davatelja poštanskih usluga prognostički model je primjeren za korištenje.

5.2.1. Utvrđivanje broja paketskih pošiljaka primjenom godišnjeg prognostičkog modela

Napravljena je usporedba broja paketskih pošiljaka dobivena temeljem prognostičkog modela s ostvarenim prometom paketskih pošiljaka na području Republike Hrvatske, što se može vidjeti u tablici 21.

Tablica 21. Ostvaren i prognoziran broj paketskih pošiljaka

Godina	Broj paketa (tis)	Procjena (tis)	Rezidual (%)
2007.	6.461	5.743	12,50
2008.	7.628	8.574	-11,03
2009.	7.377	7.072	4,32
2010.	7.689	7.949	-3,27
2011.	8.059	9.140	-11,82
2012.	8.929	10.325	-13,52
2013.	10.399	11.098	-6,29
2014.	13.620	11.918	14,28
2015.	14.749	14.374	2,61
2016.	16.499	15.735	4,86
2017.	18.860	16.627	13,43
2018.	20.950	22.666	-7,57

U razdoblju od 2015. godine do 2018. godine može se vidjeti da je u 2015. godini ostvareno za 2,61% paketa više u odnosu na procjenjen broj paketa, u 2016. godini ostvareno je za 4,86% paketa više u odnosu na procjenjen promet paketskih pošiljaka, a u 2017. godini ostvareno je 13,43% paketa više u odnosu na procjenjen broj paketa. U 2018. godini ostvareno je za 7,57% paketa manje u odnosu na procjenjen broj paketa.

Nakon procjene broja paketskih pošiljaka upotrebom odabranog prognostičkog modela na godišnjoj razini te usporedbe između prognoziranog broja paketskih pošiljaka i ostvarenog broja paketskih pošiljaka u Republici Hrvatskoj radi se usporedba između planiranog broja paketskih pošiljaka od strane jednog davatelja poštanskih usluga i ostvarenog broja paketskih pošiljaka. Ukoliko prognostički model daje preciznije procjene broja paketa u odnosu na planiran broj paketskih pošiljaka odabranog davatelja poštanskih usluga prognostički model je primjeren za korištenje.

5.2.2. Utvrđivanje broja paketskih pošiljaka davatelja poštanske usluge

Podaci za promatrane godine prikazani tablicom 22. prikupljeni su iz HAKOM-a i godišnjih izvješća promatranog davatelja poštanskih usluga. Može se vidjeti da ukupno paketsko poslovanje u Hrvatskoj raste pa tako i paketsko poslovanje promatranog davatelja poštanskih usluga čiji se tržišni udio također povećava.

Tablica 22. Promet paketskim pošiljkama [114, 115, 116, 117]

Godina	Ukupno paketskih pošiljaka na tržištu RH	Ostvaren broj paketskih pošiljaka promatranog davatelja	Tržišni udio
2015.	14.749.000	4.690.000	31,80
2016.	16.499.000	5.726.000	34,71
2017.	18.860.000	6.815.000	36,17
2018.	20.950.000	8.295.000	39,69

Promatrani je davatelj poštanskih usluga u promatranoj godini ostvario povećanje broja paketskih pošiljaka. Planirani broj paketskih pošiljaka također se povećavao s tim da je u odnosu na ostvareni broj paketskih pošiljaka, izuzev 2017., ostvarena veća količina paketskih pošiljaka od planirane što se može vidjeti iz tablice 23.

Tablica 23. Ostvaren i planiran broj paketskih pošiljaka [114, 115, 116, 117]

Godina	Ostvareno (br. paketskih pošiljaka)	Planirano (br. paketskih pošiljaka)
2015.	4.690.000	4.513.720
2016.	5.726.000	4.823.000
2017.	6.815.000	6.877.000
2018.	8.295.000	7.575.000

U odnosu na planirano u 2015. ostvareno je 176.280 više poštanskih paketskih pošiljaka. Također je 2016. godine ostvareno više paketskih pošiljaka od planiranog i to za 903.000. U 2017. ostvaren je manji broj paketskih pošiljaka u odnosu na planirano za 62.000, a 2018. ostvareno je 720.000 više paketskih pošiljaka od paniranog.

Uzimajući u obzir predviđeni broj paketskih pošiljaka i prosječnu masu odnosno volumen paketskih pošiljaka dobiva se ukupni predviđeni volumen odnosno masa paketskih pošiljaka za predviđeno razdoblje. Kako bi se predviđena masa i volumen paketskih pošiljaka mogli prevesti, potrebno je analizirati postojeće kapacitete (nosivost vozila i zapremina teretnog prostora) te primjenom prognostičkog modela utvrditi buduće potrebe obzirom na predviđeni broj paketskih pošiljaka.

5.2.3. Validacija prognostičkog modela

Temeljem tržišnog udjela promatranog davatelja poštanskih usluga te očekivanim brojem paketskih pošiljaka modelom za Republiku Hrvatsku od 2015.do 2018. godine izračunat je očekivan broj paketskih pošiljaka promatranog davatelja poštanske usluge što se može vidjeti u tablici 24.

Tablica 24. Očekivan broj paketskih pošiljaka modelom

Godina	Očekivan broj paketskih pošiljaka u RH (000)	Tržišni udio promatranog davatelja poštanske usluge	Očekivan broj paketskih pošiljaka promatranog davatelja poštanske usluge modelom (000)
2015.	14.260*	31,80	4.534*
2016.	15.773*	34,71	5.474*
2017.	18.612*	36,17	6.732*
2018.	21.060*	39,69	8.359*

*očekivana vrijednost

Usporedba rezultata odstupanja između modelom prognoziranog broja paketskih pošiljaka i ostvarenog broja paketskih pošiljaka, te između planiranog broja paketskih pošiljaka od strane davatelja poštanskih usluga i ostvarenog broja paketskih pošiljaka može se vidjeti na grafičkom prikazu na slici 60. Cilj usporedne analize je utvrditi procjenjuje li model preciznije kretanje paketskih pošiljaka u odnosu na procjenu promatranog davatelja poštanskih usluga.

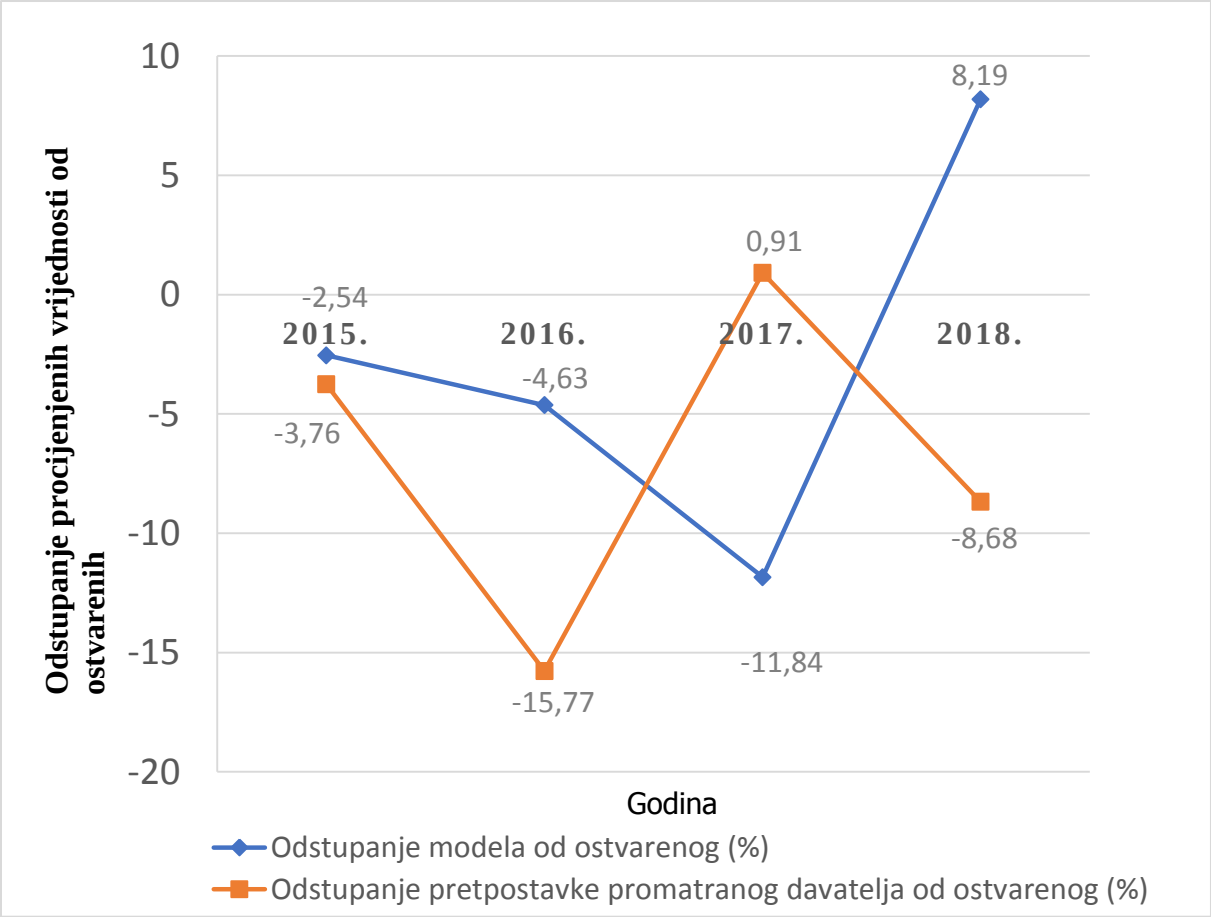

Slika 60. Odstupanje modela i pretpostavke davatelja poštanske usluge u odnosu na ostvareni broj paketskih pošiljaka

Usporedbom odstupanja modela i pretpostavke davatelja poštanske usluge u odnosu na ostvareni broj paketskih pošiljaka promatranog davatelja poštanskih usluga (Slika 60.) može se vidjeti da su odstupanja modela za tri od četiri promatrane godine (75%) manja u odnosu na očekivani promet paketskih pošiljaka davatelja poštanskih usluga, što navodi na zaključak da se model može koristiti u ove svrhe, odnosno za prognoziranje paketskih pošiljaka. U 2015. model je bolji za 1,22 postotna poena u odnosu na pretpostavke davatelja poštanske usluge. Za 2016. godinu model je pokazao da je bolji za čak 11,14 postotnih poena. U 2017. model je lošiji u odnosu na očekivani promet paketskih pošiljaka davatelja poštanske usluge za 10,93 postotnih poena, dok je u 2018. model precizniji za 0,49 postotnih poena.

Nadalje, može se utvrditi da godišnji prognostički model ima manju pogrešku procjene u promatranim godinama što omogućuje učinkovitije planiranje voznog parka u odnosu na pretpostavke promatranog davatelja poštanskih usluga budući da je raspon između projiciranih i ostvarenih vrijednosti manji, te se kod procijenjenog modela kreće u rasponu od

-11,84% do 8,19%, dok je raspon procjene davatelja poštanskih usluga u rasponu od -15,77% do 0,91%.

Uži interval procjene smanjuje rizik budućih potreba za neplaniranim ili nepotrebnim kapacitetima prijevoznih sredstava zbog čega dolazi do bolje iskorištenosti voznog parka.

Temeljem podataka o masi i volumenu paketskih pošiljaka napravljena je dodatna validacija modela kako bi se utvrdila razlika u preciznosti procjene prognostičkog godišnjeg modela u odnosu na pretpostavke odabranog davatelja poštanskih usluga što se može vidjeti u tablici 25.

Tablica 25. Validacija modela temeljem pokazatelja

Godina	**Odstupanje modela u odnosu na ostvaren br. paketskih pošiljaka**	**Odstupanje promatranog davatelja poštanske usluge u odnosu na ostvaren br. paketskih pošiljaka**	**Odstupanje modela u masi paketskih pošiljaka (kg)**	**Odstupanje promatranog davatelja poštanske usluge u masi paketskih pošiljaka (kg)**	**Odstupanje modela u volumenu paketskih pošiljaka (m^3)**	**Odstupanje promatranog davatelja poštanske usluge u volumenu paketskih pošiljaka (m^3)**
2015.	-156.000	-176.280	-588.120	-664.576	-4.617,71	-5.218
2016.	-252.000	-903.000	-950.040	-3.404.310	-7.459,38	-26.729
2017.	-83.000	62.000	-312.910	233.740	-2.456,86	1.835
2018.	64.000	-720.000	241.280	-2.714.400	1.894,45	-21.313

Iz tablice 25. primjenom pokazatelja može se vidjeti koliko je odstupanje modela u odnosu na promatranog davatelja poštanske usluge u ukupnoj godišnjoj masi i volumenu paketskih pošiljaka tijekom promatranih godina. Za izračun su korištene prosječne vrijednosti paketskih pošiljaka utvrđene na području Republike Hrvatske gdje je istraživanjem utvrđena prosječna masa (3,77 kg) i prosječan volumen paketskih pošiljaka (0,02960073 m^3). Za 2015. model je precizniji za 76.456 kg i 600 m^3 paketskih pošiljaka u odnosu na promatranog davatelja poštanskih usluga. U 2016. model je precizniji za 2.454.270 kg i 19.270 m^3 paketskih pošiljaka. U 2017. model je manje precizan za 79.170 kg i 622 m^3 dok je u 2018. precizniji za 2.473.120 kg i 19.418 m^3 paketskih pošiljaka.

Dakle, vrijednosti koje daje prognostički model su preciznije u odnosu na procjenu broja paketskih pošiljaka odabranog davatelja poštanskih usluga, slijedom čega se može zaključiti da se vrednovanjem pokazatelja uz primjenu modela može unaprijediti proces planiranja kapaciteta potrebnih prijevoznih sredstava.

5.3. Metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava

Nakon izrade modela za predviđanje paketskih pošiljaka te određivanjem i primjenom varijabli mase i volumena paketskih pošiljaka definira se metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unapređenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu.

Metodologija se može koristiti za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unapređenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu.

Uz metodologiju se koristi model koji omogućuje analizu prijevoznih kapaciteta i optimizaciju voznog parka.

Prema [118, 119] koeficijentom statičnog opterećenja prijevoznih sredstava (γ_s), koji se dobije dijeljenjem stvarnog i mogućeg (nazivnog) opterećenja, moguće je izračunati postotak natovarenosti vozila. Koeficijent statičnog opterećenja za jednu vožnju ima slijedeći izraz:

$$\gamma_{s_\lambda} = \frac{q_\lambda}{q_n} \tag{26}$$

pri čemu je:

q_λ - stvarna količina supstrata na prijevoznom sredstvu tijekom jedne vožnje
q_n - nazivna nosivost prijevoznog sredstva.

Primjenom izraza (26) dan je izraz za izračun masenog udjela natovarenosti vozila, odnosno masenog pokazatelja učinkovitosti:

$$N_m = \frac{m_p}{n_v} \cdot 100 \text{ [\%]} \tag{27}$$

pri čemu je:

m_p- masa paketskih pošiljaka u vozilu (kg)
n_v – nosivost vozila (kg).

Također dan je izraz za izračun volumenskog udjela natovarenosti vozila, odnosno volumenskog pokazatelja učinkovitosti:

$$N_v = \frac{V_p}{V_v} \cdot 100 \text{ [\%]} \tag{28}$$

pri čemu je:

V_p – volumen paketskih pošiljaka u vozilu (m^3)

V_v – zapremina teretnog prostora vozila (m^3).

Izraz za izračun masenog udjela natovarenosti vozila odnosno za izračun volumenskog udjela natovarenosti vozila koristi se za izračun trenutne natovarenosti (mase ili volumena) vozila, te kod primjene prognostičkog modela za izračun predviđene natovarenosti vozila.

Stvarna količina supstrata, u ovom slučaju masa ili volumen paketskih pošiljaka u prijevoznom sredstvu, predstavlja stvarni učinak, dok nazivna nosivost odnosno nazivna zapremina teretnog prostora predstavlja mogući učinak [112].

Tvrtke za prijevoz robe često upotrebljavaju oko 60% raspoložive nosivosti svojih vozila. Na uzorku od pedeset tri vozna parka u britanskom lancu opskrbe hranom istraživanje je pokazalo da je prosječna masena iskorištenost vozila 69% [112].

Istraživanje u području učinkovitost prijevoza paketskih pošiljaka na davateljima poštanskih usluga u Velikoj Britaniji, od poštanskih ureda do hub-ova (u kojima se vršio istovar i utovar paketskih pošiljaka) i nazad, pokazalo je da je prosječna volumenska iskorištenost vozila na početku svakog putovanja bila 44%, pri čemu je šest od osam voznih parkova imalo iskorištenost ispod 55%. Prosječna volumenska iskorištenost na kraju svakog putovanja bila je 40%, gdje je pet od osam voznih parkova imalo iskorištenost ispod 30%. Ukupna prosječna volumenska popunjenost vozila, uzimajući u obzir početak i kraj putovanja za svaki vozni park, iznosila je 42% [29] iz čega se zaključuje da vozni park nije optimiziran.

U Nizozemskoj je provedeno istraživanje na pet različitih prijevoznika. Analizirano je 150 putovanja na kojima se prevozio generalni teret. Što se tiče mjerenja volumenske iskorištenosti vozila istraživanje je pokazalo da je prosječni iskorišteni volumenski kapacitet bio 82%. Gotovo je polovica putovanja bila 90% puna, a minimalna iskorištenost kapaciteta na temelju volumena bila je 38%. Istražena je i masena iskorištenost. Prosječni iskorišteni

maseni kapacitet bio je 57%. Samo u nekoliko putovanja bilo je potpuno natovareno. Samo jedno od šest putovanja imalo je masenu iskorištenost kapaciteta preko 90%. Minimalna masena iskorištenost kapaciteta bila je 10% [27].

Istraživanje provedeno na tri vodeće Švedske tvrtke za prijevoz tereta, gdje je analizirano 263 prijevoza, pokazalo je prosječnu stopu volumenske iskorištenosti vozila 61,2% [31].

Referentni interval iskorištenosti kapaciteta prijevoznih sredstava poduzeća samostalno odabiru prema svojoj poslovnoj politici [27]. S druge strane može se vidjeti da su istraživanja pokazala različite vrijednosti pokazatelja učinkovitosti prijevoza. Maseni pokazatelj učinkovitosti prijevoza bio je u granicama od 10% do 100% s time da je prosječna masena iskorištenost bila 57%, 60% i 69%. Volumenski pokazatelj učinkovitosti prijevoza bio je u granicama od 30% do 90% s tim da je prosječna volumenska iskorištenost bila 42%, 61,2% i 82%.

Kod odabranog davatelja poštanskih usluga upotrebom geometrijske sredine verižnih indeksa kretanja broja paketskih pošiljaka utvrđena je prosječna godišnja stopa rasta broja paketskih pošiljaka.

Vrijednost geometrijske sredine verižnih indeksa kretanja paketskih pošiljaka u razdoblju od 2009. do 2016. godine ukazuje na prosječnu godišnju stopu rasta paketskih pošiljaka za 10% godišnje.

U slučaju popunjenosti kapaciteta od 90% u tekućoj godini dostupni vozni park može prevesti pakete i u narednoj godini budući da je prema članku 228. Zakona o javnoj nabavi u otvorenom postupku velike vrijednosti minimalni rok za dostavu ponuda 35 dana od dana slanja poziva na nadmetanje. To ne uključuje rok isporuke objekta nabavke, vrijeme potrebno za sastavljanje natječaja, žalbeni rok i sl., iz čega se može utvrditi da od pokretanja inicijative za nabavkom do realizacije prođe vremenski rok do godinu dana [120].

Stoga je kod primjene metodologije za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unaprjeđenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu uzeta donja vrijednosti masenog i volumenskog pokazatelja učinkovitosti prijevoza od 60%, dok je za gornju granicu za oba pokazatelja uzeta vrijednost 90%.

Optimalnom učinkovitošću smatra se vrijednost volumenskog i masenog pokazatelja u rasponu od 60% do 90% gdje u slučaju odstupanja izvan prihvatljivog raspona postoji potreba za korekcijom kapaciteta vozila. Prihvatljive razine masenog udjela natovarenosti vozila,

odnosno masenog pokazatelja učinkovitosti te volumenskog udjela natovarenosti vozila, odnosno volumenskog pokazatelja učinkovitosti u funkciji prijevoza između entiteta poštanske mreže prikazane su tablicom 26.

Tablica 26. Prihvatljive razine masenog i volumenskog udjela natovarenosti vozila u funkciji prijevoza između entiteta mreže

Učinkovitost	
$\langle 90\%, 100\%]$	Manjak kapaciteta
$[60\%, 90\%]$	Prihvatljivi kapaciteti
$[0\%, 60\%\rangle$	Višak kapaciteta

Radnje koje je potrebno napraviti kako bi se dobila prihvatljiva razina natovarenosti vozila, odnosno pokazatelji učinkovitosti prijevoza prikazane su matricom natovarenosti vozila u tablici 27. gdje korištene vrijednosti predstavljaju granične vrijednosti kod utvrđivanja potreba za korekcijama kapaciteta prijevoznih sredstava i unapređenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu.

Tablica 27. Matrica natovarenosti vozila

	Volumenski pokazatelj učinkovitosti		
Maseni pokazatelj učinkovitosti	$[0\%, 60\%\rangle$	$[60\%, 90\%]$	$\langle 90\%, 100\%]$
$[0\%, 60\%\rangle$	Smanjiti ukupan kapacitet vozila	Smanjiti nosivost vozila	Povećati volumen teretnog prostora vozila i smanjiti nosivost vozila
$[60\%, 90\%]$	Smanjiti volumen teretnog prostora vozila	Optimalno rješenje	Povećati volumen teretnog prostora vozila
$\langle 90\%, 100\%]$	Povećati nosivost vozila i smanjiti volumen teretnog prostora vozila	Povećati nosivost vozila	Povećati ukupni kapacitet vozila

Definiranje metodologije za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unapređenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu sastoji se od šest koraka:

1. Utvrditi trenutni broj paketskih pošiljaka
2. Utvrditi prosječnu masu i volumen paketskih pošiljaka
3. Utvrditi broj paketskih pošiljaka između entiteta poštanske mreže upotrebom podataka o udjelu broja paketskih pošiljaka svake od linija u ukupnom broju paketskih pošiljaka,
4. Prognostičkim modelom prognozirati broj paketskih pošiljaka,
5. Istražiti mogućnost postojećeg voznog parka za adekvatan prijevoz prognoziranog broja paketskih pošiljaka određivanjem:
    - Broja paketskih pošiljaka,
    - Nosivosti vozila,
    - Zapremnine teretnog prostora,
    - Prosječne mase paketskih pošiljaka,
    - Prosječnog obujma paketskih pošiljaka.

Gdje su mogući sljedeći ishodi:

- Maseni i volumenski udio natovarenosti vozila u rasponu od 60% – 90% → optimalne razine pokazatelja učinkovitosti, nema potrebe za korekcijom,
- Maseni udio natovarenosti vozila u rasponu od 60% - 90%, dok je volumenski udio natovarenosti vozila ispod 60 % → potrebna nabavka vozila manje zapremine teretnog prostora uz zadržavanje iste nosivosti vozila,
- Maseni udio natovarenosti vozila u rasponu od 60% - 90%, dok je volumenski udio natovarenosti vozila iznad 90% → potrebna nabavka vozila s većom zapreminom teretnog prostora uz zadržavanje iste nosivosti vozila,
- Masena i volumenska iskorištenost kapaciteta su ispod 60% → potrebna nabavka vozila manjeg masenog i volumenskog kapaciteta,
- Maseni udio natovarenosti vozila ispod 60%, dok je volumenski udio natovarenosti vozila u rasponu od 60% - 90% → potrebna nabavka vozila s istom zapreminom teretnog prostora, ali s manjom nosivosti,
- Maseni udio natovarenosti vozila ispod 60%, dok je volumenski udio natovarenosti vozila iznad 90% → potrebna nabavka vozila s većom zapreminom teretnog prostora, ali s manjom nosivosti,

- Maseni i volumenski udio natovarenosti vozila u iznad 90% → potrebna nabavka vozila s većom zapreminom teretnog prostora i većom nosivosti,
- Maseni udio natovarenosti vozila iznad 90%, dok je volumenski udio natovarenosti vozila ispod 60% → potrebna nabavka vozila s manjom zapreminom teretnog prostora, ali s većom nosivosti,
- Maseni udio natovarenosti vozila iznad 90%, dok je volumenski udio natovarenosti vozila u rasponu od 60% - 90% → potrebna nabavka vozila s istom zapreminom teretnog prostora, ali s većom nosivosti.

6. Ako razina masenog i volumenskog udjela natovarenosti vozila nije u rasponu od 60% do 90%, ponovno odrediti potreban kapacitet prijevoznih sredstava.

Na slici 61. prikazan je dijagram toka kojim se omogućuje analiza prijevoznih kapaciteta i optimizacija voznog parka

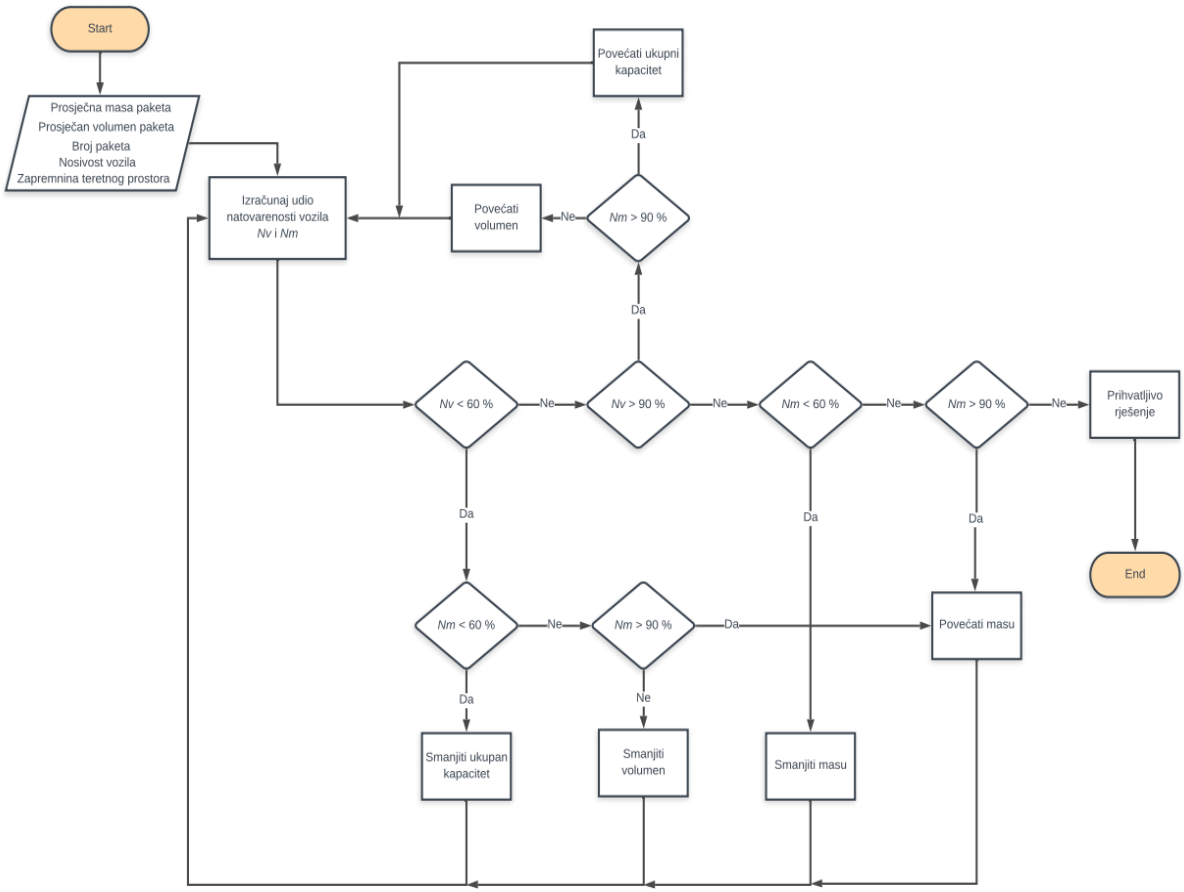

Slika 61. Dijagram toka za utvrđivanje prihvatljivih kapaciteta prijevoznih sredstava u poštanskom prometu

5.4. Primjena metodologije između entiteta poštanske mreže

Kako bi se utvrdila potreba za budućim kapacitetima prijevoznih sredstava, potrebno je najprije vrednovati učinkovitost prijevoza. Zatim je potrebno primijeniti prognostički model broja paketskih pošiljaka kako bi se utvrdila prihvatljivost kapaciteta voznog parka na prognoziranom broju paketskih pošiljaka u budućim razdobljima. Upotrebom predložene metodologije određuju se potrebni kapaciteti prijevoznih sredstava čime se unapređuje učinkovitost prijevoza paketskih pošiljaka u poštanskom prometu. Temeljem utvrđenih potreba za budućim kapacitetima prijevoznih sredstava može se odabrati odgovarajuće prijevozno sredstvo kako bi se unaprijedila učinkovitost prijevoza.

Kod odabranog davatelja poštanskih usluga provedeno je istraživanje učinkovitost prijevoza paketskih pošiljaka. Za istraživanje učinkovitosti prijevoza korištena je baza podataka o tehničkim karakteristikama vozila na svim relacijama (vrsta, zapremina teretnog prostora i nosivost vozila), o količini pošiljaka (ukupnoj masi i volumenu) u vozilu na relacijama, te volumenskoj i masenoj natovarenosti vozila.

U nastavku je prikazana dopuštena nosivost i zapremina vozila koja se koriste za prijevoz paketskih pošiljaka između entiteta poštanske mreže (Tablica 28.). Promatrani davatelj poštanskih usluga prevezao je u godini dana 4,690 milijuna paketskih pošiljaka.

Analiza je napravljena na 332 vozila koja su prevozila poštanske pošiljke na području pojedinih županija te 39 vozila koja su obavljala prijevoz poštanskih pošiljaka između županija u razdoblju od jedne godine.

Tablica 28. Masena i volumenska specifikacija vozila odabranog davatelja poštanskih usluga

Vozilo	Broj vozila	Dopuštena nosivost (kg)	Zapremnina teretnog prostora (m^3)
Teretno vozilo A	7	768	3
Teretno vozilo B	138	1.294	11
Teretno vozilo C	115	1.368	15
Teretno vozilo D	63	1.181	17
Teretno vozilo E	15	4.500	31
Teretno vozilo F	4	7.900	35
Teretno vozilo G	20	9.900	40

Izvor: Autor uredio prema internim podatcima davatelja poštanskih usluga

Iz tablice 28. može se vidjeti da je raspon masenog kapaciteta vozila odabranog davatelja poštanskih usluga 9.132 kilograma (od 768 kg do 9.900 kg) i 37 m^3 tovarnog prostora (od 3 m^3 do 40 m^3).

Rezultati analize usklađenosti mase i volumena kod županijskog i međužupanijskog prijevoza dani su u tablici 29.

Tablica 29. Prosječni udio masene i volumenske natovarenosti voznog parka

	Udio natovarenosti vozila po masi (%)	**Udio natovarenosti vozila po volumenu (%)**
Županijski prijevoz	53,67%	64,01%
Međužupanijski prijevoz	87,70%	89,36%

Izvor: Autor uredio prema internim podatcima davatelja poštanskih usluga

Prosječni maseni i volumenski udio natovarenosti vozila je veći kod međužupanijskog prijevoza te se nalazi unutar referentnog metodološkog raspona između 60% i 90%, dok je kod županijskog prijevoza utvrđeno odstupanje masenog udjela natovarenosti u odnosu na referentni raspon. Prosječni udio volumenske natovarenosti je unutar referentnog raspona iz čega se može utvrditi potreba za utvrđivanjem prihvatljivih kapaciteta prijevoznih sredstava u voznom parku.

Analiza udjela natovarenosti prema tipu vozila prikazana je tablicom 30. Na relacijama je prometovalo sedam vrsta vozila. Prema tehničkim karakteristikama vozila i količini paketskih pošiljaka u prijevoznom sredstvu izračunat je udio natovarenosti vozila, odnosno pokazatelji učinkovitosti.

Tablica 30. Udio natovarenosti vozila prema vrsti vozila

Vozilo	**Broj vozila**	**Maseni udio natovarenost (%)**	**Volumenski udio natovarenost (%)**
Teretno vozilo A	7	16,09%	53,57%
Teretno vozilo B	138	42,32%	58,96%
Teretno vozilo C	115	60,87%	67,10%
Teretno vozilo D	63	71,28%	72,13%
Teretno vozilo E	15	80,08%	80,67%
Teretno vozilo F	4	**94,94%**	**97,50%**
Teretno vozilo G	20	87,71%	91,25%

Izvor: Autor uredio prema internim podatcima davatelja poštanskih usluga

Najveću natovarenost po volumenu i masi ima teretno vozilo F gdje je udio natovarenosti po masi i po volumenu iznad gornje granice referentnog intervala od 90%. Teretna vozila A i teretna vozila B bilježe u prosjeku potkapacitiranost budući da je prosječan udio masene i volumenske natovarenosti ispod donje granične vrijednosti metodološkog referentnog intervala od 60%. Navedeno je posljedica prometovanja na relacijama s malom koncentracijom stanovnika.

Kod svih vrsta vozila natovarenost vozila po volumenu je veća u odnosu na natovarenost vozila po masi. Vozila imaju veću nosivost u odnosu na volumen, odnosno u prosjeku nije moguće natovariti vozilo do razine dozvoljene nosivosti izuzev teretnih vozila D, E, F i G.

Nadalje, analizirana je učinkovitost prijevoza paketskih pošiljaka na četiri linije između entiteta poštanske mreže kako bi se dobio uvid u postojeće stanje masenog i volumenskog udjela natovarenosti vozila između entiteta poštanske mreže te se prezentira učinkovitost prijevoza na prognoziranom broju paketskih pošiljaka u 2019. godini.

Provedena je analiza na dvjema linijama između poštanskih središta te dvjema linijama između poštanskih središta i poštanskih ureda u 2015. godini kako bi se prikazao udio promatrane linije u ukupnom broju paketskih pošiljaka prevezenim na svim linijama promatranog davatelja poštanskih usluga. U tablicama 31. i 32. prikazan je ukupan broj paketskih pošiljaka prevezen u godini dana te godišnji prosjek masenog i volumenskog udjela natovarenosti vozila na promatranim linijama.

Tablica 31. Linije između poštanskog središta i ureda

Linija	**Vozilo**	**Udio linije**	**Broj paketskih pošiljaka**	**Udio volumenske natovarenost (%)**	**Udio masene natovarenost (%)**
Linija 1	Teretno vozilo E	1.13%	35.721	100.00	88.89
Linija 2	Teretno vozilo C	0.11%	3.572	20.00	29.24

Na Liniji 1 prometovalo je teretno vozilo E koje je prevezlo 1,13% ukupnog broja paketskih pošiljaka promatranog davatelja poštanskih usluga (35.721 paketskih pošiljaka). Utvrđen je udio volumenske natovarenosti vozila koja prelazi graničnu vrijednost od 90%, odnosno postoji potreba za povećanjem volumenskih kapaciteta, dok je udio masene natovarenosti vozila ispod granične vrijednosti od 90%.

Problem neadekvatnih kapaciteta (manjak) rješava se vozilom većeg volumenskog i masenog kapaciteta, i to teretnim vozilom F koje omogućuje smanjenje volumenskog udjela natovarenosti ispod granične vrijednosti od 90%. Vozilo se može pribaviti iz postojećeg voznog parka zamjenom teretnog vozila E na liniji gdje postoji višak kapaciteta, a na kojoj se koristi teretno vozilo F. U slučaju da ne postoji dostupno teretno vozilo F, potrebno je iz eksternih izvora kupiti novo vozilo, i to vozilo suvremenih tehničkih specifikacija koje omogućuje smanjenje potrošnje fosilnih goriva i smanjenje emisije štetnih plinova.

Na Liniji 2 prometovalo je teretno vozilo C koje je prevezlo 0,11% ukupnog broja paketskih pošiljaka promatranog davatelja poštanskih usluga (3.572 paketskih pošiljaka), te je utvrđen udio volumenske i masene natovarenosti vozila koja je ispod granične vrijednosti od 60%, odnosno postoji potreba za smanjenjem masenih i volumenskih kapaciteta.

Ovdje se problem neadekvatnih kapaciteta (višak) rješava nabavkom vozila manjeg volumenskog i masenog kapaciteta i to teretnog vozila B koje omogućava povećanje masenog i volumenskog udjela natovarenosti u prihvatljivu razinu od 60% od 90%. Vozilo se može pribaviti iz postojećeg voznog parka zamjenom teretnog vozila B na liniji gdje postoji višak kapaciteta, a na kojoj se koristi teretno vozilo B. U slučaju da ne postoji dostupno teretno vozilo B, potrebno je iz eksternih izvora kupiti novo vozilo, i to vozilo suvremenih tehničkih specifikacija koje omogućuje smanjenje potrošnje fosilnih goriva i smanjenje emisije štetnih plinova.

Tablica 32. Linije između poštanskih središta

Linija	**Vozilo**	**Udio linije**	**Broj paketskih pošiljaka**	**Udio volumenske natovarenost (%)**	**Udio masene natovarenost (%)**
Linija 3	Teretno vozilo E	1.19%	37.507	100.00	93.33
Linija 4	Teretno vozilo E	0.23%	7.144	100.00	88.89

Na Liniji 3 prometovalo je teretno vozilo E koje je prevezlo 1,19% ukupnog broja paketskih pošiljaka promatranog davatelja poštanskih usluga (37.507 paketskih pošiljaka) te je utvrđen udio masene i volumenske natovarenosti vozila koji prelazi granične vrijednosti od 90%, odnosno postoji potreba za povećanjem volumenskih i masenih kapaciteta.

Problem neadekvatnih kapaciteta (manjak) rješava se nabavkom vozila većih volumenskih i masenih kapaciteta, i to teretnog vozila F koje omogućuje smanjenje masenog i volumenskog udjela natovarenosti ispod granične vrijednosti od 90%. Vozilo se može pribaviti iz postojećeg voznog parka zamjenom postojećeg teretnog vozila E na liniji gdje postoji višak kapaciteta, a na kojem se koristi teretno vozilo F. U slučaju da ne postoji dostupno teretno vozilo F, potrebno je iz eksternih izvora kupiti novo vozilo, i to vozilo suvremenih tehničkih specifikacija koje omogućuje smanjenje potrošnje fosilnih goriva i smanjenje emisije štetnih plinova.

Na Liniji 4 prometovalo je teretno vozilo E koje je prevezlo 0.23% ukupnog broja paketskih pošiljaka promatranog davatelja poštanskih usluga (7.144 paketskih pošiljaka) te je utvrđen udio volumenske natovarenosti vozila koji prelazi graničnu vrijednost od 90%, odnosno postoji potreba za povećanjem volumenskih kapaciteta, dok je udio masene natovarenosti vozila ispod granične vrijednosti od 90%.

Problem neadekvatnih kapaciteta (manjak) rješava se nabavkom vozila većih volumenskih i masenih kapaciteta, i to teretnog vozila F koje omogućuje smanjenje udjela masene i volumenske natovarenosti ispod granične vrijednosti od 90%. Vozilo se može pribaviti iz postojećeg voznog parka zamjenom postojećeg teretnog vozila E na liniji gdje postoji višak kapaciteta, a na kojoj se koristi teretno vozilo F. U slučaju da ne postoji dostupno teretno vozilo F, potrebno je iz eksternih izvora kupiti novo vozilo, i to vozilo suvremenih tehničkih specifikacija koje omogućuje smanjenje potrošnje fosilnih goriva i smanjenje emisije štetnih plinova.

Prema procijenjenom modelu za 2019. godinu se očekuje 23.325.100 paketskih pošiljaka u Republici Hrvatskoj. Daljnji izračuni su rađeni temeljem podataka o tržišnom udjelu promatranog davatelja poštanskih usluga.

Primjenom definirane metodologije na četiri odabrane linije za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unaprjeđenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu promatrana je adekvatnost postojećih prijevoznih kapaciteta za zadovoljenje prijevoznih potreba u 2019. godini, što se može vidjeti u tablicama 33. i 34.

Tablica 33. Linije između poštanskog središta i ureda na procijenjenom broju paketskih pošiljaka u 2019. godini

Linija	Vozilo	Udio linije	Broj paketskih pošiljaka	Udio volumenske natovarenost (%)	Udio masene natovarenost (%)
Linija 1	Teretno vozilo E	1.13%	74.499	202,07	179,62
Linija 2	Teretno vozilo C	0.11%	7.450	40,41	59,08

Primjenom predložene metodologije na Liniji 1 utvrđeno je da postoji potreba za 2,02 postojeća kapaciteta volumenskog prostora teretnog vozila nosivosti do 4,5 tone te 1,80 postojećih masenih kapaciteta vozila nosivosti do 4,5 tone, iz čega se može utvrditi da je potrebno povećati prijevozne kapacitete teretnim vozilom s većim masenim i volumenskim kapacitetima. Prema definiranoj metodologiji potrebna je korekcija, dok masena i volumenska natovarenost ne budu u intervalu od 60% do 90% iskorištenosti kapaciteta. Problem neadekvatnih kapaciteta (manjak) rješava se nabavkom vozila većih volumenskih i masenih kapaciteta, i to teretnog vozila nosivosti koje prelazi 9,4 tona te volumena koji prelazi 70 m^3 koje omogućuje smanjenje udjela masene i volumenske natovarenosti ispod granične vrijednosti od 90%. U slučaju da ne postoji dostupno teretno vozilo čija nosivost prelazi 9,4 tona i ima volumenske kapacitete koji prelaze 70 m^3, potrebno je iz eksternih izvora kupiti novo vozilo, i to vozilo suvremenih tehničkih specifikacija koje omogućuje smanjenje potrošnje fosilnih goriva i smanjenje emisije štetnih plinova.

Na Liniji 2 utvrđeno je da će postojeće vozilo zadovoljiti prijevozne potrebe i u 2019. godini gdje se javlja potreba za vozilom manje zapremine teretnog prostora uz zadržavanje iste nosivosti vozila. Ovdje se problem neadekvatnih kapaciteta (višak) rješava nabavkom vozila manjeg volumenskog i masenog kapaciteta, i to teretnog vozila B koje omogućava povećanje masenog i volumenskog udjela natovarenosti u prihvatljivu razinu od 60% od 90%. Vozilo se može pribaviti iz postojećeg voznog parka zamjenom teretnog vozila B na liniji gdje postoji višak kapaciteta, a na kojoj se koristi teretno vozilo B. U slučaju da ne postoji dostupno teretno vozilo B, potrebno je iz eksternih izvora kupiti novo vozilo, i to vozilo suvremenih tehničkih specifikacija koje omogućuje smanjenje potrošnje fosilnih goriva i smanjenje emisije štetnih plinova.

Tablica 34. Linije između poštanskih središta na procijenjenom broju paketskih pošiljaka u 2019. godini

Linija	Vozilo	Udio linije	Broj paketskih pošiljaka	Udio volumenske natovarenost (%)	Udio masene natovarenost (%)
Linija 3	Teretno vozilo E	1.19%	78.224	202,07	188,59
Linija 4	Teretno vozilo E	0.23%	14.899	202,07	179,62

Primjenom predložene metodologije na Liniji 3 utvrđeno je da postoji potreba za 2,02 postojeća kapaciteta volumenskog prostora teretnog vozila nosivosti do 4,5 tone, te 1,89 postojećih masenih kapaciteta vozila nosivosti do 4,5 tone iz čega proizlazi potreba za povećanjem volumenskih i masenih kapaciteta. Problem neadekvatnih kapaciteta (manjak) rješava se nabavkom vozila većih volumenskih i masenih kapaciteta, i to teretnog vozila nosivosti koje prelazi 9,40 tone te volumena koji prelazi 70 m^3 koje omogućuje smanjenje udjela masene i volumenske natovarenosti ispod granične vrijednosti od 90%. U slučaju da ne postoji dostupno teretno vozilo čija nosivost prelazi 9,4 tone te volumena koji prelazi 70 m^3, potrebno je iz eksternih izvora kupiti novo vozilo, i to vozilo suvremenih tehničkih specifikacija koje omogućuje smanjenje potrošnje fosilnih goriva i smanjenje emisije štetnih plinova.

Na Liniji 4 utvrđeno je da postoji potreba za 2,02 postojećih kapaciteta volumenskog prostora teretnog vozila nosivosti do 4,5 tone, te 1,80 postojećih masenih kapaciteta vozila nosivosti do 4,5 tone iz čega se može utvrditi da je potrebno povećat prijevozne kapacitete teretnim vozilom s većim masenim i volumenskim kapacitetima. Ovdje se također problem neadekvatnih kapaciteta (manjak) rješava nabavkom vozila većih volumenskih i masenih kapaciteta, i to teretnog vozila nosivosti koje prelazi 9,4 tone te volumenskog kapaciteta koji prelazi 70 m^3 koje omogućuje smanjenje udjela masene i volumenske natovarenosti ispod granične vrijednosti od 90%. U slučaju da ne postoji dostupno teretno vozilo čija nosviost prelazi 9,4 tona te volumenskog kapaciteta koji prelazi 70 m^3, potrebno je iz eksternih izvora kupiti novo vozilo, i to vozilo suvremenih tehničkih specifikacija koje omogućuje smanjenje potrošnje fosilnih goriva i smanjenje emisije štetnih plinova.

Istraživanjem je utvrđeno da je upotrebom regresijskih modela moguće procijeniti broj paketskih pošiljaka u Republici Hrvatskoj, dok se upotrebom podatka o tržišnom udjelu može predvidjeti očekivan broj paketskih pošiljaka za svakog od davatelja poštanskih usluga na nacionalnoj razini. Uzorkom je utvrđena prosječna masa i volumen paketskih pošiljaka što je

osnova za primjenu predložene metodologije kojom se omogućuje optimizacija voznog parka davatelja poštanskih usluga. Stoga korištenje mase i volumena paketskih pošiljaka te njihov broj predstavljaju moguću podlogu za upravljanje voznim parkom kako bi se poboljšala njegova učinkovitost. Svi koraci u predloženoj metodologiji primjenjivi su u poslovanju davatelja poštanskih usluga, u organizaciji poštanske mreže između jedinica mreže u urbanim i suburbanim područjima. Na četiri odabrane linije analizirana je i potvrđena primjenjivost modela za utvrđivanje prihvatljivih kapaciteta prijevoznih sredstava u poštanskom prometu u praksi.

6. ZAKLJUČAK

Na svjetskom, europskom pa tako i hrvatskom tržištu kurirskih, ekspresnih i paketskih pošiljaka dolazi do povećanja broja pošiljaka. Njihovom povećanju zasigurno je pridonjela e-trgovina. Tako se u paketskom prometu povećava broj paketskih pošiljaka u unutarnjem i međunarodnom prometu s time da međunarodne pošiljke imaju brži rast. Najviše proizvoda online kupuje se iz Kine, Velike Britanije, Njemačke i SAD-a, a što sigurno utječe na rast paketskih pošiljaka u međunarodnom prometu. Republika Hrvatska također slijedi ovaj trend.

Istraživanja u zemljama Europe su pokazala da se mase običnih i ekspresnih paketskih pošiljaka mijenjaju, stoga je za potrebe ovog istraživanja istražena masa paketskih pošiljaka u Republici Hrvatskoj čija prosječna vrijednost iznosi 3,77 kg. Također je istražen i volumen paketkih pošiljaka u Republici Hrvatskoj čija prosječna vrijednost iznosi 29.600,73 cm^3, odnosno 0,03 m^3 što je manje od prosječnog volumena paketskih pošiljaka u EU, a koji iznosi 0,06 m^3. Ovo je bitno jer rast broja paketskih pošiljaka utječe na okoliš zbog zahtjeva za više prijevoznih kapaciteta u odnosu na pismovne pošiljke. Pojava COVID-Sars2 povećala je kupovinu putem Interneta odnosno e-trgovinom što također utječe na povećanje potražnje za paketskim uslugama.

Kako bi se zadovoljio zahtjev za potrebnim prijevoznim kapacitetima na paketskom tržištu i povećala učinkovitost prijevoza, analizirani su čimbenici koji utječu na broj paketskih pošiljaka, primijenjeni su metodološki postupci za izradu prognostičkog modela broja paketskih pošiljaka te napravila metodologija koja omogućuje utvrđivanje potrebnih kapaciteta prijevoznih sredstava.

Krenulo se s 30 nezavisnih varijabli kojima su obuhvaćeni ekonomski, tehničko-tehnološki, poštanski i demografski čimbenici za koje se očekivalo da će utjecati na broj paketskih pošiljaka. Prije procjene prognostičkih modela temeljene na dvanaestogodišnjim podatcima (2007.-2018. godina) upotrebom korelacijske analize ispitana je prisutnost povezanosti među varijablama. U daljnjem koraku su upotrebom stepwise forward postupka izrađena dva modela. Linearni regresijski model s trendom te linearni regresijski model bez trenda. Uz detaljno analizirane čimbenike koji utječu na broj paketskih pošiljaka, primjenom deskriptivne i korelacijske analize, logično je bilo uključiti i varijablu trend jer je broj paketskih pošiljaka zavisan o promjeni vremena promatranja. Iako je linearni regresijski model s trendom pokazao veću preciznost procjene primjereniji za buduće projekcije

paketskih pošiljaka je linearni regresijski model bez trenda, koji također ima veliku preciznost procjene, ali ne sadrži varijablu fiksne telefonske linije koja ima tendenciju opadanja na važnosti radi svoje tehnološke zastarjelosti.

Nakon provedenog istraživanja utvrđen je statistički značajan utjecaj broja Internet kupaca i BDP-a po stanovniku na kretanje broja paketskih pošiljaka. Za obje varijable je utvrđen pozitivan utjecaj na kretanje broja paketskih pošiljaka, odnosno porast broja Internet kupaca doprinosi porastu broja paketskih pošiljaka. Porastom BDP-a po stanovniku dolazi također do porasta broja paketskih pošiljaka. Veći je utjecaj na kretanje broja paketskih pošiljaka utvrđen kod varijable broja Internet kupaca u odnosu na BDP po stanovniku, slijedom čega se potvrđuje hipoteza H1 kojom se pretpostavlja da se analizom čimbenika koji utječu na broj paketskih pošiljaka u poštanskom prometu može utvrditi njihova nejednakost postojanja i vrijednosti ovisnosti.

Upotrebom definirane metodologije koja koristi maseni i volumenski pokazatelj učinkovitosti vozila kod svake linije između poštanskih entiteta omogućuje se uvid u postojanje podkapacitiransti ili prekapacitirnosti, čime se indicira na potrebu za korekcijom, te se potvrđuje hipoteza rada H2 da je vrednovanjem pokazatelja učinkovitosti prijevoza moguće unaprijediti proces planiranja kapaciteta potrebnih prijevoznih sredstava.

Temeljem koeficijenata linearne regresije vrednovanih čimbenika utjecaja na broj paketskih pošiljka u poštanskom prometu izrađena su dva regresijska modela te je odabran model prognoziranja paketskih pošiljaka koji sadržava čimbenike: Internet kupci i BDP po stanovniku. Vrednovanjem utjecaja pojedinih čimbenika na broj paketskih pošiljaka u poštanskom prometu, te izradom prognostičkog modela broja paketskih pošiljaka ostvaren je znanstveni doprinos D1.

Kako bi se zadovoljio zahtjev za potrebnim prijevoznim kapacitetima na paketskom tržištu i povećala učinkovitost prijevoza pored izrade regresijskog modela, potrebna je odgovarajuća metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava. Definiranom metodologijom za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i unaprjeđenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu ostvaren je znanstveni doprinos D2. Da bi se unaprijedila učinkovitost prijevoza paketskih pošiljaka, potreban je prognostički model te maseni i volumenski pokazatelj učinkovitosti prijevoza.

Primjenom postupka na četiri linije između entiteta poštanske mreže dokazano je da predložena metodologija za utvrđivanje potrebnih kapaciteta prijevoznih sredstava i

unaprjeđenje učinkovitosti prijevoza paketskih pošiljaka u poštanskom prometu omogućuje uvid u postojeće i buduće stanje iskorištenosti prijevoznih kapaciteta, odnosno pruža mogućnost sustavnog vrednovanja i optimiziranja voznog parka.

Regresijski model predstavlja vrijedan alat za predviđanje broja paketskih pošiljaka u poštanskom prometu Republike Hrvatske, što su pokazale analiza reprezentativnosti i validacija modela, a koji davateljima poštanskih usluga zajedno s pokazateljima učinkovitosti prijevoza i predloženom metodologijom omogućava donošenje zaključaka i odgovarajućih odluka o potrebnim kapacitetima prijevoznih sredstava.

LITERATURA

[1] Grünert T, Sebastian H-J, Thärigen M. The design of a letter-mail transportation network by intelligent techniques. In: Proceedings of the 32nd Hawaii International Conference on System Sciences, 1999, USA

[2] Song Q, Zhang C, Li X, Hao F. Genetic algorithm based modeling and optimization of the borough postal transportation network. In: 46th IEEE Conference on Decision and Control, December 12-14 2007, New Orleans, LA, USA

[3] Song Q, Wang X, Li X, Zhang C. Optimization of postal express mail network based on swarm intelligence. In: Joint 48th IEEE Conference on Decision and Control and 28th Chinese Control Conference, 16 - 18 December 2009, Shanghai, China

[4] Syberfeldt A, Grimm H, Ng A, Andersson M, Karlsson, I. Simulation-based optimization of a complex mail transportation network. In: Proceedings of the 2008 Winter Simulation Conference, 2008, Miami, FL , USA

[5] Blagojević M. et al. Determining the number of postal units in the network – Fuzzy approach, Serbia case study. Expert systems with Applications. 2013; Vol. 40: 4090-4095.

[6] Lee J-H, Moon I. A hibrid hub-and-spoke postal logistics network with realistic restrictions: A case study of Korea Post. Expert Systems with Applications. 2014; Vol. 41: 5509-5519.

[7] Hensher D A, Ton T T. A comparison of the predictive potential of artificial neural networks and nested logit models for commuter mode choice. Transportation Research Part E 36. 2000; 155-172.

[8] Aguilar D P. A Radial Basis Neural Network for the Analysis of Transportation Dana. Graduate Theses and Dissertations, College of Engineering: University of South Florida; 2004.

[9] Jugović A, Hess S, Poletan Jugović T. Traffic Demand Forecasting for Port Services. Promet Traffic&Transportation. 2011; Vol. 23, No. 1: 59-69.

[10] Samimia A, Kawamurab K, Mohammadianc A. A behavioral analysis of freight mode choice decisions. Transportation Planning and Technology. 2011; Vol. 34, No. 8: 857-869.

[11] Xu S. et al. Linear Regression Prediction Model of Prefecture level Highway Passenger Transport Volume. In: International Conference on Electronic & Mechanical Engineering and Information Technology, August 12-14 2011, Harbin, China

[12] Krasić D, Novačko L. The Impact of Public Transport Network Accessibility on Trip Generation Model. Promet – Traffic&Transportation. 2015; Vol. 27, No. 2: 165-172.

[13] European Commission, DG Internal Market and Services: Main developments in the postal sector (2006-2008), ECORYS Nederland BV, September 2008.

[14] Universal Postal Union: Market Research on International Letters and Lightweight Parcels and Express Mail Service Items, International Bureau of the UPU, 2010.

[15] T. Kljak, M. Bolarić, M. Binički. Impact of Mobile Telecommunications Traffic on the Development of Postal Traffic, Promet – Traffic&Transportation, 2011; Vol. 23, No. 5: 359-365.

[16] Knežević N, et al. A Two-Level Approach for Human Resource Planning Towards Organizational Efficiency of a Postal Distribution System. Economic Computation and Economic Cybernetics Studies and Research. 2011; Vol. 45 No. 4: 155-168.

[17] Farajpour G. Forecasting postage traffic using principal component analysis and artificial neural network. African Journal of Business Management. 2012; Vol 6 (33): 9496-9503.

[18] Matović V, Dobrodolac M. Forecasting the Number of Postal Services in the Region of South East Europe. HORIZONS.B. 2016; 571-579. Dostupno na: http://www.uklo.edu.mk/filemanager/HORIZONTI%202017/Horizonti%20serija%20B/VIII-03.Matovic_Vitomir_FORECASTING%20THE%20NUMBER%20OF.pdf

[19] Seo S., Ahn C., Lee J.-S. Developing a Parcel Freight O-D and Identifying Parcel Freight Determinants for Seoul Metropolitan Area. MetroFreight Center of Excellence. The Korea Transport Institute. Report number: 16-1.1d, 2016.

[20] McKinnon A C, Stirling I, Kirkhope J. Fuel Efficiency of Road Freight Operations. International Journal of Physical Distribution & Logistics Management. 1993; Vol. 23, No. 9: 3-11.

[21] McKinnon A C. A Logistical Perspective on the Fuel Efficiency of Road Freight Transport, Workshop on Improving of Fuel Efficiency in of Road Freight: The Role of

Information Technologies. In: International Energy Agency and European Conference of Ministers of Transport, February 24, 1999, Paris, France

[22] Okafor I F, Unachukwu G O, Odukwe A O. Measuring energy efficiency of the public passenger road transport vehicles in Nigeria.Transport Policy 35. 2014; 319–325.

[23] Bureau of Industry Economics: International Performance Indicators – Road Freight. Australian Government Publishing Service; 1992.

[24] Donselaar K, Kokke K, Allessie M. Performance measurement in the transportation and distribution sector. International Journal of Physical Distribution & Logistics Management. 1998; Vol. 28, No. 6: 434 – 450.

[25] Kim T. Efficiency of trucks in logistics: technical and scale efficiency. Asian Journal on Quality ,Vol. 11 No. 1, 2010; 89-96

[26] Cruijssen F, Dullaert W, Joro T. Freight transportation efficiency through horizontal cooperation in Flanders. International Journal of Logistics: Research and Applications. 2010; Vol. 13, No. 3: 161–178.

[27] Hosseini S V, Shirani M. Fill Rate in Road Freight Transport. Master of Science Thesis in Supply Chain Management. Chalmers University of Technology, Sweden; 2011.

[28] Andrejić M, Bojović N, Kilibarda M. A framework for measuring transport efficiency in distribution centers. Transport Policy 45. 2016; 99–106.

[29] Department for Transport of Great Britain: Key Performance Indicators for the Next-day Parcel Delivery Sector.; 2006.

[30] McKinnon A. European Freight Transport Statistics: Limitations, Misinterpretations and Aspirations. Report prepared for the 15th ACEA Scientific Advisory Group Meeting, 8th September, 2010, Brussels, Belgium

[31] Pahlén P.-O., Börjesson F. Measuring resource efficiency in long haul road freight transport. In: NOFOMA 2012 - Proceedings of the 24th annual nordic logistics research network conference, 7-8 June 2012, Naantali, Finland

[32] McKinnon A., Ge Y., Leuchars D. Analysis of Transport Efficiency in the UK Food Supply Chain. Full Report of the 2002 key performance indicator survey. Logistics research centre. Heriot-Watt University. Edinburgh. UK, 2003.

[33] Šošić I.:Primijenjena statistika, Školska knjiga, Zagreb, 2004.

[34] Zelenika R.: Metodologija i tehnologija izrade znanstvenog i stručnog djela, Ekonomski fakultet Sveučilišta u Rijeci, Rijeka, 2000.

[35] Žugaj M.: Osnove znanstvenog i stručnog rada, Zagreb r.o. za grafičku djelatnost, Samobor, 1989.

[36] Krasić D, Novačko L. The Impact of Public Transport Network Accessibility on Trip Generation Model. Promet – Traffic&Transportation. 2015; Vol. 27, No. 2: 165-172.

[37] D. Naletina, A. Vuletić, L. Meštrović. Analiza poštanskog tržišta u Republici Hrvatskoj. Zbornik Veleučilišta u Rijeci. Vol. 7. 2019; No. 1: 301-315.

[38] https://www.mordorintelligence.com/industry-reports/courier-express-and-parcel-cep-market, 10. 05. 2020.

[39] https://www.statista.com/chart/10922/parcel-shipping-volume-and-parcel-spend-in-selected-countries/, 14. 05. 2020.

[40] https://www.statista.com/statistics/235412/b2c-market-share-of-parcel-services-in-europe/, 25. 06. 2020.

[41] https://www.statista.com/statistics/737418/parcel-traffic-worldwide-by-sector/, 08. 02. 2021.

[42] https://www.effigy-consulting.com/covid-19-impact-on-cep-market/, 12. 02.2021.

[43] A.T. Kearney, Inc.: Europe's CEP Market: Growth on New Terms, 2012.

[44] A.T. Kearney, Inc.: Europe's CEP Market: Steady Growth Begins to Shift, 2015.

[45] European Commission: Main Developments in the Postal Sector (2013-2016), Study for the European Commission, Directorate-General for Internal Market, Industry, Entrepreneurship and SMEs, Brussels, 2018.

[46] A.T. Kearney, Inc.: Europe's International CEP Market: Solid Growth With Challenges Ahead, 2017.

[47] https://lider.media/aktualno/hammond-deprecijacija-funte-dugorocno-vodi-snaznijem-i-konkurentnijem-izvozu-36050, 30. 05. 2020.

[48] https://www.effigy-consulting.com/cep-market-report/, 10. 02. 2021.

[49]https://www.statista.com/statistics/1198045/courier-express-parcel-market-volume-europe/, 10. 02. 2021.

[50] WIK-Consult: Assessment of EU Parcel Delivery Markets, Preliminary results from a study for DG GROW: Development of Cross-border E-commerce through Parcel Delivery, 2018.

[51] WIK-Consult: Development of Cross-border E-commerce through Parcel Delivery, A study for DG GROW, Delivering for the Future III: Workshop on Developments in the Postal Sector Brussels, January 2019.

[52] FTI Consulting: Intra-Community cross-border parcel delivery, A study for the European Commission, December 2011.

[53] ITA Consulting & WIK-Consult: The Evolution of the European Postal Market since 1997, Study for the European Commission, DG Internal Market and Services, August 2009.

[54] Miletić, Z. Trendovi europskog poštanskog tržišta. EKON. MISAO PRAKSA DBK. GOD XXI. 2012; BR. 1: 179-202.

[55] HAKOM: Godišnje izvješće o radu za 2018., Zagreb, srpanj 2019.

[56] https://www.hakom.hr/default.aspx?id=9491, 09. 07. 2020.

[57]https://www.hakom.hr/UserDocsImages/2020/e_trziste/GOD%20HR%202019_Ukupne%20usluge.pdf, 11. 02. 2021.

[58] Ministarstvo pomorstva, prometa i infrastrukture: Strategija razvoja tržišta poštanskih usluga u Republici Hrvatskoj do 2020. godine, Zagreb, 2014.

[59] HAKOM: Godišnje izvješće o radu za 2016., Zagreb, lipanj 2017.

[60] HAKOM: Godišnje izvješće o radu 2019., Zagreb, lipanj 2020.

[61] Državni zavod za statistiku Republike Hrvatske: Bruto domaći proizvod, Bruto domaći proizvod – godišnji obračun, Statistika u nizu, Zagreb, prosinac 2020.

[62] Državni zavod za statistiku Republike Hrvatske: Statistički ljetopis Republike Hrvatske 2018, Zagreb, prosinac 2018.

[63] Interna dokumentacija HAKOM, 12. 02. 2021.

[64] https://www.hakom.hr/default.aspx?id=10482, 11. 02. 2021.

[65]https://www.hakom.hr/UserDocsImages/2020/e_trziste/KVA%20HR%20Q3%202020%20Ukupne%20usluge.pdf, 11. 02. 2021.

[66]https://www.hakom.hr/UserDocsImages/2020/e_trziste/KVA%20HR%20Q3%202020%20Vrste%20po%C5%A1iljaka.pdf, 11. 02. 2021.

[67] Žužul J., Šimović V., Leinert-Novosel S.: Statistika u informacijskom društvu (za nematematičare), Europski centar za napredna i sustavna istraživanja ECNSI, Zagreb, 2008.

[68] Dumičić K. i ostali: Poslovna statistika, Udžbenik Sveučilišta u Zagrebu, Element d.o.o., Zagreb, 2011.

[69] Kazmier L. J.: Theory and Problems of Business Statistics, fourth edition, McGraw-Hill Companies, SAD, 2004.

[70] Washington S. P., Karlaftis M. G., Mannering F. L.: Statistical and Econometric Metods for Transportation Dana Analysis, Chapman&Hall/CRC, SAD, 2003.

[71] Bahovec V. i ostali: Statistika, Udžbenik Sveučilišta u Zagrebu, Element d.o.o., Zagreb, 2015.

[72] Rozga A.: Statistika za ekonomiste, VI. izdanje, Ekonomski fakultet Split, Sveučilište u Splitu, Split, 2017.

[73] Gujarati D. N.: Basic Econometrics, Fourth edition, The McGraw−Hill Companies, 2004.

[74] Ivančević T., Perec K.: Osnove ekonomije, Visoka poslovna škola Zagreb, Zagreb, 2017.

[75] https://www.hnb.hr/statistika/glavni-makroekonomski-indikatori, 06. 04. 2019.

[76] https://www.hgk.hr/documents/6-makrotabela-za-web-09201657dbe939dac81.pdf, 06. 04. 2019.

[77] Perkov J., Mikulandra Volić I., Lastavec M. The Revision of Macroeconomic Indicators in EU-28 on the Example of Gross National Income. Oeconomica Jadertina. 2017; Vol. 7, No. 1: 41-53.

[78] Florens J.-P., Marcy S., Toledano J. Mail Demand in the Long and Short Term. Postal and Delivery Services. Pricing, Productivity, Regulation and Strategy. 2002; 171-190.

[79] Slavuj L. Objektivni i subjektivni pokazatelji u istraživanju koncepta kvalitete života. Geoadria. 2012; Vol. 17, No. 1: 73-92.

[80] https://www.dzs.hr/Hrv/important/Obrasci/12-NacRacuni/Obrasci/INV-P.pdf, 10. 04. 2019.

[81] Jimenez L., Lintell M., Owsiany A. Evaluating measures of dispersion to explain the unobserved heterogeneity in mail volumes across countries. In: 15th Conference on Postal and Delivery Economics, 2007, Austria

[82] Pechota M., Matúšková M., Madleňáková L. The trend of cost of universal services provided by national postal operator and correlation between price of letter mail and amount of sent letter mails in Slovakia. Procedia Engineering 192. 2017; 574 – 579.

[83] Baldigara T., Koić M. Modelling the international tourism demand in croatia using a polynomial regression analysis. Turističko poslovanje. 2015; Broj 15: 29-38.

[84] Jelušić A. Modelling tourist consumption to achieve economic growth and external balance: case of Croatia. Tourism and Hospitality Management. 2017; Vol. 23, No. 1: 87-104.

[85] http://scholar.harvard.edu/files/rogowski/files/post_office_development.pdf, 04. 04. 2019.

[86] United Nations Conference on Trade and Development, Search of cross-border e-commerce trade data, UNCTAD Technical Notes on ICT for Development, No. 6, April 2016.

[87] Zahra K, Azim P, Mahmood A. Telecommunication Infrastructure Development and Economic Growth: A Panel Data Approach. Dostupno na: https://pdfs.semanticscholar.org/daf1/756cf4973e512594123f16c00b63e020624f.pdf

[88] Röller L-H, Waverman L. Telecommunications Infrastructure and Economic Development: A Simultaneous Approach. The American Economic Review. 2001; Vol. 91, No. 4: 909-923.

[89] Depp C A, et al. Age, affective experience, and television use. American Journal of Preventive Medicine. 2010; Vol. 39 (2): 173–178.

[90] Randall A. Lewis R A, Reiley D H. Advertising Effectively Influences Older Users: How Field Experiments Can Improve Measurement and Targeting. Dostupno na: http://davidreiley.com/papers/AEIOU.pdf

[91] Charness N, Boot W R. Aging and information technology use. Potential and barriers. Current directions in psychological science. 2009; Vol. 18, No 5: 253-258.

[92] Quadrello T, et al. Grandparents use of new communication technologies in a European perspective. European Journal of Ageing. 2005; Vol. 2 (2): 200–207.

[93] Groß M. Exploring the acceptance of technology for mobile shopping: an empirical investigation among Smartphone users. The International Review of Retail, Distribution and Consumer Research. 2015; Vol. 25, No. 3: 215–235.

[94] https://www.statista.com/statistics/374623/mobile-commerce-buyers-worldwide/, 14. 04. 2019.

[95] https://www.statista.com/statistics/274774/forecast-of-mobile-phone-users-worldwide/, 14. 04. 2019.

[96] http://www.enciklopedija.hr/natuknica.aspx?id=50198, 21. 05. 2019.

[97] Državni zavod za statistiku: Primjena informacijskih i komunikacijskih tehnologija (ikt) u kućanstvima i kod pojedinaca u 2016., Prvi rezultati, DZS, Zagreb, prosinac 2016.

[98] https://www.dzs.hr/

[99] https://ec.europa.eu/eurostat

[100] https://www.hakom.hr/

[101] https://www.hnb.hr/

[102] http://databank.worldbank.org/data/home.aspx

[103] https://www.statista.com/

[104] Mlikotić S.: Globalna financijska kriza - uzroci, tijek i posljedice, Pravnik, 44, 2 (89), 2010.

[105] Sadiq, N., Shahid Qureshi, M.: Climatic Variability and Linear Trend Models for the Five Major Cities of Pakistan. Journal of Geography and Geology. 2010. Vol. 2, No 1.: 83-92.

[106] Akmal, N. et. al.: Trend analysis of rice area and yield in Punjab. Pakistan J. Agric. Res. 2015. Vol 28 No.4: 439-444

[107] Sektor za financijske institucije, poslovne informacije i ekonomske analize, Odjel za makroekonomske analize: Kretanje BDP-a u Hrvatskoj – izvori rasta i posljedice, Hrvatska gospodarska komora, ožujak 2017.

[108] Rozga A.: Statistika za ekonomiste, 5. izdanje, Ekonomski fakultet, Sveučilište u Splitu, Split, 2009.

[109]https://www.hakom.hr/UserDocsImages/2018/e_trziste/GOD%20HRV%202017_Gusto%C4%87a%20%C5%A0PI%20putem%20pokretne%20mre%C5%BEe.pdf, 17.09.2018.

[110] Tabachnick, B. G., Fidell, L. S.: Using multivariate statistics, 5th ed., Allyn and Bacon, Boston, 2007.

[111] Jurun E., Ratković N.: Poslovna statistika s primjerima u Microsoft Excelu, Ekonomski fakultet Sveučilišta u Splitu, Split, 2017.

[112] McKinnon A. European Freight Transport Statistics: Limitations, Misinterpretations and Aspirations. Report prepared for the 15th ACEA Scientific Advisory Group Meeting, 8th September, 2010, Brussels, Belgium

[113] Šimundić, S.; Žužul, J. Statististika za upravni studij, PFST, 2012.

[114] HP-Hrvatska pošta d.d.: Godišnji izvještaj o poslovanju za 2015. godinu, Zagreb, 2016.

[115] HP-Hrvatska pošta d.d.: Godišnje izvješće za 2016. godinu, Zagreb, 2017.

[116] HP-Hrvatska pošta d.d.: Godišnje izvješće za 2017. godinu, Zagreb, 2018.

[117] HP-Hrvatska pošta d.d.: Godišnje izvješće za 2018. godinu, Zagreb, 2019.

[118] Županović, I.: Tehnologija cestovnog prijevoza, Fakultet prometnih znanosti, Zagreb, 2002.

[119] Protega, V.: Nastavni materijal za predavanja iz kolegija Osnove tehnologije prometa, Fakultet prometnih znanosti, Zagreb, 2009/2010.

[120] Zakon o javnoj nabavi, Narodne novine 120/16.

POPIS SLIKA

Slika 1. Broj paketskih pošiljaka u svijetu na unutarnjem i međunarodnom tržištu. Autor uredio prema [41] 11

Slika 2. CEP tržište po regijama [38] 12

Slika 3. Prikaz rasta broja paketskih i ekspresnih pošiljaka, indeks (2013 = 100) [45] 13

Slika 4. Europsko međunarodno CEP tržište [46] 14

Slika 5. Isporučene paketske pošiljke na europskom CEP tržištu [49] 15

Slika 6. Europsko paketno tržište 2016. [50] 15

Slika 8. Potražnja za paketskim i ekspres pošiljkama po stanovniku po zemljama [45] 16

Slika 9. Prikaz postotnog udjela nacionalnih poštanskih operatera na unutarnjem tržištu paketa i ekspresnih pošiljaka u 2016. [45] 17

Slika 10. Prikaz mase međunarodnih ekspres pošiljki u pojedinim zemljama u 2013. Autor uredio prema [44] 18

Slika 11. Prikaz mase međunarodnih ekspresnih pošiljaka pojedinih zemalja u 2016. Autor uredio prema [46] 19

Slika 12. Usporedba B2C online kupovine 2013. i 2017. godine na području EU-28 [51] 21

Slika 13. Povezanost između korištenja Interneta i naručivanja robe online [51] 22

Slika 14. Zemlje iz kojih je naručena roba Internetom [51] 23

Slika 15. Broj paketskih pošiljaka u RH [57, 53, 60] 24

Slika 16. Udio paketskih pošiljaka u unutarnjem i međunarodnom prometu. Autor uredio prema [62,63] 25

Slika 17. Prikaz tumačenja vrijednosti koeficijenta korelacije [68] 28

Slika 18. Plan izbora nezavisnih varijabli u višestrukoj linearnoj regresiji 48

Slika 19. Broj dolazaka turista 52

Slika 20. Broj noćenja turista 52

Slika 21. Broj stanovnika 53

Slika 22. Uvoz 53

Slika 23. Izvoz 54

Slika 24. Neto plaća 55

Slika 25. Bruto nacionalni dohodak po stanovniku 55

Slika 26. Zaposleni 56

Slika 27. Nezaposleni 57

Slika 28. BDP po stanovniku 58

Slika 29. Bruto investicije 58
Slika 30. Bruto dodana vrijednost 59
Slika 31. Obiteljske naknade 60
Slika 32. Pristupna mjesta 60
Slika 33. Zaposleni kod davatelja poštanskih i kurirskih usluga 61
Slika 34. Poštanski pretinci 62
Slika 35. Prihod od obavljanja poštanskih usluga 62
Slika 36. Prostorna pokrivenost pristupnih mjesta 63
Slika 37. Telefonske linije nepokretne mreže 64
Slika 38. Korisnici pokretne mreže 64
Slika 39. Pokrivenost stanovništva svakog pristupnog mjesta 65
Slika 40. Ulaganja operatora elektroničkih komunikacija 66
Slika 41. Pravne osobe 66
Slika 42. Obrt i slobodna zanimanja 67
Slika 43. Kućanstva s pristupom Internetu 68
Slika 44. Internet kupci 68
Slika 45. Gustoća stanovništva na 1 km^2 69
Slika 46. Godišnji raspoloživi dohodak po kućanstvu 70
Slika 47. Indeks potrošačkih cijena za poštanske usluge 70
Slika 48. Vrijednost prodanih industrijskih proizvoda 71
Slika 49. Paketske pošiljke 72
Slika 50. Grafički prikaz korelacija između paketskih pošiljaka i nezavisnih varijabli 78
Slika 51. Histogram reziduala 83
Slika 52. Grafički prikaz reziduala u odnosu na normalnu razdiobu 84
Slika 53. Dijagram raspršenosti reziduala i vrijednosti modela 85
Slika 54. Histogram reziduala 89
Slika 55. Grafički prikaz reziduala u odnosu na normalnu razdiobu 90
Slika 56. Dijagram raspršenosti reziduala i vrijednosti modela 91
Slika 57. Ostvaren i procijenjen promet paketskim pošiljkama u promatranom razdoblju od 2007. do 2018. godine 94
Slika 58. Histogram mase paketskih pošiljaka 99
Slika 59. Histogram volumena paketskih pošiljaka 99

Slika 60. Odstupanje modela i pretpostavke davatelja poštanske usluge u odnosu na ostvareni broj paketskih pošiljaka 104

Slika 61. Dijagram toka za utvrđivanje prihvatljivih kapaciteta prijevoznih sredstava u poštanskom prometu 111

POPIS TABLICA

Tablica 1. Udio prihoda od poštanskih usluga u BDP-u Republike Hrvatske u razdoblju od 2013.-2019. godine. Autor uredio prema [55, 59, 60, 61] ..... **Error! Bookmark not defined.**

Tablica 2. Odnos koeficijenta determinacije i koeficijenta jednostavne linearne korelacije [68] 33

Tablica 3. Pregled čimbenika koji se analiziraju 41

Tablica 4. Deskriptivna statistika 50

Tablica 5. Polazne pretpostavke linearnog regresijskog modela 73

Tablica 6. Skraćenice naziva varijabli 74

Tablica 7. Pearsonova korelacija između broja paketskih pošiljaka i odabranih varijabli 75

Tablica 8. Matrica korelacije između odabranih varijabli 79

Tablica 9. Forward regresijski postupak na godišnjim podatcima 81

Tablica 10. ANOVA tablica svih efekata linearnog regresijskog modela 82

Tablica 11. Tablica razine tolerancija i pripadnih koeficijenata determinacije 82

Tablica 12. Korelacijska analiza nezavisnih varijabli i nestandardiziranih reziduala 85

Tablica 13. Forward regresijski postupak na godišnjim podacima 87

Tablica 14. ANOVA tablica svih efekata linearnog regresijskog modela 88

Tablica 15. Tablica nivoa tolerancija i pripadnih koeficijenata determinacije 88

Tablica 16. Korelacijska analiza nezavisnih varijabli i nestandardiziranih reziduala 91

Tablica 17. Usporedba rezultata regresijskih modela 92

Tablica 18. Rezultati prognoziranja pomoću godišnjeg modela 95

Tablica 19. Deskriptivna statistika paketskih pošiljaka 98

Tablica 20. Testiranje razdiobe paketa u uzorku u odnosu na Gaussovu krivulju 98

Tablica 21. Ostvaren i prognoziran broj paketskih pošiljaka 101

Tablica 22. Promet paketskim pošiljkama [114, 115, 116, 117] 102

Tablica 23. Ostvaren i planiran broj paketskih pošiljaka [114, 115, 116, 117] 102

Tablica 24. Očekivan broj paketskih pošiljaka modelom 103

Tablica 25. Validacija modela temeljem pokazatelja 105

Tablica 26. Prihvatljive razine masenog i volumenskog udjela natovarenosti vozila u funkciji prijevoza između entiteta mreže 109

Tablica 27. Matrica natovarenosti vozila 109

Tablica 28. Masena i volumenska specifikacija vozila odabranog davatelja poštanskih usluga 112

Tablica 29. Prosječni udio masene i volumenske natovarenosti voznog parka 113

Tablica 30. Udio natovarenosti vozila prema vrsti vozila..... 113

Tablica 31. Linije između poštanskog središta i ureda 114

Tablica 32. Linije između poštanskih središta 115

Tablica 33. Linije između poštanskog središta i ureda na procijenjenom broju paketskih pošiljaka u 2019. godini 117

Tablica 34. Linije između poštanskih središta na procijenjenom broju paketskih pošiljaka u 2019. godini..... 118

PRILOZI

Prilog 1. Čimbenici koji utječu na tržište poštanskih usluga

Ekonomski čimbenici	**Tehnološki**	**Poštanski**	**Društveni**
Bruto domaći proizvod	SMS	Proizvodi i usluge	Broj stanovnika
Globalizacija	E-mail	Ljudski potencijal	Broj kućanstava
Inflacija	Društvene mreže	Kakvoća usluga	Starost stanovništva
Ključne gospodarske djelatnosti		Marketing	Kulturalne razlike
Stopa nezaposlenosti		Primijenjena tehnologija	Razina obrazovanja
Osobna potrošnja		Poštanska mreža	
Uvoz		Zakonodavni okvir	
Izvoz		Tarife	
Razvoj ekonomije		Konkurentsko okruženje	
Struktura gospodarskih aktivnosti i broj tvrtki		Prometna infrastruktura	
Mala i srednja poduzeća		Gospodarsko okruženje	
Cijena poštanskih usluga			
Razina i struktura prihoda			

Prilog 2. Istraženi čimbenici za koje se pretpostavilo da utječu na poštanski promet Republike Iran

Ekonomski čimbenik	**Socijalno-kulturološki čimbenici**	**Poštanski čimbenici**	**Tehnološki čimbenici**
Nacionalni dohodak po stanovniku	Stanovništvo	Broj poštanskog osoblja	Broj telefona i mobitela
Bruto nacionalna proizvodnja	Ruralno stanovništvo	Broj poštanskih jedinica	Ulaganja u komunikacije
Bruto nacionalna proizvodnja po glavi stanovnika	Urbano stanovništvo	Broj poštanskih pretinaca	Dodana vrijednost komunikacija
Bruto domaća proizvodnja	Obiteljske naknade	Poštanski dohodak	Broj sela s telefonom
Bruto domaća proizvodnja po stanovniku	Naknada za kulturna obiteljska dobra	Cijena pojedinačnih paketskih pošiljaka	Faktor utjecaja mobitela
Dodana vrijednost sektora usluga	Broj obitelji	Prostorna pokrivenost svake poštanske jedinice	Faktor utjecaja telefona
Dodana vrijednost prijevoza, skladištenja i komunikacija	Ratne godine	Pokrivenost stanovništva svake poštanske jedinice	Vrijednost proizvodnje i komunikacije
Dodana vrijednost industrija i rudarstva	Pismeno stanovništvo	Proizvodna pokrivenost svakog poštanskog zaposlenika	Broj internetskih pretplatnika

Dodana vrijednost odjela nafte i plina	Kulturne i obrazovne naknade urbanog stanovništva	Pokrivenost stanovništva svakog poštanskog zaposlenika	
Dodana vrijednost poljoprivrednog sektora	Kulturne i obrazovne naknade ruralnog stanovništva	Dohodak po glavi svakog poštanskog zaposlenika	
Ulaganje uslužnog sektora	Prijevozne i obiteljske komunikacijske naknade		
Ulaganje poljoprivrednog sektora			
Ulaganje sektora nafte i plina			
Ulaganje cijele države			
Ulaganje državnog sektora			
Ulaganje privatnog sektora			
Ulaganje prijevoznog sektora			
Dohodak obitelji			
Izvoz			
Uvoz			
Globalizacija			

Prilog 3. Socio-ekonomski čimbenici koji utječu na tokove paketskih pošiljaka

Populacija	**Kućanstvo**	**Industrija**	**Dohodak**
Gustoća naseljenosti	Broj samostojećih kuća	Broj proizvodnih pogona	Broj kuća sa 6 i više soba
Broj kućanstava	Broj kuća s više kućanstava	Broj zaposlenih u proizvodnji	Fiskalizacija
Broj stanovnika	Broj kuća s poslovnim prostorom	Broj prodajnih mjesta	Indeks cijena kuća u lisingu
Broj jednočlanih kućanstava	Broj stanova	Broj zaposlenih u prodaji	
Omjer odrasli-dijete	Broj kuća u gradu		
Veličina ženske populacije	Broj multipleksa		

Prilog 4. Prikaz čimbenika po segmentima i regijama koji utječu na potražnju za paketskim pošiljkama pri razini pouzdanosti 90%

Segmenti i regije	**Čimbenici**
Afrika	BDP, Siromaštvo, Inflacija
Arapske zemlje	Kućanstva, Izvoz, Cijena
Azija-Pacifik	Cijena, Kućanstva, BDP, Inflacija
Istočna Europa	Izvoz, Siromaštvo, Kućanstva, Korisnici Interneta
Latinska Amerika	Kućanstva, Izvoz, BDP
Sjeverna Amerika	BDP
Zapadna Europa	BDP, Inflacija
Svjetski podaci	Cijena, Neto migracije

Životopis

Ana-Mari Poljičak rođena je 18.03.1978. godine u Šibeniku. Osnovnu školu ″Gušte Šprljan″ završila je u Vodicama, a srednju Medicinsku i kemijsku školu u Šibeniku. Daljnje školovanje nastavila je na Fakultetu prometnih znanosti, Sveučilišta u Zagrebu, na kojem 2004. završava dodiplomski studij Promet- PT smjer i stječe zvanje diplomiranog inženjera prometa.

U Poštanskoj i telekomunikacijskoj školi u Zagrebu zapošljava se 2006. godine kao profesor stručnih predmeta iz područja PT prometa te 2007. godine na Učiteljskom fakultetu, Sveučilišta u Zagrebu, završava program pedagoško-psihološke naobrazbe i u Agenciji za strukovno obrazovanje polaže stručni ispit.

Na Veleučilištu u Šibeniku zapošljava se 2009. godine u suradničko zvanje asistenta na odgovarajuće radno mjesto gdje sudjeluje na izvođenju nastave na preddiplomskom stručnom studiju Promet iz kolegija: Unutarnji transport i skladištenje, Prekrcajna sredstva I, Prekrcajna sredstva II, Prometna logistika, Sredstva i eksploatacija sredstava cestovnog prometa, Infrastruktura PT prometa, Planiranje poštanske mreže i Tehnička sredstva PT prometa.

U nastavno zvanje predavača za područje tehničkih znanosti, polje tehnologija prometa i transport izabrana je 2011. godine te na preddiplomskom stručnom studiju Promet izvodi nastavu na kolegijima: Planiranje poštanske mreže, Sredstva i eksploatacija sredstava cestovnog prometa, Prekrcajna sredstva II dok na kolegijima Tehnička sredstva PT prometa, Infrastruktura PT prometa, Unutarnji transport i skladištenje, Prekrcajna sredstva I izvodi nastavu i nositelj je kolegija. U 2012. godini postaje nositelj i kolegija Prekrcajna sredstva II. U 2013. godine postaje nositelj i izvodi nastavu na kolegiju Robno distribucijski centri i terminali. Od 2014. godine do danas izvodi nastavu na kolegiju Sredstva i eksploatacija sredstava cestovnog prometa dok na kolegijima: Promet u turizmu, Unutarnji transport i skladištenje, Prekrcajna sredstva I, Prekrcajna sredstva II, Robno distribucijski centri i terminali izvodi nastavu i nositelj je kolegija. U 2016. godine izvodila je i nastavu na kolegiju Suvremeni prometni sustavi.

Voditeljica je preddiplomskog stručnog studija Promet, Veleučilišta u Šibeniku, u periodu 2013. do 2017. godine. U akademskoj godini 2014./2015. voditeljica druge godine, a u akademskoj godini 2015./2016. treće godine preddiplomskog stručnog studija Promet.

Veleučilište u Šibeniku 2016. godine uručilo joj je priznanje za ostvarene projekte suradnje s gospodarstvom. U 2017. godine izabrana je u nastavno zvanje višeg predavača za područje tehničkih znanosti, polje tehnologija prometa i transport.

Objavila je ukupno petnaest (15) radova u domaćim i međunarodnim časopisima i zbornicima skupova te obrazovni materijal za predmet iz kojeg izvodi nastavu.

Usavršava engleski jezik na Milner International College of English u Australiji te njemački jezik na Deutsch Akademie BLAISE PASCAL u Beču.

Popis objavljenih radova

1. Šego, Darijo; Ljubić Hinić, Martina; Poljičak, Ana-Mari. Methods of Goods Delivery to the Historic Core of the City of Šibenik Duringthe Tourist Season. // Logi, 11 (2020), 1; 88-98 doi:10.2478/logi-2020-0009 (međunarodna recenzija, članak, znanstveni)

2. Karin, Ivan; Poljičak, Ana-Mari; Šego, Darijo. Development trends in the number of postal parcels in the Republic of Croatia. // Transport Problems 2019 International Scientific Journal / Sladkowski, Aleksander (ur.). Katowice (Republic of Poland): Silesian University of Technology, Faculty of Transport, 2019. str. 320-325. (https://www.bib.irb.hr/1015924) (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

3. Olivari, Luka; Poljičak, Ana-Mari; Pražen, Ante. Korištenje obnovljivih izvora energije kao turističkih atrakcija u svrhu razvoja održivog turizma. // Zbornik radova Veleučilišta u Šibeniku / Cavrić, B. ; Rimac, T. ; Zlatović, D. (ur.). Šibenik: Veleučilište u Šibeniku, 2017. str. 184-193 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

4. Maretić, Branimir; Poljičak, Ana-Mari; Plenča, Kristijan. Usporedna analiza sustava javnih bicikala gradova Šibenika i Zadra. // Zbornik radova Veleučilišta u Šibeniku / Cavrić, B. ; Rimac, T. ; Zlatović, D. (ur.). Šibenik: Veleučilište u Šibeniku, 2017. str. 520-531 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

5. Poljičak, Ana-Mari; Ljubić Hinić, Martina; Šego, Darijo. ICE mreža vlakova Njemačkih željeznica. // Zbornik radova Veleučilišta u Šibeniku, 10 (2016), 1-2; 115-127. (https://www.bib.irb.hr/829269) (domaća recenzija, pregledni rad, znanstveni)

6. Ljubić Hinić, Martina; Poljičak, Ana-Mari; Šego, Darijo. Javni linijski prijevoz u Gradu Zadru. // Zbornik radova Veleučilišta u Šibeniku, 10 (2016), 3-4; 69-80. (https://www.bib.irb.hr/884054) (domaća recenzija, pregledni rad, znanstveni)

7. Šego, Darijo; Poljičak, Ana-Mari; Ljubić Hinić, Martina. Određivanje lokacije smještaja Logističko- distribucijskog centra Šibenik. // Zbornik radova Veleučilišta u Šibeniku, 10 (2016), 1-2; 129-135. (https://www.bib.irb.hr/829272) (domaća recenzija, članak, stručni)

8. Bilić, Stipe; Janković, Ana-Mari; Ljubić Hinić, Martina. Impact of the Economic Crisis on the Roadworthiness of Vehicles in the Republic of Croatia. // Transport Problems, 10 (2015), 2; 83-90 doi:10.21307/tp-2015-023 (međunarodna recenzija, članak, znanstveni)

9. Ljubić Hinić, Martina; Bilić, Stipe; Janković, Ana-Mari. Štete po policama obveznog osiguranja od automobilske odgovornosti u Republici Hrvatskoj. // Savetovanje sa međunarodnim učešćem na temu Saobraćajne nezgode : zbornik radova / Todorović, Jovan ; Šotra, Dragoljub (ur.). Zlatibor: IPJ, 2014. str. 232-242 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

10. Ljubić Hinić, Martina; Božić, Nikica; Janković, Ana-Mari. Utjecaj korištenja mobitela u vožnji na sigurnost cestovnog prometa u Šibensko-kninskoj županiji. // Zbornik radova /

Jusufranić, Ibrahim ; Alispahić, Sinan ; Zaimović, Azra (ur.). Travnik: Internacionalni univerzitet Travnik, 2013. str. 133-139 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

11. Janković, Ana-Mari; Ljubić Hinić, Martina; Beović, Bruna. Linijski pomorski prijevoz putnika Šibenskog okružja. // Zbornik radova Veleučilišta u Šibeniku / Radić Lakoš, Tanja ; Bratić, Ivana ; Grubišić, Anita ; Marguš, Drago ; Mečev, Dijana ; Pavlović, Marina ; Poljičak, Ivica ; Radačić, Marko ; Šišara, Jelena ; Urem, Frane (ur.). Šibenik: Veleučilište u Šibeniku, 2013. str. 455-463 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

12. Janković, Ana-Mari; Ljubić Hinić, Martina; Božić, Nikica. Analiza prometnih nesreća mladih vozača Šibensko- kninske županije. // Zbornik radova / Jusufranić, Ibrahim ; Alispahić, Sinan ; Zaimović, Azra (ur.). Travnik: Internacionalni univerzitet Travnik, 2013. str. 60-65 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

13. Janković, Ana-Mari; Ljubić Hinić, Martina; Urem, Nikolina. Utjecaj turističkih migracija na prometnu ponudu grada Vodice. // Zbornik radova Veleučilišta u Šibeniku / Radić Lakoš, Tanja ; Bratić, Ivana ; Grubišić, Anita ; Marguš, Drago ; Mečev, Dijana ; Pavlović, Marina ; Poljičak, Ivica ; Radačić, Marko ; Šišara, Jelena ; Urem, Frane (ur.). Šibenik: Veleučilište u Šibeniku, 2013. str. 464-471 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), stručni)

14. Janković, Ana-Mari; Ljubić Hinić, Martina; Bazijanac, Ernest. Dinamika uvođenja Euro normi u Republici Hrvatskoj. // Suvremeni promet, 31 (2011), 5/6; 454-458 (podatak o recenziji nije dostupan, članak, znanstveni)

15. Janković, Ana-Mari; Ljubić Hinić, Martina; Bilić, Stipe. Emisija štetnih tvari u voznom parku Republike Hrvatske. // EKOLOGIJA I SAOBRAĆAJ / Ibrahim Jusufranić (ur.). Travnik: INTERNACIONALNI UNIVERZITET TRAVNIK, 2011. str. 21-29 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)