Razvoj pravičnoga tarifnoga modela u integriranom prijevozu putnika

Šipuš, Denis

Doctoral thesis / Disertacija

2020

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:489053

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-26**

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

Sveučilište u Zagrebu

Fakultet prometnih znanosti

Denis Šipuš

RAZVOJ PRAVIČNOGA TARIFNOGA MODELA U INTEGRIRANOM PRIJEVOZU PUTNIKA

DOKTORSKI RAD

Zagreb, 2020.

Sveučilište u Zagrebu

Fakultet prometnih znanosti

Denis Šipuš

RAZVOJ PRAVIČNOGA TARIFNOGA MODELA U INTEGRIRANOM PRIJEVOZU PUTNIKA

DOKTORSKI RAD

Mentor: izv. prof. dr. sc. Borna Abramović

Zagreb, 2020.

Faculty of Transport and Traffic Sciences

Denis Šipuš

MODELING OF EQUITY FARE SYSTEMS IN INTEGRATED PASSENGER TRANSPORT

DOCTORAL DISSERTATION

Supervisor: Associate professor Borna Abramović, PhD

Zagreb, 2020.

INFORMACIJE O MENTORU: izv. prof. dr. sc. Borna Abramović

Borna Abramović rođen je 20. rujna 1977. u Slavonskom Brodu. Osnovnu te srednju Željezničku tehničku školu završio je u Zagrebu. Diplomirao je na Fakultetu prometnih znanosti Sveučilišta u Zagrebu s temom *Formalne metode u analizi sigurnosti željezničkih cestovnih prijelaza u razini*. Znanstveni magistarski rad s temom *Tehnološki model pristojbi za željezničku infrastrukturu* uspješno je obranio 2007. godine. Doktorsku disertaciju pod nazivom *Modeliranje potražnje u funkciji prijevoza željeznicom* uspješno je obranio 2010.

Izabran je u znanstveno zvanje viši znanstveni suradnik te u znanstveno-nastavno zvanje izvanredni profesor. Na Fakultetu prometnih znanosti u Zagrebu obnaša funkciju voditelja Katedre za organizaciju željezničkoga prometa, u Agenciji za sigurnost željezničkoga prometa predsjednik je Upravnoga vijeća. Predsjednik je Željezničkoga strukovnoga razreda Hrvatske komore inženjera tehnologije prometa i transporta te predsjednik Grupacije za integrirani prijevoz putnika Hrvatske gospodarske komore. Obnaša funkciju *Railway Talent Ambassador* Međunarodne željezničke unije.

Nositelj je sljedećih kolegija na Fakultetu prometnih znanosti: Organiziranje željezničkog prometa, Prijevoz robe željeznicom, Gospodarenje u željezničkom sustavu i Organizacija prijevoza putnika željeznicom. Izvođač je kolegija Teorija igara. Na doktorskom je studiju nositelj kolegija Primijenjena statistika za istraživanja u prometu, Inovativne intermodalne tehnologije i Istraživački seminar iz organizacije integriranog prijevoza putnika. Na Fakultetu elektrotehnike i računalstva Sveučilišta u Zagrebu izvođač je kolegija Željeznički sigurnosno-signalni i komunikacijski sustavi. Gost je predavač na Geografskom odjelu Prirodoslovnoga fakulteta Sveučilišta u Zagrebu, na kolegiju Promet i organizacija prostora.

Gost je predavač na sljedećim visokoobrazovnim ustanovama u Europi: *University of Žilina* (Slovačka), *University of Pardubice* (Češka), *University of Palermo* (Italija), *Technical University Carolo – Wilhelmina Braunschweig* (Njemačka), *University of Ljubljana* (Slovenija), *University of Košice (Slovačka), University of Novi Sad (Srbija), Institute of Technology and Business in Češke Budejovice* (Češka), *Newcastle University* (Ujedinjeno Kraljevstvo), *Budapest University of Technology and Economics* (Mađarska), *Vilnius Gediminas Technical University* (Litva), *Politehnica University of Bucharest* (Rumunjska), *Gdansk University* (Poljska) *i University Lumiere Lyon 2* (Francuska) *i Iran University of Science and Technology* (Iran).

Područja su njegovoga interesa u znanosti sljedeća: organizacija željezničkoga prometa, pristojbe za željezničku infrastrukturu, prijevoz robe željeznicom, tržište željezničkih usluga, integrirani prijevoz putnika, prognoziranje prometa, prijevozna potražnja i teorija igara.

Aktivni je istraživač i sudionik velikoga broja znanstvenih projekata na razini Europske unije i Hrvatske te velikoga broja studija i elaborata u Hrvatskoj.

Ukupno je objavio 4 poglavlja u knjizi, 4 sveučilišna udžbenika (od toga 2 na engleskom jeziku), 30 znanstvenih radova u međunarodnim časopisima, 9 pozvanih predavanja na znanstvenim međunarodnim skupovima i 78 radova u zbornicima skupova s međunarodnom recenzijom.

Želio bih zahvaliti svima koji su mi proaktivno pomogli pri izradi disertacije tijekom prethodnih triju godina.

Ponajprije bih zahvalio svojem mentoru, izv. prof. dr. sc. Borni Abramoviću, koji je mentoriranjem mojega završnog, diplomskog i sada doktorskog rada usmjerio moja istraživanja k cilju i pomogao mi savjetima kojima sam savladavao prepreke s kojima sam se susretao.

Zahvaljujem svim članovima povjerenstva na prepoznavanju važnosti i kvalitete provedenoga istraživanja te na konstruktivnim prijedlozima i sugestijama.

Kolegama s Fakulteta prometnih znanosti u Zagrebu, kao i ostalim kolegama te prijateljima zahvaljujem na potpori i savjetima.

Naposljetku, jednu od najvećih zahvala dugujem svojim roditeljima i obitelji koji su cijelo vrijeme vjerovali u mene te supruzi koja je imala najviše razumijevanja i pomagala u trenutcima kada je bilo najpotrebnije.

Ovaj rad posvećujem svojem sinu Davidu kojemu sam uskratio vrijeme zajedničkih druženja tijekom izrade ovoga rada!

Sažetak

Modeliranje tarifnih sustava u javnom prijevozu putnika predstavlja složen optimizacijski problem usklađivanja želja i potreba dionika koji su uključeni u sustav te mogućnosti sustava, posebice u integriranom prijevozu putnika. Analizom dosadašnjih istraživanja tarifnih sustava u integriranom prijevozu putnika uočava se nedostatak istraživanja tarifnih sustava s gledišta prometne marginaliziranosti i pravičnosti tarifnih modela. Prometna se marginaliziranost odnosi na prostor i društvo te predstavlja pojavu ograničene ili onemogućene mobilnosti. Primjenom pravičnih tarifnih modela teži se sprječavanju prometne marginaliziranosti davanjem dodatne naklonosti dionicima u nepovoljnijem položaju s ciljem izjednačavanja. Znanstvenim su istraživanjem identificirani pravični kriteriji pri određivanju tarifnih zona u integriranom prijevozu putnika koji govore o razvijenosti tarifnih zona s prometnoga, gospodarskoga i demografskoga gledišta. Modeliranjem sustavne dinamike utvrdili su se važni kriteriji za pravični tarifni model u svrhu izbjegavanja ponavljanja pojedinih kriterija. Za određivanje je važnosti svakoga pojedinoga pravičnog kriterija unutar pravičnoga tarifnoga modela korištena metodologija analitičkoga hijerarhijskog procesa (AHP) utemeljena na rangiranjima 117 europskih stručnjaka za promet, gospodarstvo i demografiju. Razvijen je novi pravični tarifni model, koji se temelji na dosadašnjem modelu, za izračun cijene tarifne zone u integriranom prijevozu putnika. U novom je modelu predstavljen koeficijent pravičnosti koji čine utvrđeni pravični kriteriji, a koji regulira cijenu tarifne zone s ciljem izjednačavanja i sprječavanja prometne marginaliziranosti. Pravični je tarifni model testiran na području Sisačko-moslavačke županije kao predstavnici najnerazvijenijih županija u Republici Hrvatskoj koju također karakterizira veliki udio ruralnih područja i nejednolika razvijenost s prometnoga, gospodarskoga i demografskog gledišta. Ovim se modelom osigurava pravičnost, sprječava marginaliziranost i omogućava bolja kvaliteta življenja stanovništvu ruralnih područja.

Ključne riječi: integrirani prijevoz putnika, tarifni sustavi, zonski tarifni sustav, pravičnost, prometna marginaliziranost

Summary

Fare system modeling in public passenger transport is a complex issue of harmonizing the demands and needs of system users with system capabilities, particularly in integrated transport. The analysis of previous fare systems in integrated transport reveals a lack of research on fare systems from the point of view of transport disadvantage and fare model equity. Transport disadvantage, which refers to both space and society, presents restricted mobility or lack thereof. Public passenger transport presupposes equal accessibility to all its users, as well as the possibility of using it under equal conditions. In previous fare systems, equal accessibility meant equal price per kilometer for each user of the transport service. However, the accessibility did not take into account equal transport, economic, and demographic development of an area in which the service is provided. Having that in mind, fare system models require changes so that transport disadvantage can be prevented in the given area. The adoption of equity fare models aims to reduce transport disadvantage by favoring the users of the system who are already at a very unfavorable position, intending to ensure equity.

Therefore, the following hypotheses are put forward in this dissertation:

1. It is possible to define and evaluate new equity criteria for determining fare zones in integrated passenger transport,
2. It is possible to devise an equity fare system model in integrated passenger transport using the said criteria.

Scientific research has identified the equity criteria for determining fare zones in integrated passenger transport. These provide an insight into the development of fare zones from the transport, economic, and demographic aspects. The identification is a prerequisite for determining all equity criteria relevant for establishing fare zones in integrated passenger transport.

System dynamics modeling has helped to establish the criteria relevant to an equity fare model which aims to prevent some of the criteria being repeated. The selection of representative indicators (equity criteria) for determining fare zones was made by system dynamics modeling using a causal loop diagram.

The definition of equity criteria meets the initial requirement for establishing the impact the criteria have on the cost of fare zones. For the defined equity criteria to be used to devise an equity fare model, the impact of each given criterion must be determined. This was done by

assessing the defined equity criteria using the analytic hierarchy process (AHP) methodology as one of the most recognized methods for multi – criteria decision – making. It was based on the rankings of 117 European experts for transport, economy, and demography.

The obtained weight coefficients of the defined equity criteria and sub – criteria are the prerequisite for devising an equity fare system model in integrated transport. The model was developed by upgrading the basic mathematical model for calculating the cost of a single journey within a zone by implementing the equity coefficient. The new model introduces the equity coefficient, which comprises the equity criteria and regulates the cost of a fare zone to ensure equality and prevent transport disadventage. The obtained model has ensured a transition from equality to equity and cost regulation from the aspects of equal transport, economic, and demographic development of each of the zones in the integrated transport.

The equity fare model was tested in the Sisak – Moslavina county which represented the most underdeveloped counties in the Republic of Croatia. The region is also characterized by a great number of rural areas and unequal transport, economic, and demographic development. Based on the case study, the model provides an overview of changes compared to the basic fare system. In other words, it outlines the changes based on which public transport service is charged equitably. Apart from the comparative analysis of the basic and equity fare system on the case study, a discussion of the obtained results is also provided.

The research has also put forward and confirmed two new scientific hypotheses. Hypothesis one confirms the possibility of defining and evaluating new equity criteria in three stages when determining fare zones in integrated passenger transport. The first stage saw a successful identification of potential equity criteria that affect the fare system: transport, economic, and demographic development of an area. In the second stage, system dynamics modeling and causal loop diagrams were used to define equity criteria for determining fare zones. Finally, in the third stage, the first hypothesis was confirmed in its entirety by assessing the defined criteria using the analytic hierarchy process methodology. The second hypothesis that had been put forward was confirmed after a model of the equity fare system in integrated passenger transport was devised using the new equity criteria.

Based on what has been stated above, the scientific contributions of the doctoral research are as follows:

- The establishment and evaluation of new equity criteria for determining fare zones in integrated passenger transport,

- The development of an equity fare system model based on the newly defined criteria for determining fare zones in integrated passenger transport.

The developed model and its adoption ensure service equity by engaging users who are in a more unfavorable position. The disadvantage of transport, social groups, and individuals is reduced from the transport service aspect. Transport demand increases in rural and underdeveloped areas because the transport service cost is adjusted to the area. The mission and vision of public transport are achieved in their entirety as public transport becomes available to all, under equitable, not equal, conditions. Equal conditions refer to the equal price per kilometer of a journey and not the equal quality of the transport service of equal economic and demographic development. This scientific research has created a foundation in the form of the first equity fare system in integrated passenger transport.

Keywords: integrated passenger transport, fare systems, zone fare systems, equity, transport disadvantage

SADRŽAJ

1. UVOD 1

1.1. Predmet istraživanja i znanstvene hipoteze 2

1.2. Cilj istraživanja i znanstveni doprinos 3

1.3. Korištene znanstvene metode 3

1.4. Struktura doktorskoga rada 4

2. ANALIZA NAČINA TARIFIRANJA U SUSTAVIMA INTEGRIRANOGA PRIJEVOZA 7

2.1. Sustav integriranoga prijevoza putnika 8

2.2. Pregled tarifnih sustava 10

2.3. Problem definiranja zona 13

2.4. Društveno korisni tarifni sustavi 14

3. IDENTIFIKACIJA PRAVIČNIH KRITERIJA PRI ODREĐIVANJU TARIFNIH ZONA U INTEGRIRANOM PRIJEVOZU PUTNIKA 17

3.1. Demografski kriteriji razvijenosti 20

3.1.1. Razmještaj stanovništva 20

3.1.2. Kretanje stanovništva 21

3.1.2.1. Opće (ukupno) kretanje 21

3.1.2.2. Prirodno kretanje 22

3.1.3. Sastav stanovništva 23

3.1.3.1. Biološki sastav 23

3.1.3.2. Gospodarski sastav 25

3.2. Gospodarski kriteriji razvijenosti 25

3.3. Prometni kriteriji razvijenosti 28

4. DEFINIRANJE PRAVIČNIH KRITERIJA PRI ODREĐIVANJU TARIFNIH ZONA U INTEGRIRANOM PRIJEVOZU PUTNIKA 31

4.1. Modeliranje sustavne dinamike 32

4.2. Dijagram uzročnih petlji (CLD) 36

4.3. Sustavna dinamika demografske razvijenosti 39

4.4. Sustavna dinamika gospodarske razvijenosti 44

4.5. Sustavna dinamika razvijenosti javnoga prijevoza putnika 48

4.6. Pravični kriteriji pri određivanju tarifnih zona u integriranom prijevozu putnika 54

5. VREDNOVANJE PRAVIČNIH KRITERIJA 58

5.1. Analitički hijerarhijski proces 59

5.2. Metodologija vredovanja pravičnih kriterija 63
5.3. Anketa za vrednovanje pravičnih kriterija 64
5.4. Rezultati vrednovanja pravičnih kriterija ..... .66

6. MODEL PRAVIČNOGA TARIFNOGA SUSTAVA U INTEGRIRANOM PRIJEVOZU PUTNIKA 75
7. TESTIRANJE MODELA 83

7.1. Metodologija testiranja modela 83
7.2. Geografske značajke Sisačko-moslavačke županije 85
7.3. Analiza pravičnih kriterija u naseljima Sisačko-moslavačke županije 95
7.3.1. Prometni kriteriji razvijenosti 95
7.3.2. Gospodarski kriteriji razvijenosti 102
7.3.3. Demografski kriteriji razvijenosti 109
7.4. Primjena pravičnoga tarifnoga modela 114
7.5. Diskusija dobivenih rezultata 118

8. ZAKLJUČAK 121
LITERATURA 124
POPIS SLIKA 129
POPIS TABLICA 131
PRILOZI 132
Životopis autora 165
Popis radova autora 166

„Price is what you pay.

Value is what you get."

Warren Buffett

1. Uvod

Javni prijevoz putnika podrazumijeva jednaku dostupnost svim korisnicima te mogućnost korištenja pod jednakim uvjetima. Činjenica da javni prijevoz nije jednako dostupan svima i pod jednakim uvjetima postavlja pitanje je li javni prijevoz putnika onakav kakvim ga se opisuje. U uvodnom je poglavlju definiran predmet istraživanja s posebnim naglaskom na motivaciji pri izradi doktorskoga rada. Definirane su znanstvene hipoteze, cilj istraživanja te očekivani znanstveni doprinos. Osim navedenoga prikazane su korištene znanstvene metode. Poglavlje završava opisom strukture doktorskoga rada.

1.1. Predmet istraživanja i znanstvene hipoteze

Predmet su istraživanja doktorskoga rada tarifni sustavi u integriranom prijevozu putnika. Najzastupljeniji su zonski tarifni sustavi koji se temelje na geografskom određivanju područja naplate te na određivanju cijene unutar zona uz pretpostavku kako cijena treba biti što bliža cijenama relacijskoga tarifnoga sustava. Relacijski tarifni sustav smatra se najpravednijim jer se cijena prijevozne usluge naplaćuje svima jednako po prijeđenom kilometru udaljenosti [1]. Općenita definicija javnoga prijevoza putnika govori kako on podrazumijeva jednaku dostupnost svim korisnicima na tržištu te kako se ni jednoga korisnika ne može isključiti iz mogućnosti korištenja [2]. Jednaka je dostupnost kod dosadašnjih tarifnih sustava predstavljena kao jednaka cijena po kilometru za svakoga korisnika prijevozne usluge, dok se jednaka dostupnost nije razmatrala s gledišta jednake prometne, gospodarske i demografske razvijenosti područja koja su obuhvaćena javnim prijevozom. Takav način razmišljanja dovodi do promjene unutar modela tarifnih sustava s ciljem izjednačavanja dionika u nepovoljnijem položaju i ostalih dionika te dovodi do sprječavanja prometne marginaliziranosti prostora i društva koje migrira takvim područjima. Primjenom pravičnih tarifnih modela teži se sprječavanju prometne marginaliziranosti davanjem dodatne naklonosti dionicima u nepovoljnijem položaju s ciljem izjednačavanja (Slika 1.).

Slika 1. Različitost jednakosti i pravičnosti u prometu [3]

Motivacija za izradu novoga tarifnoga modela koji se temelji na pravičnosti prometno su marginalizirani prostori, društvene skupine, ruralna i gospodarski slabije razvijena područja. S obzirom na prijevoznu potražnju i navedenu motivaciju usluga javnoga prijevoza putnika nije svima jednako dostupna pod jednakim uvjetima.

Na temelju navedenoga hipoteze su istraživanja u ovom doktorskom radu sljedeće:

1. Moguće je definirati i vrednovati nove pravične kriterije pri određivanju tarifnih zona u integriranom prijevozu putnika.
2. Moguće je izraditi model pravičnoga tarifnoga sustava u integriranom prijevozu putnika na temelju novodefiniranih kriterija.

1.2. Cilj istraživanja i znanstveni doprinos

Cilj je istraživanja razvoj pravičnoga tarifnoga modela u integriranom prijevozu putnika. U tom je smislu potrebno definirati i vrednovati kriterije koji utječu na pravičnost tarifnih sustava u integriranom prijevozu putnika te potom izraditi pravični tarifni model.

Znanstveni se doprinos očituje u:

- utvrđivanju novih pravičnih kriterija i njihovom vrednovanju pri određivanju tarifnih zona u integriranom prijevozu putnika
- razvoju modela pravičnoga tarifnoga sustava u integriranom prijevozu putnika na temelju novih definiranih kriterija za određivanje tarifnih zona u integriranom prijevozu putnika.

1.3. Korištene znanstvene metode

U skladu s postavljenim predmetom istraživanja, ciljem istraživanja, znanstvenim hipotezama i očekivanim znanstvenim doprinosom koristit će se sljedeće znanstvene metode:

- indukcija i dedukcija
- analiza i sinteza
- apstrakcija i konkretizacija
- generalizacija i specijalizacija

- kompilacija i komparacija
- klasifikacija
- statističke metode
- metoda teorije sustava
- deskripcija.

Navedene različite kombinacije znanstvenih metoda proizlaze iz same tematike istraživanja za koju su potrebna znanja iz područja prirodnih, tehničkih i društvenih znanosti. Znanstvene metode logičkoga zaključivanja, odnosno metode indukcije i dedukcije korištene su pri izradi dijagrama uzročnih petlji i određivanja uzročnih utjecaja između varijabla u četvrtom dijelu istraživanja. Osim navedene metode u četvrtom su dijelu istraživanja korištene i metode apstrakcije i konkretizacije te metoda teorije sustava koja je detaljno opisana u navedenom dijelu istraživanja. Apstrakcija i konkretizacija postupci su srodni analizi i sintezi, a razlika je u izdvajanju važnih elemenata iz cjeline koju metoda apstrakcije pruža za razliku od analize, dok je metoda konkretizacije suprotna apstrakciji. Metoda je analize i sinteze korištena u drugom dijelu istraživanja pri analizi dosadašnjih istraživanja o načinima tarifiranja u sustavima integriranoga prijevoza putnika. U drugom je dijelu istraživanja također korištena metoda kompilacije i komparacije kao neizostavna metoda pri pisanju istraživačkih radova zbog preuzimanja tuđih rezultata, odnosno tuđih opažanja i zaključaka. U trećem je dijelu istraživanja pri identifikaciji pravičnih kriterija korištena metoda generalizacije i specijalizacije zbog postupka uočavanja, odnosno identifikacije kriterija. Metoda je klasifikacije kao znanstvena metoda raspodjele primijenjena u petom dijelu istraživanja za raspodjelu pravičnih kriterija i bolju vizualizaciju pri stručnom vrednovanju kriterija. Pri razvoju je modela pravičnoga tarifnoga sustava u šestom dijelu istraživanja te testiranju modela u sedmom dijelu istraživanja korištena statistička metoda koja omogućuje istraživanje pojava s pomoću brojčanoga izražavanja. Znanstvena je metoda deskripcije primijenjena u sedmom dijelu istraživanja za opisivanje pojava u studiji slučaja primjene pravičnoga tarifnoga modela.

1.4. Struktura doktorskoga rada

Predmet istraživanja kao i navedene postavljene hipoteze nametnule su potrebu predstavljanja rezultata istraživanja doktorskoga rada kroz osam međusobno povezanih dijelova (poglavlja).

U prvom je dijelu, ***UVODU***, definiran predmet istraživanja s naglaskom na motivaciji izrade doktorskoga rada, znanstvenoj hipotezi, cilju istraživanja, očekivanom znanstvenom doprinosu, korištenim znanstvenim metodama tijekom izrade doktorskoga rada te njegovoj strukturi.

Drugi dio, ***ANALIZA NAČINA TARIFIRANJA U SUSTAVIMA INTEGRIRANOGA PRIJEVOZA PUTNIKA,*** analizira dosadašnja istraživanja o načinima tarifiranja u sustavima integriranoga prijevoza putnika. Podijeljen je na pregled istraživanja o samom sustavu integriranoga prijevoza putnika, tarifnim sustavima, problemima definiranja zona te o društveno korisnim tarifnim sustavima.

U trećem su dijelu, ***IDENTIFIKACIJI PRAVIČNIH KRITERIJA PRI ODREĐIVANJU TARIFNIH ZONA U INTEGRIRANOM PRIJEVOZU PUTNIKA,*** kroz literaturu identificirani svi potencijalni pravični kriteriji koji se mogu iščitati kao kriteriji prometne, gospodarske i demografske razvijenosti područja.

Četvrti dio, ***DEFINIRANJE PRAVIČNIH KRITERIJA PRI ODREĐIVANJU TARIFNIH ZONA U INTEGRIRANOM PRIJEVOZU PUTNIKA***, prikazuje način određivanja relevantnih pravičnih kriterija za određivanje tarifnih zona u integriranom prijevozu putnika. Opisuje metodologiju sustavne dinamike kao sredstva za određivanje i kritički se osvrće na rezultate koji su dobiveni spomenutom metodom.

U petom je dijelu, ***VREDNOVANJU PRAVIČNIH KRITERIJA***, za definirane pravične kriterije utvrđen utjecaj svakoga pojedinačnoga kriterija. Utjecaj kriterija određen je vrednovanjem definiranih pravičnih kriterija s pomoću metode analitičkoga hijerarhijskoga procesa kao jedne od najpoznatijih metoda za višekriterijsko odlučivanje.

Šesti dio, ***MODEL PRAVIČNOGA TARIFNOGA SUSTAVA U INTEGRIRANOM PRIJEVOZU PUTNIKA,*** donosi razvoj modela koji se temelji na osnovnom tarifnom modelu i koeficijentu pravičnosti kojim se postiže promjena iz jednakosti u pravičnost i cjenovna regulacija s gledišta prometne, gospodarske i demografske razvijenosti svake pojedine tarifne zone u integriranom prijevozu putnika.

U sedmom dijelu, ***TESTIRANJU MODELA,*** provodi se analiza i utvrđivanje točnosti modela na konkretnoj studiji slučaja. Daje se jasan prikaz promjene iz jednakosti u pravičnost usporednom analizom osnovnoga i pravičnoga tarifnog modela naplate u javnom prijevozu putnika.

U osmom su dijelu, ***ZAKLJUČKU***, donesena zaključna razmatranja koja se temelje na dobivenim rezultatima istraživanja, a na temelju kojih su dokazane postavljene znanstvene

hipoteze predmetnoga istraživanja te su dani izvorni znanstveni doprinosi. Osim navedenoga prikazan je i pogled u buduća istraživanja i potencijalne benefite razvijenoga modela u praksi.

„Analysis is the critical starting point of strategic thinking."

Kenichi Ohmae

2. Analiza načina tarifiranja u sustavima integriranoga prijevoza putnika

U ovom će se poglavlju provesti analiza dosadašnjih istraživanja o načinima tarifiranja u sustavima integriranoga prijevoza putnika. Pritom će se posebna pozornost pridati nedostatcima u istraživanjima tarifnoga planiranja i prostoru za optimiziranje procesa tarifiranja. Tarifno planiranje u javnom prijevozu putnika predstavlja zahtjevan optimizacijski proces. Različitost shvaćanja modela tarifnoga planiranja ogleda se u željama korisnika i operativnim troškovima pružatelja usluga javnoga prijevoza. Definiranje tarifa može značajno utjecati na ponašanje korisnika i njihov izbor načina putovanja, stoga je potrebno objektivno planirati tarifne sustave kako bi se pozitivno utjecalo na prijevoznu potražnju.

2.1. Sustav integriranoga prijevoza putnika

Istraživanja na području mobilnosti stanovništva zauzimaju važan dio prometne znanosti s ciljem poboljšanja kvalitete življenja. Pritom javni prijevoz putnika ima glavnu ulogu jer pridonosi smanjenju prometnih zagušenja koja su uzrokovana korištenjem osobnih automobila. Kako bi se poboljšala kvaliteta prijevozne usluge, povećala atraktivnost te privukli i zadržali korisnici, u sustavu javnoga prijevoza počinje se osmišljavati i uvoditi integrirani sustav javnoga prijevoza putnika.

Integrirani javni prijevoz putnika prvi se put spominje u Njemačkoj, Švicarskoj i Austriji, a prvo je uvođenje takvoga sustava bilo 1965. godine u Hamburgu. Statistički podatci prema *Šťastná et al.* [4] pokazuju da uvođenje takvih sustava u sustav javnoga prijevoza putnika pridonosi povećanju korisnika javnoga prijevoza koji prelaze s osobnih automobila na usluge javnoga prijevoza. Koncept integriranoga prijevoza putnika predstavlja nov, odnosno posljednje osmišljen i aktualan način organiziranja i upravljanja javnim prijevozom putnika.

S porastom intenziteta urbanoga prometa kod uobičajenih se načina javnoga prijevoza putnika, kao što su željeznički, autobusni i tramvajski promet, javljaju nedostatci za svaki prijevozni mod koji sprječava daljnji razvitak gradova. Autori *Li CB et al.* [5] predlažu integraciju prijevoznih modova s ciljem bolje koordinacije i sinkronizacije u javnom prijevozu putnika.

U radu je autora *Šťastná i Vaishar* [6] uočeno kako pokrivenost ruralnih krajeva javnim prijevozom putnika predstavlja ključan problem mobilnosti stanovništva koje živi u tim krajevima. Razvijene zemlje nastoje imati kvalitetan javni prijevoz u periurbanim i ruralnim krajevima kao alternativu osobnim automobilima zbog zaštite okoliša, no usporedno se postavlja pitanje financijske isplativosti. Podjele su područja na urbana, periurbana i ruralna u pravilu vezane uz gustoću naseljenosti, veličinu područja te infrastrukturna i morfološka obilježja područja. U manje razvijenim zemljama prijevoznici nastoje održavati samo najisplativije linije kako bi mogli ostvarivati veće prihode. Šipuš i Abramović [7] uočavaju pojavu stalnoga iseljavanja stanovništva ruralnih krajeva te potrebu ulaganja u prometni sektor kako bi se postavili temelji za daljnji dugoročni razvoj ruralnih područja. Dostupnost javnoga prijevoza, kvalitetno upravljanje linijma te uspostava integriranih prometnih sustava u javnom prijevozu pridonijeli bi povećanju prometne pravednosti, smanjenju trenda iseljavanja iz ruralnih krajeva i općenito olakšanju života stanovništvu koje živi u periurbanim i ruralnim krajevima.

Kopecká i Švetak [8] naglašavaju nekoliko važnih preduvjeta uvođenju sustava integriranoga prijevoza putnika. Pokretanje integriranoga prijevoza putnika zahtijeva određenu razinu prijevozne potražnje na području uvođenja. Važno je oblikovanje izvorišno-odredišnih (IO) matrica kako bi se mogla promatrati putovanja mogućih korisnika, odnosno putnika. Mrežni se linijski plan na području uvođenja sustava usklađuje prema željezničkim linijama koje predstavljaju nositelja prometnoga opterećenja sustava. Osim spomenutih preduvjeta za uvođenje sustava integriranoga prijevoza putnika naglašava se potreba usklađivanja voznih redova i tarifa koje su korisne za prijevoznike te korisnike usluga prijevoza.

Mjesta integracije prijevoznih modova osiguravaju siguran i neometan prelazak putnika s jednoga prijevoznoga moda na drugi. *Čejka et al.*[9] predlažu izgradnju ili premještanje autobusnih terminala uz željezničke kolodvore. Sustav integriranoga prijevoza putnika također zahtijeva dobru povezanost s korisnicima osobnih automobila izgradnjom P+R (engl. *park and ride*) sustava i korisnicima bicikala osiguravanjem mjesta za odlaganje bicikala. Važna mjesta u sustavu integracije podrazumijevaju P+R sustave za dugoročno čuvanje osobnih automobila i opremljenost uređajima za sigurno čuvanje bicikala.

Zadovoljstvo korisnika usluga javnoga prijevoza putnika ovisi o karakteristikama sustava koji pruža spomenute usluge i očekivanjima korisnika. *Filipović et al.* [10] definiraju kvalitetu usluge kao sposobnost pružatelja usluge da zadovolji sve zahtjeve i predviđene potrebe korisnika. Utvrđuju se četiri pogleda na kvalitetu pružanja usluge: očekivana kvaliteta, ciljana kvaliteta, stvarna kvaliteta i postignuta kvaliteta. Očekivana kvaliteta izražava potrebe korisnika za planiranjem, projektiranjem i unaprjeđenjem usluge, odnosno za shvaćanjem potreba korisnika. Razina povezanosti potreba korisnika s mogućnostima pružanja usluga prijevoznika definira se kao ciljana kvaliteta. Stvarna kvaliteta predstavlja razinu svakodnevno postignutih usluga, dok se postignutom kvalitetom izražava razina zadovoljstva korisnika pruženom uslugom. U radu autora *Sumaedi et al.* [11] zadovoljstvo korisnika prijevoza pruženom uslugom definira se latentnom varijablom jer ne može biti izravno izmjereno, ali može biti procijenjeno koristeći se jednim ili više indikatora. Navode zadovoljstvo korisnika kao presliku korisnikove mentalne slike ponude koja uključuje simboličko shvaćanje posebnih produkata koji su proizišli iz ostvarene usluge.

Stopka et al. [12] smatraju kako se tarifnom integracijom različitih prijevoznih modova na području obuhvata sustava integriranoga prijevoza putnika omogućavaju najbolji financijski uvjeti putovanja putnicima koji mijenjaju prijevozne modove. Provedena su anketna istraživanja pokazala kako korisnicima sustav integriranoga prijevoza putnika u odnosu na

klasični sustav javnoga prijevoza nije značajan ako se njime ne dobiva kraće vrijeme putovanja i manja cijena prijevozne karte.

Istraživanja su autora *Reis i Macario* [13] također pokazala kako postoji niz prepreka pri uvođenju i provedbi integracije u prometu te su ju klasificirali na: fizičku – odnosi se na planiranje i upravljanje prometnom infrastrukturom, logičku – davanje potrebnih informacija korisnicima, ekonomsku – pružanje potrebnih tehnologija i pravila po kojima se obavlja raspodjela prihoda u sustavu, ugovornu – okvir u kojem se određuju pravila suradnje dionika u sustavu, institucijsku – strukturni aspekti dionika te pravnu i regulatornu – integracija između različitih vrsta prijevoznih modova.

2.2. Pregled tarifnih sustava

Razlozi istraživanja i promišljanja o modelima tarifnih sustava u javnom prijevozu temelje se na činjenici da su oni izravni i fleksibilni instrument kojim se utječe na ponašanje putnika i povrat troškova javnoga prijevoznoga sustava. Empirijska su istraživanja autora *Šťastná i Vaishar* [6] dokazala da izbor putovanja korisnika ovisi o više čimbenika, ponajprije o dostupnosti, vremenu putovanja, posjedovanju automobila, povlaštenim godišnjim kartama i tarifama.

Tarifni se sustavi u praksi temelje na izračunu cijene putovanja po kilometru prijeđenoga puta, prelascima definiranih zona i vremenskim ograničenjima.

Modeli za planiranje tarifnih sustava u javnom prijevozu ciljano služe maksimiziranju: potražnje, prihoda, dobiti i društvene korisnosti. Autori *Borndorfer et al*. u istraživanjima [14, 15] predlažu nelinearni optimizacijski pristup tarifnom planiranju koji se temelji na detaljnom diskretnom izboru ponašanja korisnika. Predlažu se četiri modela za planiranje tarifa koji uključuju različite aspekte čija prilagođenost ovisi o posebnim stajalištima planiranja. Najjednostavniji je model u planiranju tarifa model za maksimiziranje prihoda koji se temelji na posebnim interesima korisnika ili političkim ciljevima. Drugi je model prilagođen maksimiziranju dobiti te uključuje operativne troškove na linijama. Može se zaključiti kako takav model predstavlja razliku modela za maksimiziranje prihoda i operativnih troškova koji su uzrokovani putovanjima. Treći model predstavlja maksimiziranje potražnje prijevozne usluge. U pravilu se u literaturi potražnja promatra u kontekstu putničkih kilometara. Osim spomenutih modela ističe se model maksimiziranja funkcioniranja društvene korisnosti. On

predstavlja zbroj koristi davatelja prijevoznih usluga i koristi korisnika prijevoza. Koristi davatelja prijevoznih usluga predstavljaju dobit (prihodi minus trošak), dok su koristi korisnika prijevoza razlika između generalizirane cijene koja je prihvatljiva korisniku i stvarne generalizirane cijene koju plaća za dobivenu uslugu prijevoza. Naglašava se utjecaj političkih, društvenih i vanjskih ograničenja pri izboru modela tarifnoga planiranja.

Studije slučaja u navedenim istraživanjima uključuju IO matrice putovanja putnika većinom na kratkim udaljenostima, od 0,5 do 10 kilometara za putovanja u javnom prijevozu i putovanja osobnim automobilom. Putovanja osobnim automobilima ne uključuju dodatno vrijeme koje je potrebno za, primjerice, parkiranje automobila i plaćanje parkiranja. Naglašava se različitost elastičnosti cijena jednokratnih prijevoznih karata u odnosu na cijene mjesečnih prijevoznih karata zbog pretpostavke da su korisnici mjesečnih prijevoznih karata osjetljiviji na svaku promjenu cijena. Razrađeni modeli uzimaju pretpostavku da svi korisnici prijevoza imaju mogućnost korištenja automobila, što na kraju dovodi do veće konkurentnosti između osobnih automobila i mjesečnih karata u javnom prijevozu nego u stvarnosti. U stvarnosti dio stalnih korisnika mjesečnih i godišnjih prijevoznih karata ne posjeduje osobni automobil te je manje osjetljiv na elastičnost cijena karata.

Huang et al. [16] navode kako unatoč ulaganju sredstava u prometnu infrastrukturu mnogi gradski sustavi prijevoza ne zadovoljavaju potrebe korisnika. Prihodi od prodaje prijevoznih karata teško pokrivaju operativne troškove, stoga većina prijevozničkih poduzeća podnosi gubitke suočavajući se pritom s problemima opstanka na tržištu. Temeljni je problem regulacije društveno korisnoga tarifiranja u prijevozu osiguravanje financijske ravnoteže između prijevozničkih poduzeća i prijevozničkih nadležnih tijela. Naglašavaju važnost međuovisnosti dionika u reguliranju tarifnih sustava prijevozničkih poduzeća, prijevozničkih nadležnih tijela i korisnika. Prijevoznička nadležna tijela reguliraju tarifno funkcioniranje i podugovaraju prijevoznička poduzeća koja pružaju usluge prijevoza putnika. Uočavaju njihovu nepovezanost u definiranju tarifnih sustava i frekventnosti polazaka te uvode model za definiranje tarifnih sustava u koji je uključeno sudjelovanje svih triju dionika (Slika 2.). Naglašava se važnost komunikacije u tri smjera: prijevoznička nadležna tijela – prijevoznička poduzeća, zbog određivanja cijena i subvencioniranja, prijevoznička nadležna tijela – korisnici i prijevoznička poduzeća – korisnici. Prijevoznička nadležna tijela promatraju javni prijevoz kao javno dobro te teže maksimiziranju društvene korisnosti. Prijevoznička poduzeća više teže ukupnoj dobiti koja bi im osigurala nastavak djelovanja i održivi razvoj, dok korisnici teže minimalnoj cijeni ukupnih troškova usluga prijevoza.

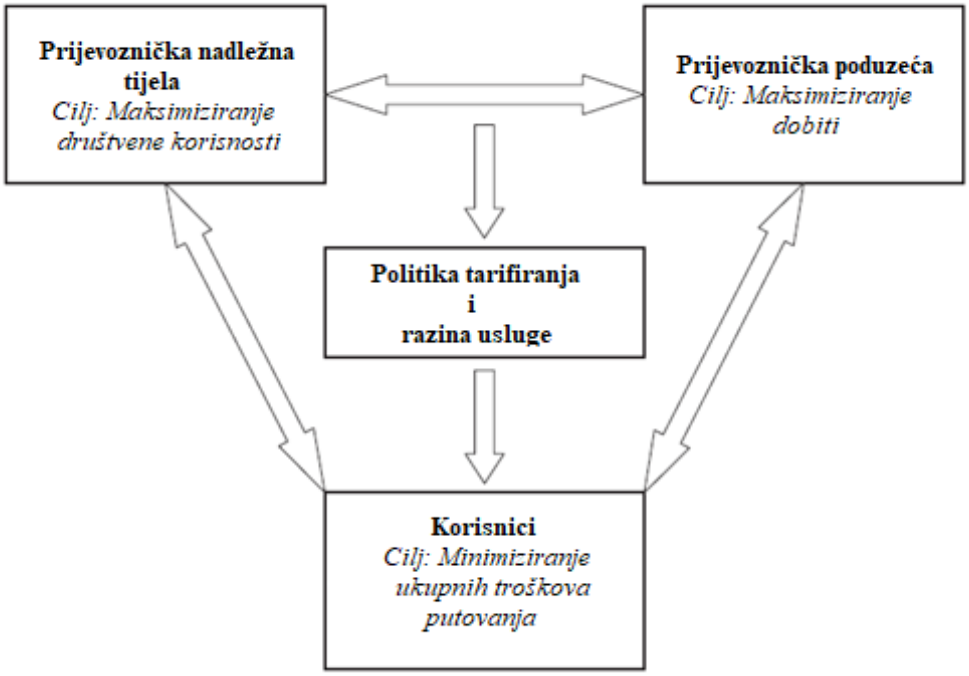

Slika 2. Odnos dionika u stvaranju tarifnoga sustava [16]

Drdla i Bulíček [17] navode shvaćanje sljedećih važnih promjena u odnosu na standardne tarifne sustave: promjene u *check-in* tehnologiji, uvođenje prenosivih prijevoznih karata – tarifa u regionalnom autobusnom prijevozu i uvođenje jedinstvenih prijevoznih karata s vremenskim ili zonskim ograničenjima. Istaknuti su zahtjevi tarifnih sustava u integriranom prijevoznom sustavu koje moraju ispunjavati ciljevi individualnih dionika: jednostavan i brz način plaćanja prijevoznih usluga i prijava u sustav, osiguravanje uvjeta organizacije i razvoja integriranoga prijevoznoga sustava, osiguravanje jasnoga poravnavanja prihoda između prijevoznika i provjera prijevoznih učinaka, prikupljanje statističkih podataka o sustavu (dinamika putnika, broj putnika na pojedinim linijama itd.), poboljšavanje pristupačnosti javnoga prijevoza putnicima i omogućavanje razvitka tarifa koje se temelje na optimalnoj cijeni za realiziranu prijevoznu uslugu, smanjivanje operativnih troškova (print, distribucija, prodaja prijevoznih dokumenata), visoka razina sigurnosti sustava (zaštita od krivotvorenja prijevoznih dokumenata), smanjenje broja *slijepih putnika* – putnika bez prijevoznih karata. U integriranom prijevozu putnika koriste se tri tipa tarifnoga oblikovanja: zonski, kombinacija zona i vremenskih ograničenja i daljinski (km). Kod zonskoga je tarifnoga sustava područje obuhvata podijeljeno na tarifne prostorne zone koje imaju svoju cijenu te putniku raste cijena prijevozne karte proporcionalno prelasku zona. Kombiniranjem zonskih i vremenskih tarifnih sustava

dobiva se dodatno ograničenje valjanosti prijevozne karte u skladu s vremenom putovanja. Ovisnost cijene prijevozne karte o prijeđenoj udaljenosti u kilometrima javlja se kod tarifnih sustava koji se temelje na duljini pružene prijevozne usluge.

U današnje se vrijeme sve više upotrebljavaju beskontaktne pametne kartice i potpuno je opravdano njihovo uključivanje u različite tarifne strukture. Autori *Bouteiller et al.* [18] tvrde kako tarifni sustavi u kombinaciji s beskontaktnim pametnim karticama omogućavaju dobivanje važnih informacija o putovanju koje utječu na izračun cijena pruženih prijevoznih usluga. Osim za određivanja cijena prijevoza moguće je prikupiti podatke i za kapacitiranje kolodvora. Sustav pametnih kartica svakodnevno prikuplja informacije o kretanju, odnosno ponašanju korisnika te omogućava konstrukciju zadovoljavajućih IO matrica. Težnja za tim da svi putnici očitaju beskontaktne kartice u vozilima omogućava dobivanje informacija o serijskom broju putnikove pametne kartice, imenu i identifikacijskom broju polaznoga stajališta, datumu i vremenu njegovoga ulaska te liniji autobusa i broju priključka, odnosno varijanti ruta.

2.3. Problem definiranja zona

Dizajniranje je tarifnih sustava u sustavima integriranoga prijevoza putnika važan čimbenik za shvaćanje i motiviranje korisnika, također i prijevoznika i prijevozničkih nadležnih tijela uključenih u sustav. *Kohání* [19,20] navodi nekoliko načina dizajniranja tarifnih sustava: relacijski, jedinstveni i zonski. Naglašava da se relacijski tarifni sustavi smatraju pravednim tarifnim sustavima jer se cijena plaća za stvarno dobivenu uslugu po kilometru putovanja. Jedinstveni tarifni sustavi koji imaju istu cijenu prijevozne usluge za cijelo područje usluživanja obično se koriste u gradskom javnom prijevozu, ali nisu pogodni za regionalni javni prijevoz jer kratka putovanja između dvaju stajališta ne mogu imati istu cijenu kao i putovanja na dužim relacijama koje su pokrivene regionalnim javnim prijevozom. Treći je način koji se obično koristi u sustavima integriranoga prijevoza putnika zonski tarifni sustav koji predstavlja kombinaciju relacijskoga i jedinstvenoga tarifnog sustava. Kod takvih je sustava cijelo područje podijeljeno na niz manjih područja te se cijena za pruženu uslugu prijevoza naplaćuje prema broju zona koje su korištene u putovanjima. Ističu se dva problema pri dizajniranju zonskih tarifnih sustava:

1. određivanje područja svake zone – podjela zona
2. određivanje optimalne naplate.

Oblikovan je matematički model za dizajniranje tarifnih zona koji se temelji na brojenju zona koje uključuju parametre modeliranja utjecaja promjene cijene na potražnju u prijevozu. Fokus je takvoga modela na utjecaju promjena u potražnji prijevoza pri dizajniranju tarifnih zona i podjeli stajališta u tarifnim zonama.

Zonski su tarifni sustavi vrlo popularni zbog svoje jednostavnosti i pristupačnosti informacija putnicima, stoga se većinom upotrebljavaju pri dizajniranju tarifnih sustava u integriranom prijevozu putnika. Pri dizajniranju spomenutih sustava *Hamacher i Schöbel* [21] naglašavaju potrebu za postizanjem prometno pravednih zonskih tarifa. Pravedni zonski tarifni sustavi podrazumijevaju prilagodbu preporučenoj cijeni pružene usluge prijevoza koja je općenito smatrana pravednom kao spomenuti relacijski tarifni sustav. Takav pristup od prijevozničkih kompanija zahtijeva procjenu njihovih novih prihoda.

Jansson [22] definira optimalnu cijenu prijevozne usluge kao jednakost zbroja prijevoznikovih graničnih troškova i graničnih vanjskih utjecaja na putnike, odnosno kao razliku prijevoznikovih varijabilnih troškova i vremena u kojem se stvara financijski deficit.

2.4. Društveno korisni tarifni sustavi

Pitanja koja se često postavljaju u istraživanjima o integriranom prijevozu putnika usmjerena su na otkrivanje čimbenika koji utječu na spremnost, odnosno želju za korištenjem takvih sustava. Istraživanja *Chowdhuryja* [23] pokazala su kako na korisnikovu želju za korištenjem takvih sustava utječu tri čimbenika: psihološki, operativni i politički. U psihološke čimbenike svrstavaju percepciju o javnom prijevozu, tehnike marketinga, kognitivne modele te navike i ponašanje prema okolišu. Operativni čimbenici uključuju sigurnost i zaštitu, pouzdanost, vrijeme putovanja, informacijske sustave, izdavanje prijevoznih karata i tarifne sustave te komfor, odnosno udobnost, dok političke čimbenike predstavljaju *push and pull* strategije, zakoni, ekonomičnost, informacije i obrazovanje te osobni planovi putovanja.

Chen et al. [24] naglašavaju potrebu maksimiziranja društvene koristi u prijevozu te predlažu modele za određivanje optimalnih uvjeta kako bi se omogućilo njezino postizanje. Razlog je tomu činjenica da putnici teže smanjenju vremena i cijene putovanja, odnosno

povećanju komfora. Prijevoznici teže maksimiziranju vlastitih dobiti, dok prijevoznička nadležna tijela pokušavaju minimalizirati ukupno prosječno vrijeme putovanja unutar približno stalne potražnje ili maksimizirati društvenu korist s obzirom na prisutnu elastičnu potražnju. Iz perspektive prijevozničkih nadležnih tijela društvena se korist sastoji od korisnikova viška naplaćenih sredstava i dobiti prijevozničkih poduzeća. Korisnikov se višak definira kao razlika između maksimalne cijene koju bi korisnik želio platiti i trenutačne cijene za pruženu uslugu.

Mjere za maksimiziranje društvene korisnosti i pravednosti zahtijevaju bitne promjene u cjelokupnom tarifnom sustavu i prijevoznoj ponudi. Ponajviše se odnose na smanjenje cijena za pružanje prijevoznih usluga i povećanje frekvencije polazaka. Spomenute mjere generiraju povećani financijski deficit prijevoznika, odnosno prijevozničkih nadležnih tijela zbog veće potrebe za subvencioniranjem javnoga prijevoza putnika, što u svojim radovima navode autori *Holmgren, Guzman et al. i Čarný et al.* [25 – 27]. Problemi se javljaju kod nadležnih tijela s većim financijskim ograničenjima.

Prijevoz ima važnu ulogu u izbjegavanju društvene isključenosti. Optimizacija tarifnih sustava koja se temelji na društvenoj pravednosti predstavlja važan dio planiranja u javnom prijevozu putnika. Istraživanja *Houstona i Tilleyja* [28] naglašavaju važnosti optimizacije tarifnih sustava za posebne skupine putnika kao što su na primjer mladi, osobe s invaliditetom, žene i stariji.

Analiziranjem radova o prometnom planiranju u javnom prijevozu putnika nailazi se na pojam prometne marginaliziranosti. Prometna marginalizacija prema Gašparoviću [29] predstavlja proces postavljanja pojedinca ili skupine na položaj na kojem im se pridaje ograničena društvena važnost zbog ograničenoga pristupa prometnom sustavu. Primjerena mobilnost te dostupnost osnovni su zahtjevi današnjega društva u cjelini. Prometno marginaliziranim prostorom smatra se onaj prostor u kojem stupanj dostupnosti nije dovoljno visok kako bi omogućio neometan pristup životnim aktivnostima. Parametre dostupnosti dijele na sljedeće skupine: prostorne, vremenske, financijske, ekološke, infrastrukturne i institucionalne. Shvaćanje tarifnih sustava u javnom prijevozu putnika u kontekstu sprječavanja prometne marginaliziranosti predstavlja sastavni dio društvene politike i prometnoga planiranja. Uočava se nedostatak istraživanja tarifnih sustava s gledišta prometne marginaliziranosti, posebice optimizacije tarifnih sustava u integriranom prijevozu putnika. *Martens* naglašava [30] važnost i dužnost prijevozničkih nadležnih tijela u pružanju pravednoga planiranja i naplate javnih prijevoznih usluga s društvenoga i prostornoga aspekta. Potrebno je

jačanje svijesti o potrebi postizanja i omogućavanja dostatne razine mobilnosti i dostupnosti za svakoga pojedinca odnosno društvenu skupinu.

„Ethics and equity and the principles of justice

do not change with the calendar."

D. H. Lawrence

3. Identifikacija pravičnih kriterija pri određivanju tarifnih zona u integriranom prijevozu putnika

U trećem su poglavlju identificirani svi potencijalni pravični kriteriji koji su navedeni u znanstvenoj i stručnoj literaturi kao kriteriji prometne, gospodarske i demografske razvijenosti područja. Identifikacija je kriterija nužna kako bi se u sljedećem koraku mogli utvrditi svi relevantni pravični kriteriji za određivanje tarifnih zona u integriranom prijevozu putnika.

Izrada pravičnoga tarifnoga modela u integriranom prijevozu putnika zahtijeva identifikaciju i utvrđivanje pravičnih kriterija definiranja tarifnih zona. Pravični se kriteriji definiranja tarifnih zona mogu identificirati kroz tri skupine kriterija razvijenosti: demografske, gospodarske i prometne. Posebnu pozornost treba pridati kriterijima prometne razvijenosti koji uvelike utječu na prometnu pravičnost odnosno prometnu marginaliziranost pojedinih područja i skupina ljudi. Identifikacija je pravičnih kriterija definiranja tarifnih zona u integriranom prijevozu putnika preduvjet utvrđivanju bitnih kriterija za izradu pravičnih tarifnih zona.

Demografski kriteriji razvijenosti proučavaju stanovništvo s kvantitativnoga i kvalitativnoga stajališta, odnosno proučavaju njegovu brojnost, razvoj, sastav i strukturu te prirodno i mehaničko kretanje [31]. Gospodarski kriteriji razvijenosti utvrđuju gospodarsku razvijenost područja, a prometni kriteriji razvijenosti govore o kvaliteti i razvijenosti javnoga prijevoza putnika na promatranom području.

Autori *Perišić i Wagner* [32] navode indeks razvijenosti kao kompozitni pokazatelj razvijenosti područja koji se računa kao ponderirani prosjek pet društveno-ekonomskih pokazatelja koji su sljedeći:

1. prosječni dohodak *per capita*
2. prosječni izvorni prihodi jedinica lokalne samouprave, odnosno jedinica regionalne samouprave *per capita*
3. prosječna stopa nezaposlenosti
4. opće kretanje stanovništva
5. udio obrazovanoga stanovništva u ukupnom stanovništvu dobi 16 – 65 godina.

Indeks razvijenosti lokalne jedinice (c) izračunava se s pomoću formule [32]:

$$I_c = 0{,}25X_{c1} + 0{,}15X_{c2} + 0{,}3X_{c3} + 0{,}15X_{c4} + 0{,}15X_{c5}\ , \qquad (1.)$$

pri čemu je:

c – lokalna jedinica

X_1 – prosječni dohodak *per capita*

X_2 – prosječni izvorni prihodi jedinica lokalne samouprave, odnosno jedinica regionalne samouprave *per capita*

X_3 – prosječna stopa nezaposlenosti

X_4 – opće kretanje stanovništva

X_5 – udio obrazovanoga stanovništva u ukupnom stanovništvu dobi 16 – 65 godina.

Dohodak po stanovniku izračunava se kao omjer ukupnoga iznosa dohotka koji su tijekom jednoga poreznoga razdoblja (kalendarske godine) ostvarili porezni obveznici, fizičke osobe s prebivalištem ili uobičajenim boravištem na području jedinice lokalne, odnosno područne (regionalne) samouprave za koju se obavlja izračun i broja stanovnika koji žive na području te jedinice. Proračunski prihodi jedinica lokalne, odnosno regionalne samouprave po stanovniku izračunavaju se kao omjer ostvarenih prihoda jedinica lokalne, odnosno regionalne samouprave (umanjenih za prihode domaćih i stranih pomoći i donacija, prihode iz posebnih ugovora – sufinanciranje građana za mjesnu samoupravu, prihode koji su ostvareni na temelju dodatnih udjela u porezu na dohodak i pomoći za izravnanja za financiranje decentraliziranih funkcija te prihode od prireza porezu na dohodak) i broja stanovnika na području jedinice lokalne, odnosno regionalne samouprave. Prosječna stopa nezaposlenosti izračunava se kao omjer broja nezaposlenih i zbroja zaposlenih te nezaposlenih osoba na području pojedine jedinice lokalne, odnosno regionalne samouprave. Opće kretanje stanovništva izračunava se kao omjer usporedivoga broja stanovnika jedinica lokalne, odnosno područne (regionalne) samouprave u dvama posljednjim popisima stanovništva Republike Hrvatske. Stopa obrazovanosti izračunava se kao udjel stanovništva sa završenom srednjom školom i višom razinom obrazovanosti u ukupnom stanovništvu, u dobi između 16 i 65 godina, na području jedinice lokalne, odnosno regionalne samouprave.

Navedeni društveno-ekonomski pokazatelji razvijenosti ne utvrđuju aspekt prometne razvijenosti koji je ključan pokazatelj pri izradi pravičnih tarifnih sustava u integriranom javnom prijevozu putnika. Stoga se javlja potreba za detaljnim sagledavanjem svakoga pojedinoga aspekta razvijenosti kako bi se identificirali svi kriteriji koji utječu na pravičnost i kojima je svrhom eliminiranje postojanja društvene isključenosti i prometne marginaliziranosti.

3.1. Demografski kriteriji razvijenosti

Demografska razvijenost nameće se kao važan teorijski pojam suvremene demografije. On označava proces razvoja stanovništva na nekom prostoru. Stanovništvo predstavlja osnovni čimbenik gospodarskoga razvoja jer pokreće proizvodnju, ali i izravno sudjeluje u potrošnji proizvedenih dobara i usluga, odnosno stvaranju prijevozne potražnje. Nepovoljni demografski trendovi pridonose smanjenju ukupnoga ljudskoga potencijala te u značajnoj mjeri mogu izazvati poremećaje u proizvođačkoj i potrošačkoj ulozi stanovništva. Ulaganje je u stanovništvo i u kvalitetu življenja stanovništva na nekom području povezano s napretkom društva u svim njegovim dijelovima.

Demografski kriteriji razvijenosti smatraju se relevantnima za određivanje smjera društveno-ekonomskoga razvoja, a mogu se podijeliti na:

1. razmještaj
2. kretanje
3. sastav i strukturu stanovništva.

3.1.1. Razmještaj stanovništva

Stanovništvo je skup osoba koje žive i rade na nekom prostoru. Može se govoriti o stanovništvu svijeta, kontinenata, država, regija, naselja i drugih prostornih jedinica. Razmještaj stanovništva jedna je od temeljnih značajka i bitnih teškoća suvremenoga čovječanstva jer je s neravnomjernom gustoćom naseljenosti povezano mnoštvo drugih teškoća koje zahvaćaju globalne zajednice [33]. Pod gustoćom naseljenosti podrazumijevamo broj stanovnika koji živi na nekom području. Aritmetička ili opća relativna gustoća naseljenosti pokazuje broj stanovnika na jedinici površine.

$$Gustoća\ naseljenosti = \frac{broj\ stanovnika}{površina\ istoga\ područja}\left[\frac{stanovnici}{km^2}\right] \quad (2.)$$

Nejašmić [31] kategorizira gustoću naseljenosti na sljedeći način:

1. *rijetko* naseljeni prostori – manje od 15 stanovnika na 1 km^2
2. *srednje* naseljeni prostoru – od 15 do 64 stanovnika na 1 km^2
3. *gusto* naseljeni prostori – od 65 do 115 stanovnika na 1 km^2
4. *prenaseljeni* prostori – više od 115 stanovnika na 1 km^2.

3.1.2. Kretanje stanovništva

Kretanje stanovništva posljedica je prirodnoga kretanja i pokretljivosti u prostoru (migracija). Pokazatelji su prirodnoga kretanja stopa rodnosti ili natalitet i stopa smrtnosti, odnosno mortalitet, dok se pokazateljima pokretljivosti u prostoru smatraju stope imigracije (doseljavanja) i emigracije (iseljavanja). Kretanje stanovništva odražava sliku društveno-ekonomskoga stanja na nekom području. Razlozi kretanja stanovništva najčešće su povezani s gospodarskom razvijenošću i željom za kvalitetnijim življenjem. Posljedica neravnomjernoga ulaganja u razvitak dijelova nekoga područja ili zemlje jest proces iseljavanja, odnosno emigracije koji dovodi do zapuštenosti i cjelokupnoga iseljavanja stanovništva na nekom području.

3.1.2.1. Opće (ukupno) kretanje

Nejašmić [31] definira formulu općega, odnosno ukupnoga kretanje stanovništva između međupopisnoga razdoblja:

$$D = (N - M) + (I - E), \tag{3.}$$

pri čemu je:

D – ukupno kretanje stanovništva

N – natalitet (rodnost)

M – mortalitet (smrtnost)

I – imigracija (doseljavanje)

E – emigracija (iseljavanje).

Ukupno kretanje stanovništva unutar međupopisnoga razdoblja može se jednostavnije izračunati s pomoću sljedeće formule [31]:

$$D = P_2 - P_1\ , \tag{4.}$$

pri čemu je:

D – ukupno kretanje stanovništva

P_2 – broj stanovnika u novijem međupopisnom razdoblju i

P_1 – broj stanovnika u starijem međupopisnom razdoblju.

3.1.2.2. Prirodno kretanje

Prirodno kretanje stanovništva implicira prisutnost bioloških, odnosno prirodnih činitelja i procesa u tom kretanju. Nejašmić [31] navodi osnovne sastavnice prirodnoga kretanja stanovništva: rodnost ili natalitet i smrtnost ili mortalitet. Njihova razlika dovodi do pozitivne, negativne ili stagnacijske prirodne promjene u kretanju stanovništva.

Rodnost ili natalitet najjednostavnije se iskazuje kroz opću stopu efektivne (neto) rodnosti ili nataliteta s pomoću formule:

$$n = \frac{N}{P} \times 1000\,, \tag{5.}$$

pri čemu je:

N – broj živorođene djece u jednoj godini

P – ukupno stanovništvo sredinom godine.

Negativna je sastavnica prirodnoga i ukupnoga kretanja stanovništva, koja djeluje na smanjenje ukupnoga broja stanovnika, smrtnost ili mortalitet. Označava pojavu umiranja stanovništva u određenom razdoblju. Najjednostavniji je pokazatelj opća stopa smrtnosti ili mortaliteta koja pokazuje broj umrlih na tisuću stanovnika u jedinici vremena (najčešće u jednoj godini). Izračunava se s pomoću formule:

$$m = \frac{M}{P} \times 1000, \qquad (6.)$$

pri čemu je:

M – broj umrlih tijekom jedne godine

P – ukupno stanovništvo sredinom godine.

3.1.3. Sastav stanovništva

Stanovništvo se može strukturirati prema različitim obilježjima kao što su spol, dob, zanimanje itd. Sastav je funkcija prirodnoga kretanja i prostorne pokretljivosti stanovništva, stoga ga treba promatrati u uzročno-posljedičnoj vezi i sprezi s dinamikom stanovništva. Najrelevantnija je podjela u tri skupine: biološki sastav – u kojemu je najvažniji sastav prema spolu i dobi, društveno-gospodarski sastav – u koji se svrstava sastav prema djelatnosti, aktivnosti, zanimanju, obrazovanju i dr. te kulturno-antropološki sastav – koji obuhvaća sastav prema rasi, narodnosti, jeziku, vjeri i sličnim obilježjima.

3.1.3.1. Biološki sastav

Biološki se sastav naziva još i demografskim sastavom zbog njegove važnosti za ostale sastave stanovništva. Izravno je uvjetovan prirodnim kretanjem stanovništva i sadrži sastav prema spolu i dobi. Sastav prema spolu pokazuje brojčani odnos muškoga i ženskoga stanovništva. Osnovni je pokazatelj sastava prema spolu koeficijent maskuliniteta (k_m), koji

označava broj muških na sto stanovnika ili tisuću ženskih stanovnika, ili koeficijent feminiteta (k_f), koji označava broj ženskih na sto stanovnika ili tisuću muških stanovnika [31]:

$$k_m = \frac{P_m}{P_f} \times 100 \; ; \; k_f = \frac{P_f}{P_m} \times 100, \qquad (7.)$$

pri čemu je:

P_m – ukupno muško stanovništvo

P_f – ukupno žensko stanovništvo.

Sastav prema dobi jedan je od najvažnijih pokazatelja potencijalne živosti i biodinamike stanovništva nekoga područja, a posebice je važan zbog svojih društvenih i gospodarskih implikacija [31]. Predočen po dobnim skupinama uz sastav prema spolu temelj je istraživanja stanovništva. Dob stanovništva određuje se prema navršenim godinama života. Predočava se razdiobom prema dobnim skupinama ovisno o potrebama istraživanja.

Globalna je podjela autora Lamza – Maronić i Tokić [34] prema dobnoj strukturi na:

1. predradni kontingent
2. radni kontingent
3. postradni kontingent.

Predradni kontingent obuhvaća dobni razred od 0 do 14 godina, odnosno onaj dio populacije koji će tek ući u skupinu radno sposobnoga stanovništva. Brojnost skupine predradnoga kontingenta predstavlja pokazatelj količine populacije na koju gospodarstvo može u budućnosti računati. Može se zaključiti kako nema gospodarskoga razvoja bez radnoga kontingenta, odnosno druge skupine u dobnoj strukturi. Njegova brojnost i struktura izravno utječe na razvoj gospodarstva na nekom području te na društvo u cjelini. On obuhvaća stanovništvo u dobi od 15 do 64 godine starosti. U praksi nije fiksan zbog promjena u dobnoj strukturi radno sposobnoga stanovništva ovisno o zakonodavstvu pojedinih zemalja. Posljednja je, odnosno treća dobna skupina skupina postradnoga kontingenta koji predstavlja broj ljudi koji više nisu u radnom odnosu te su najčešće umirovljeni.

3.1.3.2. Gospodarski sastav

Gospodarski sastav obuhvaća gospodarski i obrazovni sastav te neka demografska obilježja braka, obitelji i kućanstva. Pojam gospodarskoga sastava u užem smislu podrazumijeva sastav stanovništva prema aktivnosti, djelatnosti i zanimanju, a u širem smislu i položaj u zanimanju, sektor vlasništva, izvore prihoda, veličine posjeda i sl. Osnovni je pokazatelj gospodarske aktivnosti stanovništva opća stopa aktivnosti stanovništva (p_a) koja se dobiva iz formule [31]:

$$p_a = \frac{P_a}{P} \times 100, \tag{8.}$$

pri čemu je:

P_a – aktivno stanovništvo

P – ukupno stanovništvo.

Sastav je stanovništva prema djelatnostima osnovna razdioba aktivnoga stanovništva. Osim same razdiobe pokazatelj je i društveno-gospodarske razvijenosti.

Sastav prema rasi, narodnosti, jeziku, vjeri i sličnim obilježjima u literaturi [31] se naziva skupnim nazivom kulturno-antropološki sastav stanovništva. Riječ je o obilježjima stanovništva koja stvaraju razlike zbog različitih prirodno-geografskih i društvenih uvjeta.

3.2. Gospodarski kriteriji razvijenosti

Gospodarski kriteriji razvijenosti utječu na tarifnu strukturu i cijenu koja se naplaćuje za pružanje prijevozne usluge u pojedinoj tarifnoj zoni neizravno pokazujući prosječnu platežnu moć stanovništva koje prebiva na tom području.

U literaturi [35 – 37] su utvrđeni na više načina: BDP po stanovniku, dohodak po stanovniku, izvoz po stanovniku, proračunski prihodi jedinica lokalne, odnosno područne (regionalne) samouprave po stanovniku, broj aktivnih tvrtka, broj radnih mjesta, stopa nezaposlenosti, prirez i radni kontingent.

Kao dobar pokazatelj za usporedbu regionalne razvijenosti često se upotrebljava bruto domaći proizvod (BDP) po stanovniku jer je objektivan pokazatelj gospodarske snage. Bruto domaći proizvod najsveobuhvatniji je i najčešći korišteni makroekonomski pokazatelj stanja gospodarstva na svim razinama. On predstavlja ukupnu vrijednost proizvoda i usluga koji su stvoreni unutar nekoga područja u vremenu od jedne godine. BDP po stanovniku označava prosječno raspolaganje novca po stanovniku, odnosno omogućavanje kvalitete života stanovništva. Makroekonomisti BDP promatraju na tri različita, ali jednakovrijedna načina. S proizvodne je strane BDP jednak vrijednosti finalnih dobara i usluga koje su proizvedene u gospodarstvu tijekom danoga razdoblja, s proizvodne je strane BDP zbroj dodanih vrijednosti u gospodarstvu tijekom danoga razdoblja, a s dohodovne je strane BDP zbroj dodanih vrijednosti u gospodarstvu tijekom danoga razdoblja. BDP je moguće rastaviti na pet dijelova koji su sljedeći [38]:

1. osobna potrošnja
2. investicije
3. državna potrošnja
4. neto izvoz
5. investicije u zalihe.

Osobna je potrošnja [38] najveća sastavnica BDP-a (u Hrvatskoj se kreće oko 60 % BDP-a) te sadrži sva dobra i usluge koje su kupili potrošači. Investicije su zbroj stambenih i nestambenih investicija. Treća je sastavnica BDP-a državna potrošnja, odnosno kupovina dobara i usluga koju obavljaju savezne, državne ili lokalne vlasti. Neto izvoz predstavlja razliku između izvoza i uvoza. Ako je izvoz manji od uvoza, može se zaključiti da zemlja ostvaruje vanjskotrgovinski manjak. Izvoz po stanovniku predstavlja ukupnu vrijednost izvezenih proizvoda i usluga po stanovniku te je sastavni dio BDP-a po stanovniku. Posljednja su sastavnica BDP-a investicije u zalihe koje se opisuju kao razlika između proizvedenih dobara i dobara prodanih u promatranoj kalendarskoj godini, odnosno razlika između proizvodnje i prodaje.

BDP po stanovniku često se koristi kao jedan od pokazatelja makroekonomske razvijenosti zemalja, regija i županija, dok ga je kod nižih teritorijalnih jedinica teško upotrijebiti jer se ne koristi, odnosno ne izračunava na razini gradova, općina i naselja. Kao

relativno kvalitetna zamjena za BDP po stanovniku na teritorijalnoj razini gradova, općina i naselja smatra se [39] prosječni dohodak po stanovniku.

Dohodak po stanovniku [40] izračunava se kao omjer ukupnoga iznosa dohotka koji su tijekom jednoga poreznoga razdoblja (kalendarske godine) ostvarili porezni obveznici, fizičke osobe s prebivalištem ili uobičajenim boravištem na području jedinice lokalne, odnosno područne (regionalne) samouprave za koju se pravi izračun, i broja stanovnika koji žive na području te jedinice. Dohodak po stanovniku uključuje dohodak ostvaren od nesamostalnoga rada, dohodak ostvaren od samostalne djelatnosti, dohodak od imovine i imovinskih prava te dohodak od kapitala.

Proračunski prihodi jedinica lokalne, odnosno područne (regionalne) samouprave po stanovniku [40] izračunavaju se kao omjer ostvarenih prihoda jedinica lokalne, odnosno područne (regionalne) samouprave tijekom jedne kalendarske godine i broja stanovnika na području jedinice lokalne, odnosno područne (regionalne) samouprave. Izražavaju stvarnu snagu gospodarstva lokalnih proračuna zato što visine proračunskih prihoda posredno utječu na životni standard omogućavajući zadovoljavanje javnih potreba koje se iz njih financiraju. Ostvarenim prihodima jedinica lokalne, odnosno područne (regionalne) samouprave smatraju se prihodi umanjeni za prihode:

- od domaćih i stranih pomoći i donacija te sredstava fiskalnoga izravnanja
- iz posebnih ugovora: sufinanciranje građana za mjesnu samoupravu
- ostvarene na osnovi dodatnih udjela u porezu na dohodak i pomoći za izravnanja za financiranje decentraliziranih funkcija
- od prodaje nefinancijske imovine
- od prireza porezu na dohodak.

Struktura je proračunskih prihoda sastavljena od prihoda poslovanja, prihoda iz donacija te kapitalnih prihoda. Prihodi poslovanja mogu se podijeliti na neporezne i porezne prihode od kojih se porezni prihodi dijele na poreze na dohodak, prirez na dohodak, porez na imovinu te porez na robu i usluge.

Prirez je dodatni porez koji se plaća gradu ili općini, a neizravno predstavlja bogatstvo regije i brojnost stanovništva.

Broj aktivnih tvrtka, odnosno poduzeća na nekom području stvara broj radnih mjesta na kojima radno sposobno stanovništvo može raditi. Povećanje je broja aktivnih tvrtka i broja radnih mjesta preduvjet smanjenju stope nezaposlenosti.

Jadan je od najvažnijih gospodarskih kriterija razvijenosti stopa nezaposlenosti koja nam neizravno pokazuje uspješnosti gospodarstva na nekom području. Stopa nezaposlenosti predstavlja odnos broja nezaposlenih stanovnika i ukupnoga broja potvrđene radne snage:

$$Stopa\ nezaposlenosti = \frac{broj\ nezaposlenih}{radna\ snaga} \times 100 \quad (9.)$$

Nezaposlenim stanovnicima smatraju se samo oni koji traže posao i potvrđeni su kao nezaposleni. Radna su snaga svi potvrđeni zaposleni i nezaposleni stanovnici, dok se oni koji nisu zaposleni i ne traže posao smatraju osobama izvan radne snage. Nezaposlenost je ekonomski signal da gospodarstvo neke svoje resurse ne koristi učinkovito.

Radni kontingent stanovništva (radna snaga) čini stanovništvo u dobi života od 15 do 65 godina koje se, s obzirom na sposobnost rada u određenom radnom vremenu, naziva radna snaga. Radna je snaga važan kriterij za utvrđivanje ekonomski aktivnoga stanovništva koje sudjeluje u procesu rada.

3.3. Prometni kriteriji razvijenosti

Prometni kriteriji razvijenosti predstavljaju ključan parametar pri određivanju pravičnih kriterija za određivanje tarifnih zona u integriranom prijevozu putniku. Važnost je uključivanja prometnih parametara predstavljena prijevoznom uslugom kojom se na nekom području mogu koristiti stanovnici, odnosno putnici. Velike su kvantitativne i kvalitativne razlike u pogledu prometnih mogućnosti vidljive na različitim područjima. Razlike su najviše naglašene pri usporedbi urbanih područja s periurbanima i ruralnima. Problemi nepostojanja usluga u javnom prijevozu putnika javljaju se pretežno u ruralnim područjima s manjom gustoćom naseljenosti gdje je vođenje linija prijevoznicima neisplativo [27, 41, 42].

Općenita definicija [2] javnoga prijevoza putnika govori kako on podrazumijeva jednaku dostupnost svim korisnicima na tržištu te kako se ni jednoga korisnika ne može isključiti iz mogućnosti korištenja. Nažalost, prijevozna usluga nije jednako dostupna svima i

pod jednakim uvjetima čime je određenim skupinama stanovništva otežana mobilnost. Razlozi tomu pronalaze se u različitoj prijevoznoj potražnji koja definira obujam i cijenu prijevoznih usluga. Budućnost je mobilnosti određena kroz 6 najvažnijih ciljeva [43] koje je potrebno postići. To su:

1. ekološka prihvatljivost – u smislu težnje najmanjoj mogućoj razini zagađenja
2. utjecaj na zdravlje – tako da se više sudjeluje u aktivnoj mobilnosti i da se smanji broj nesreća
3. učinkovitost u korištenju resursa – u čemu pomažu inovativne tehnologije i procesi
4. kompaktnost u mobilnosti – tako da su prijeđene udaljenosti između radnoga mjesta, mjesta prebivališta i ostalih mjesta svakodnevnih aktivnosti i obveza najkraće moguće
5. robusnost ili otpornost na krizne situacije – što predstavlja poboljšanje pouzdanosti
6. pravednost – koja podrazumijeva dostupnost mobilnosti svima i pravednu prostornu raspoređenost među različitim korisnicima.

Kako bi se u budućnosti postigli navedeni ciljevi potrebno je provesti niz koordiniranih mjera i procesa.

Kako bi se postigla pravednost u mobilnosti kao jedan od ciljeva budućnosti potrebno je, ponajprije, promotriti promet s gledišta razvijenosti i utvrditi različitosti. Općenito, na nekom se području mogu identificirati sljedeći prometni kriteriji razvijenosti [44,45]: razvijenost prometne mreže, prostorna gustoća prometne mreže i demografska gustoća prometne mreže. Razvijenost prometne mreže određuje se na temelju duljine i broja prometnih pravaca na nekom području. Odnosi se na sve vrste načina odvijanja prometa. Detaljniji pregled razvijenosti prometne mreže sadržava i kategorizacije prometnih pravaca s gledišta važnosti. Prostorna gustoća prometne mreže predstavlja odnos duljine mreže i površine promatranoga područja, dok se demografska gustoća prometne mreže izračunava iz odnosa duljine prometne mreže i broja stanovnika koji prebiva u promatranom području.

Ako se prometni kriteriji razvijenosti odnose na integrirani javni prijevoz putnika [46], potrebno je detaljnije promotriti kriterije koji utječu na razvijenost, a koji su sljedeći: duljina mreže javnoga prijevoza putnika, demografska gustoća prometne mreže u javnom prijevozu putnika, prostorna gustoća, frekventnost polazaka, vrijeme putovanja, komercijalna brzina, udaljenost stajališta od lokacije življenja, kvaliteta prijevoznih sredstava, opremljenost

stajališta u javnom prijevozu putnika, kvaliteta infrastrukture, prostorna gustoća stajališta i kapacitet vozila.

Duljina mreže javnoga prijevoza putnika označava duljinu linija na kojima se pruža usluga javnoga prijevoza uzimajući u obzir sve načine prijevoza koji sudjeluju u integriranom prijevozu putnika. Demografska gustoća prometne mreže u javnom prijevozu putnika predstavlja odnos duljine mreže javnoga prijevoza putnika i broja stanovnika koji prebiva na promatranom području. Prostorna gustoća mreže javnoga prijevoza putnika predstavlja odnos duljine mreže javnoga prijevoza putnika i površine promatranoga područja. Broj polazaka vozila za pružanje usluge u javnom prijevozu po stajalištu unutar promatranoga vremena naziva se frekvencijom polazaka. Vrijeme putovanja odnosi se na vrijeme koje putnik provede u vožnji i stajanju po međustajalištima unutar promatranoga područja, dok je komercijalna brzina odnos prijeđenoga puta i vremena putovanja. Kriterij prostorne gustoće stajališta odnosi se na odnos broja stajališta u javnom prijevozu i površine promatranoga područja, dok se udaljenost stajališta od lokacije življenja opisuje kao prosječna udaljenost stanovništva koje prebiva na promatranom području od najbližega stajališta javnoga prijevoza putnika. Kvaliteta je prijevoznih sredstava i infrastrukture opisana svim kvalitativnim pokazateljima u javnom prijevozu putnika. Opremljenost stajališta u javnom prijevozu putnika ponajprije se odnosi na natkrivenost stajališta i postojanost informacija o voznom redu. Kriterij je kapaciteta vozila javnoga prijevoza putnika mjerilo broja mjesta u svakom pojedinom vozilu za pružanje prijevozne usluge.

U integriranom je prijevozu putnika potrebno detaljnije promotriti prometne kriterije razvijenosti načina prijevoza koji sudjeluju u procesu pružanja usluga javnoga prijevoza putnika. Ponajprije je potrebno naglasiti kriterije dostupnosti, odnosno postojanja i gustoće stajališta jer svi ostali kriteriji nisu značajni ako putnicima prijevozna usluga nije dostupna. Istraživanja [47] su pokazala kako sam integrirani prijevoz putnika nije važan putnicima ako se njime ne dobiva niža cijena prijevoza i kraće vrijeme putovanja. Frekventnost polazaka kao jedan od prometnih kriterija razvijenosti određuje davanje mogućnosti putnicima da za svoj način putovanja izaberu javni prijevoz putnika kao alternativu osobnom automobilskom prijevozu.

„Equality is giving everyone a shoe but

Equity is giving everyone a shoe that fits."

Naheed Dasani

4. Definiranje pravičnih kriterija pri određivanju tarifnih zona u integriranom prijevozu putnika

Donošenje odluka ponekad predstavlja složen proces biranja između više mogućnosti. Važnost donošenja odluka ovisi o situacijama u kojima je potrebno donijeti neku odluku. Za donositelja odluke to predstavlja proces odlučivanja koji se sastoji od prepoznavanja i biranja mogućih rješenja koja vode do nekoga željenoga stanja. Složenost nekoga sustava podrazumijeva da se sustav sastoji od puno dijelova koji na puno načina međusobno utječu na vjerojatnost ishoda i događaja. Ako su dijelovi sustava povezani u funkcionalne cjeline, može se zaključiti da sustav funkcionira.

U ovom se poglavlju opisuje metodologija sustavne dinamike koja se koristi za bolje razumijevanje funkcioniranja sustava i dijagram uzročnih petlji koji predstavlja metodu prikaza modela sustavne dinamike i omogućava vizualizaciju uzročno-posljedičnih veza unutar sustava. S pomoću dijagrama uzročnih petlji odredit će se pravični kriteriji za određivanje tarifnih zona u integriranom prijevozu putnika.

4.1. Modeliranje sustavne dinamike

Sustav je moguće definirati na više načina. Jedna je od najjednostavnijih definicija da je sustav skup elemenata u interakciji (engl. *A System is a set of elements in interaction.* [48]). On predstavlja skup organiziranih elemenata zbog zajedničke svrhe. Njihovo uzajamno djelovanje ponekad predstavlja složenu, turbulentnu i dinamičnu cjelinu. Zbog složenosti današnjih sustava preporučuje se način sustavnoga razmišljanja i modeliranja dinamičkih sustava.

Za pojednostavljenje prikaza realnoga sustava koriste se modeli i simulacije. Služe za bolje razumijevanje realnih sustava i proučavanje sustava pri eksperimentiranju s njima. Modeliranje predstavlja stvaranje ili oblikovanje modela. Božikov [49] navodi kako nema strogih pravila za izradu dobroga modela, već veliku važnost imaju: razumijevanje problema, sposobnost apstrakcije, sustavnost, sposobnost razlučivanja bitnoga od nebitnoga i iskustvo. Simulacijsko je modeliranje proučavanje realnih sustava s kojima se ne može ili ne smije eksperimentirati u stvarnosti. Proces simulacijskoga modeliranja (Slika 3.) započinje promatranjem i proučavanjem realnoga sustava, stvaranjem njegove apstraktne slike. Razvija se simulacijski model na kojem je moguće provođenje simulacijskih eksperimenata čije je rezultate moguće interpretirati i primijeniti na realan sustav koji je predmet proučavanja. Završna je etapa procesa simulacijskoga modeliranja utvrđivanje značenja za realni sustav.

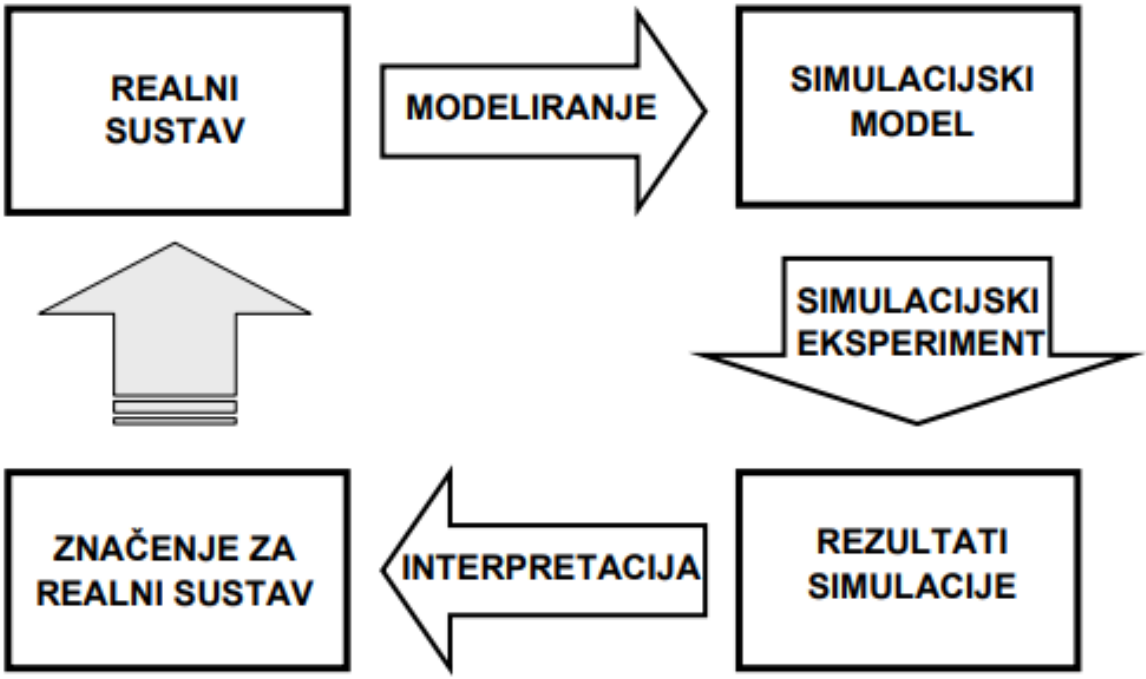

Slika 3. Proces simulacijskoga modeliranja [49]

Sustavna je dinamika metoda s pomoću koje se poboljšava razumijevanje složenih sustava. Interdisciplinarna je metoda jer obuhvaća znanja mnogih polja počevši od matematičkih i informatičkih znanja pa do psihologije i organizacijskih metoda, stoga je ključna u analiziranju društvenih sustava i kretanja unutar njih.

Osnovnu je ideju [50] sustavne dinamike (engl. *system dynamics*), izvorno nazvanu industrijska dinamika (engl. *industrial dynamics*), začeo *Jay Forrester* u svom radu na MIT-u (*Massachusetts Institute of Technology*). On je razvio teoriju informacijske povratne veze i kontrole kao način vrednovanja poduzeća i ostalih organizacijskih i društvenih sustava. To je uključivalo i razvoj metodologije analitičkoga modeliranja, što je bio ključan doprinos poslovnoj analizi. Modeliranjem sustavne dinamike istražuju se obilježja složenih dinamičkih sustava s povratnom vezom. Sustav s povratnom vezom zatvoreni je krug uzroka i posljedica pri čemu uzrok izaziva posljedice kojima neposredno utječe na samoga sebe.

Sterman [51] navodi 12 načela za uspješno modeliranje sustavne dinamike. To su:

1. *Razvoj modela za rješavanje specifičnoga problema, a ne za modeliranje sustava.*

   Model mora imati vidljivu svrhu rješavanja specifičnoga problema. Pri modeliranju se moraju izbaciti svi čimbenici koji nisu relevantni u rješavanju posebnoga problema kako bi se osigurala točnost i brzina rješavanja problema, odnosno kako bi model ostvario svoj cilj.

2. *Modeliranje treba biti uključeno u projekt od samoga početka.*

   Korist procesa modeliranja započinje u najranijoj etapi, odnosno onda kada je potrebno definirati problem. Proces modeliranja pomaže u prepoznavanju strukture sustava i prije nego dođe do problema u funkcioniranju sustava.

3. *Potrebna je skeptičnost u razmišljanju o smislu modeliranja i načinu razmišljanja – Zašto nam je to potrebno?*

   Stručnjaci u modeliranju trebaju razmišljati o posebnosti sustava koji modeliraju i o načinu na koji bi modeliranje moglo biti korisno u neku posebnu svrhu.

4. *Modeliranje sustavne dinamike nikad ne ide samostalno. Koristi se uz ostale odgovarajuće alate i metode.*

   Većina je projektnih modela dio većega projekta u koji je uložen trud koji uključuje strategijsku i operativnu analizu, *benchmarking*, statistička istraživanja, tržišna istraživanja i sl. Modeliranje najbolje služi svrsi kada je u kombinaciji s nekom drugom metodom ili alatom.

5. *Od samoga je početka projekta fokus na implementaciji.*

   Implementacija mora započeti s prvim danom trajanja projekta. Model se treba iskoristiti za postavljanje prioriteta i rješavanje posebnih problema u modelu.

6. *Modeliranje najbolje funkcionira kao iterativni proces zajedničkoga preispitivanja dionika.*

   Modeliranje se smatra procesom otkrivanja. Cilj je razumijevanje nastajanja problema i pronalazak načina za rješavanje nastalih problema. Ponavljanje testiranja modela i zajedničkoga preispitivanja dionika koji sudjeluju u modeliranju najbolji je način ispravnoga funkcioniranja modela.

7. *Treba izbjegavati Black box modeliranje.*

   Model koji se izrađuje bez preispitivanja mišljenja onih zbog kojih se model izrađuje i bez njihovih sugestija nikad ne može postići isti učinak i funkcionalnost kao modeli kod kojih su svi uključeni u proces izgradnje modela pa makar i samo s prijedlozima i mišljenjima o modelu.

8. *Validacija je stalni proces testiranja i izgradnje sigurnosti u model.*

   Validirani se model ne smatra gotovim nakon njegove izrade i nakon jedne validacije. Sigurnost u funkcionalnost izgrađenoga modela potrebno je stalno ispitivati s različitim podatcima i različitim mišljenjima stručnjaka.

9. *Brza izrada preliminarnoga modela za rad. Detalji se dodaju samo ako su nužni.*

   Važna je izrada simulacijskoga radnoga modela u što kraćem vremenu. Detalji su modela potrebni samo ako imaju posebnu važnost za naručitelja izrade modela. Brzi rezultati donose značajnu prednost korisnicima zbog donošenja odluka u kraćem vremenskom razdoblju.

10. *Granica je velikoga modela važnija od velikoga broja detalja.*

    U modelima se mora pronaći ravnoteža između korisnosti prikaza i cjelokupnoga prikaza operativne strukture. Potrebno je ograničiti se na važne povratne veze u strukturama sustava, a detalje izbaciti radi jednostavnijega shvaćanja funkcioniranja modela.

11. *Koristi stručnjake u modeliranju, ne novake.*

    Modeliranje zahtijeva discipliniran pristup i cjelokupno razumijevanje problematike modela koji se razvija te iskustvo. Zbog toga se razvijanje modela ne preporučuje studentima jer nemaju dovoljno iskustva koje je potrebno kako bi model uspješno funkcionirao.

12. *Nadogradnja nije gotova s jednim projektom.*

    Modele je potrebno stalno nadograđivati zbog posebnih dinamičnosti sustava u kojima dolazi do stalnih promjena.

Turina [50] navodi da se sustavna dinamika može upotrijebiti na više načina:

1. Sustavna dinamika nudi nekoliko grafičkih načina za predstavljanje strukture od kojih su svi dijelovi usredotočeni na procese integracije, što uzrokuje dinamično ponašanje sustava, te na uzročne odnose koji određuju način na koji se takvi sustavi ponašaju.
2. Sustavna dinamika nudi različite načine vizualizacije razvoja sustava.
3. Sustavna dinamika nudi analizu ponašanja sustava uz dopuštena povezivanja unutar strukture sustava, što omogućuje utvrđivanje temeljnih strukturalnih uzroka takvoga ponašanja.

Modeliranje je sustavne dinamike moguće i uz brojne računalne alate kao što su *Vensim, Stella, iThink* i *Powersim*, a primjenjuje se gdje god se problemi mogu izraziti kao varijabilno ponašanje kroz vrijeme.

Najvažnijim se konceptualnim modelima u diskretnoj simulaciji smatraju dijagram ciklusa aktivnosti i Petrijeve mreže, dok se dijagrami uzročnih petlji i dijagrami toka smatraju konceptualnim prikazima modela sustavne dinamike.

4.2. Dijagram uzročnih petlji (CLD)

Dijagram uzročnih petlji (engl. *Causal Loop Diagram – CLD*) važan je prikaz modela sustavne dinamike za vizualiziranje povratnih veza varijabla u sustavu. Omogućava vizualizaciju uzročno-posljedičnih veza varijabla unutar sustava. Uvelike se koristi u znanstveno-istraživačkom radu, a značajno mu raste primjena u svijetu poslovnoga okruženja zbog svojih značajka kao što su mogućnost brzoga pronalaska hipoteza o uzrocima dinamičnosti, mogućnost prikupljanja mentalnih modela pojedinca ili timova te mogućnost komunikacije s važnim povratnim vezama za koje se smatra da su odgovorne za problem koji nastojimo riješiti. Povratna je veza jedan od najvažnijih pojmova u sustavnoj dinamici jer određuje dinamiku sustava.

Osnovne namjene dijagrama uzročne petlje [50] kao instrumenta modeliranja sustavne dinamike jesu:

1. vizualiziranje važnih povratnih veza za koje se smatra da su odgovorne za analizirani problem
2. brzo i učinkovito prikazivanje hipoteza o uzrocima dinamičnosti sustava
3. utvrđivanje mentalnih modela pojedinaca ili grupe.

Konstruiranje CLD-a zahtijeva opreznost zbog složenosti samih sustava. Sastoji se [51] od varijabla spojenih strelicama koje označavaju smjer veze, odnosno uzročne utjecaje između varijabla. Svaka je uzročna veza (Tablica 1.) označena polaritetom „+“ ili „–“, što označava promjenu zavisne varijable kada se nezavisna varijabla promijeni. Pozitivna je veza ona kod koje povećanje uzroka dovodi do povećanja posljedice (ili smanjenje uzroka dovodi do smanjenja posljedice), a negativna je veza ona kod koje povećanjem uzroka dolazi do smanjenja posljedice (odnosno smanjenje uzroka dovodi do povećanja posljedice). Dvije ili više ulančanih veza u smjeru uzrok – posljedica čine važnu istaknutu petlju koja pokazuje kada je petlja povratno pozitivna (+), odnosno potencirajuća ili kada je petlja povratno negativna (–), odnosno balansirajuća. Važna se petlja označava identifikatorom petlje prikazanim u Tablici 1. Pozitivna

je povratna petlja (potencirajuća) ona kod koje varijable u petlji djeluju povratno na same sebe u istom smjeru, što dovodi do stalnoga porasta ili stalnoga pada vrijednosti tih varijabla, dok kod negativne povratne (balansirajuće) petlje elementi petlje uzrokuju promjenu smjera, što dovodi do težnje sustava ravnotežnom stanju. Pozitivnost ili negativnost povratne petlje ovisi o uzročno-posljedičnim vezama unutar petlje. Prema pravilu, ako su sve uzročno-posljedične veze unutar petlje pozitivne, onda je i povratna petlja pozitivna, a ako se unutar povratne petlje nalazi i neka ili nekoliko negativnih uzročno-posljedičnih veza, onda se promatra je li njihov broj paran ili neparan. Paran broj ukupnih negativnih uzročno-posljedičnih veza govori da je povratna petlja pozitivna, dok neparan broj negativnih uzročno-posljedičnih veza znači da je povratna petlja negativna.

Tablica 1. Simboli, značenje, primjeri i grafikoni u dijagramima uzročnih petlji (CLD) [51]

Simbol	Značenje	Primjer
	Povećanje varijable X dovodi do povećanja varijable Y.	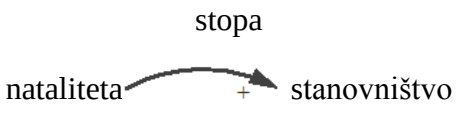
	Povećanje varijable X dovodi do smanjenja varijable Y.	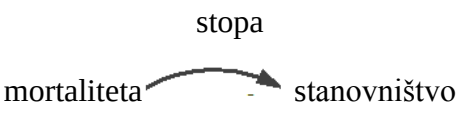
	Identifikator petlje: pozitivna (potencirajuća) petlja	
	Identifikator petlje: negativna (balansirajuća) petlja	

Pri izradi dijagrama uzročnih petlji potrebno se voditi sljedećim uputama [51]:

1. Potrebno je razmišljati o elementima u dijagramu uzročnih petlji kao o varijablama koje mogu ići gore ili dolje bez obzira na to što nekad nije moguće kvantificirati pojedine varijable:
    - Korištenje imenica za predstavljanje elemenata češće od glagola.
    - Sigurnost u definiciju elementa daje jasnu sliku u kojem smjeru ide povećanje ili smanjenje za svaku pojedinu varijablu.

- Općenito se smatra boljim i preporučuje se korištenje imena varijabla koje imaju pozitivno značenje.
- Uzročne veze označavaju smjer promjene, a ne vremenski slijed događaja. Pozitivna veza između A i B ne znači da se varijabla A prva pojavljuje, već označava što će se dogoditi s varijablom B ako se varijabla A poveća ili smanji.

2. Pri sastavljanju veza u dijagramu potrebno je uzeti u obzir da se mogu pojaviti vanjski utjecaji koji mogu utjecati na veze između varijabla. Ako se identificiraju, potrebno je odlučiti koje su veze važne za prikazivanje kao vanjski elementi.
3. Povratne petlje imaju svoj cilj bez obzira jesu li pozitivne ili negativne. Razlika je samo u načinu ponašanje varijabla u sustavu u kojem se varijable kod pozitivne povratne petlje ponašaju rastuće, a kod negativne povratne petlje balansirajuće.
4. Razlika između stvarnoga i shvaćenoga ponašanja sustava često može biti važna u objašnjavanju načina ponašanja varijabla u sustavu.
5. Često se javljaju različitosti u kratkoročnim i dugoročnim posljedicama koje uzrokuju pojedine varijable, stoga ih je potrebno prikazivati odvojenim petljama.
6. Ako veza između dviju varijabla treba više dodatnih objašnjenja, vjerojatno je potrebno dodati neke varijable između njih kako bi se bolje odredili specifični elementi koji uzrokuju neko događanje.
7. U skladu s prethodnim uputama potrebno je izgraditi dijagram uzročnih veza što je jednostavnije moguće. Svrha dijagrama nije opisivanje detalja nekoga procesa, nego prikazivanje uzročnih struktura koje vode do nekoga promatranoga načina ponašanja.

Dijagrami uzročnih petlji [50] odličan su alat za prikaz središnje strukture sustava te pronalazak temeljnih uzročnih veza u strukturi sustava. Ne predlaže se širenje dijagrama uzročnih petlji na previše detalja jer to otežava shvaćanje cjelokupne strukture povratnih veza dijagrama i načina na koji pojedine varijable komuniciraju. S druge strane, premalo detalja otežava spoznavanje logike te procjenu uvjerljivosti i stvarnosti predočenoga modela. Predlaže se gradnja modela u etapama, s nizom manjih dijagrama uzročnih petlji gdje svaki dijagram treba odgovarati jednom dijelu dinamičke priče koja se prikazuje. Poželjno je izraditi poseban dijagram za svaku važnu petlju jer samo tako mogu biti dovoljno razrađeni da prikažu kako sve varijable međusobno komuniciraju. Konačan dijagram uzročnih petlji dobiva se sastavljanjem komada dijagrama uzročnih petlji nekih dinamičkih priča koje pokazuje.

4.3. Sustavna dinamika demografske razvijenosti

Struktura povratnih veza u sustavu demografskih kriterija razvijenosti može se učinkovito prikazati modeliranjem sustavne dinamike. Kako bi se došlo do cjelokupnoga konceptualnoga prikaza modela sustavne dinamike, potrebno je graditi model u etapama i s manjim dijagramima uzročnih petlji od kojih će svaki predstavljati dio dinamičke priče modela.

Model je sustavne dinamike demografskih kriterija razvijenosti potrebno izgraditi kroz tri manja dijagrama uzročnih petlji koje se u posljednjoj etapi mogu povezati u jedan konačan model.

Prvi je dijagram uzročnih petlji vezan uz razmještaj stanovništva (Slika 4.). Varijabla *razmještaj stanovništva* izravno utječe na demografsku razvijenost područja. Varijabla kojom je moguće kvantificirati razmještaj stanovništva jest *gustoća stanovništva,* koja prikazuje broj stanovništva na jedinici površine. Drugim riječima, s varijablom *gustoća stanovništva* komuniciraju varijable *broj stanovnika* i *površina područja*. Između navedenih je varijabla moguće uspostaviti uzročne veze sa smjerom promjene prema varijabli *gustoća stanovništva*. Između varijabla *broj stanovnika* i *gustoća stanovništva* postoji pozitivna veza jer se povećanjem prve varijable povećava druga varijabla. Varijable *površina područja* i *gustoća stanovništva* vezane su negativnom vezom jer povećanje prve varijable uzrokuje smanjenje druge varijable. Na varijablu *broj stanovnika* utječu varijable *natalitet, mortalitet, imigracija* i *emigracija* između kojih se pojavljuju i povratne petlje. *Varijable natalitet* i *broj stanovnika* te varijable *imigracija* i *broj stanovnika* komuniciraju kroz pozitivnu, odnosno potencirajuću petlju jer su sve uzročno-posljedične veze unutar petlje pozitivne. U komunikaciji između varijabla *mortalitet* i *broj stanovnika* te *emigracija* i *broj stanovnika* javlja se negativna, odnosno balansirajuća petlja jer je neparan broj negativnih uzročno-posljedičnih veza.

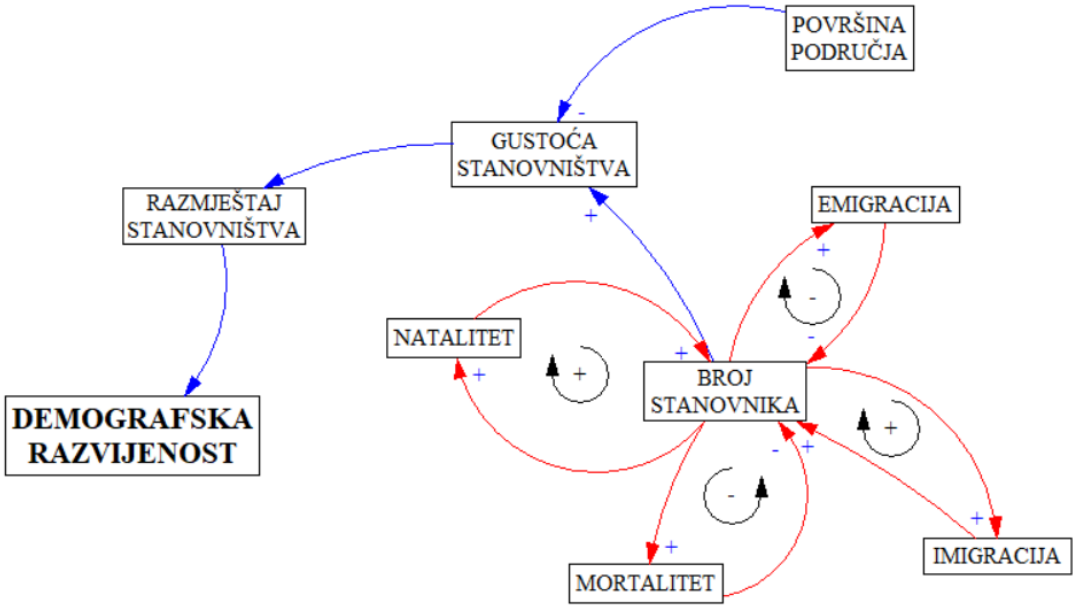

Slika 4. Dijagram uzročnih petlji razmještaja stanovništva

Kretanje stanovništva predstavlja drugi dijagram uzročnih petlji (Slika 5.). Na demografsku razvijenost područja izravno utječe varijabla *kretanje stanovništva* koja je u uzročnoj vezi s varijablom *opće kretanje stanovništva.* Varijablom o*pće kretanje stanovništva* moguće je kvantificirati kretanje stanovništva. Ona prikazuje kretanje stanovništva unutar međupopisnoga razdoblja. S varijablom *opće kretanje stanovništva* komuniciraju varijable *natalitet*, *mortalitet*, *imigracija* i *emigracija*. Između navedenih varijabla uspostavljaju se uzročne veze sa smjerom promjene prema varijabli *opće kretanje stanovništva.* U komunikaciji između varijabla *opće kretanje stanovništva* i *natalitet* te *opće kretanje stanovništva* i *imigracija* uspostavlja se pozitivna veza jer se povećanjem prve varijable povećava druga varijabla, dok se kod komunikacije između varijabla *opće kretanje stanovništva* i *mortalitet* te *opće kretanje stanovništva* i *emigracija* javlja negativna veza jer povećanje prve varijable uzrokuje smanjenje druge varijable.

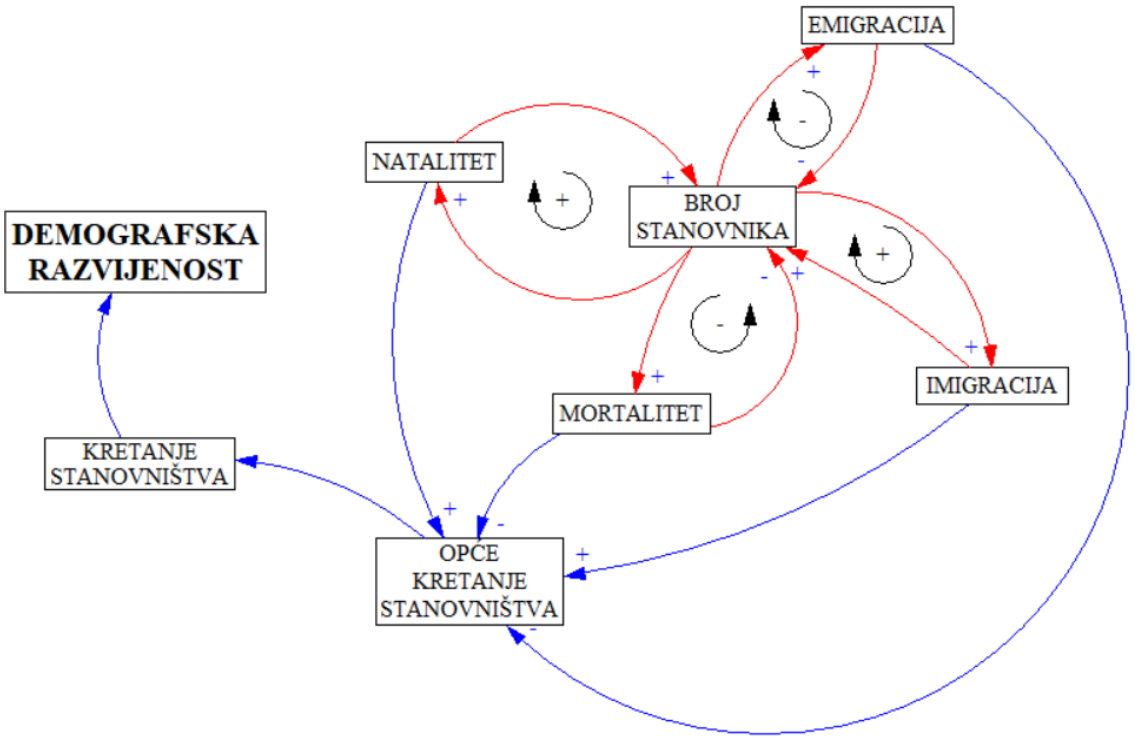

Slika 5. Dijagram uzročnih petlji kretanja stanovništva

Uočava se djelomična pojava istih varijabla kod prvoga i drugoga dijagrama uzročnih petlji, što će u posljednjoj etapi, odnosno konačnom modelu pridonijeti spajanju istih te povezivanju dvaju dijagrama uzročnim vezama.

Treći se dijagram uzročnih petlji odnosi na sastav stanovništva (Slika 6.). Varijabla *sastav stanovništva* izravno utječe na demografsku razvijenost područja, a čine ju varijable *društveno-gospodarski sastav*, *kulturno-antropološki sastav* i *biološki sastav*. S varijablom *društveno-gospodarski sastav* povezane su varijable *djelatnost*, *aktivnost*, *zanimanje* i *obrazovanje*. Varijablu *kulturno-antropološki sastav* čine varijable *rasa*, *narodnost*, *jezik i vjera*, dok varijabla *biološki sastav* sadrži varijable *spol* i *dob*. U skladu s uputama za izradu dijagrama uzročnih petlji potrebno je izgraditi dijagram uzročnih veza što je jednostavnije moguće, stoga se detaljnije proučila još varijabla *dob* jer dobna struktura uvelike uvjetuje politiku tarifiranja u javnom prijevozu putnika. Varijablu *dob* čine varijabla *predradni kontingent*, koji predstavlja brojnost stanovništva u dobi od 0 do 14 godina na nekom području, varijabla *radni kontingent*, odnosno broj stanovnika u dobi od 15 do 64 godine te varijabla *postradni kontingent*, koji predstavlja broj stanovnika u dobi od 65 godina naviše. Između navedenih varijabla postoji veza jer su varijable međusobno opisno povezane, no kod pokušaja

kvantificiranja uzročno-posljedične reakcije nije ih moguće obostrano uzročno povezati. Zbog toga nije moguće odrediti koje su uzročno-posljedične veze u trećem dijagramu pozitivne, a koje negativne.

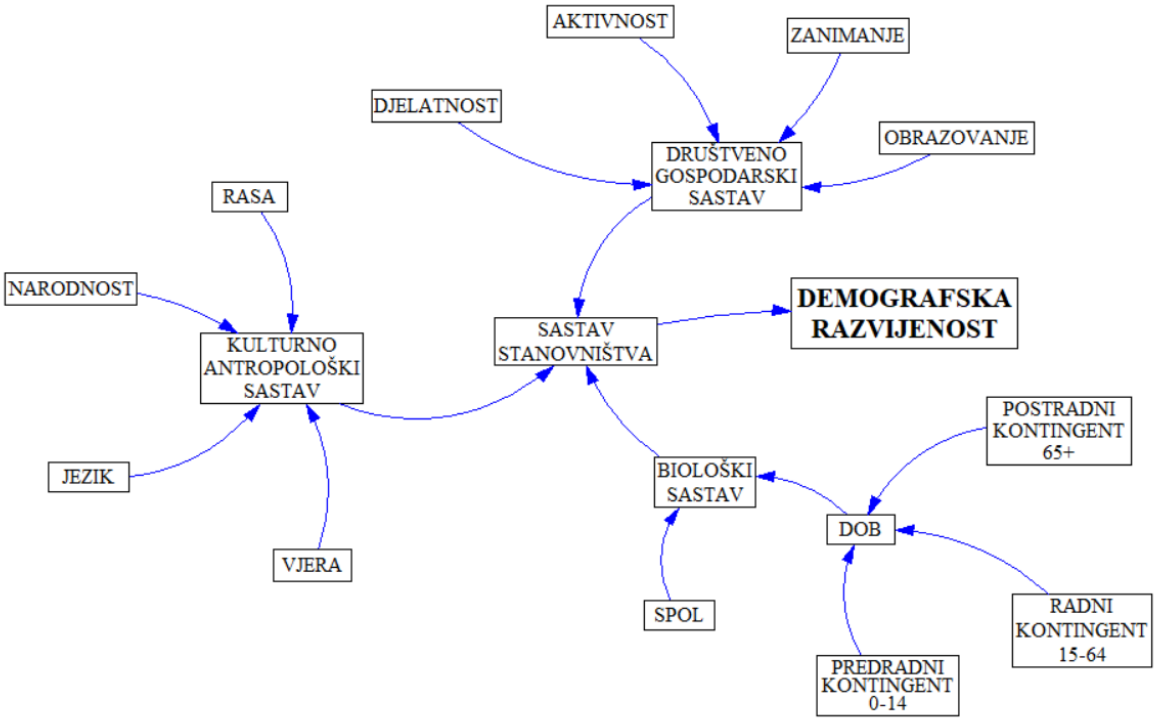

Slika 6. Dijagram uzročnih petlji sastava stanovništva

Nakon što su izrađeni svi dijelovi dijagrama uzročnih petlji može se pristupiti spajanju u konačan model (Slika 7.).

Konceptualni je prikaz modela sustavne dinamike napravljen s pomoću dijagrama uzročnih petlji u računalnom alatu *Vensim*.

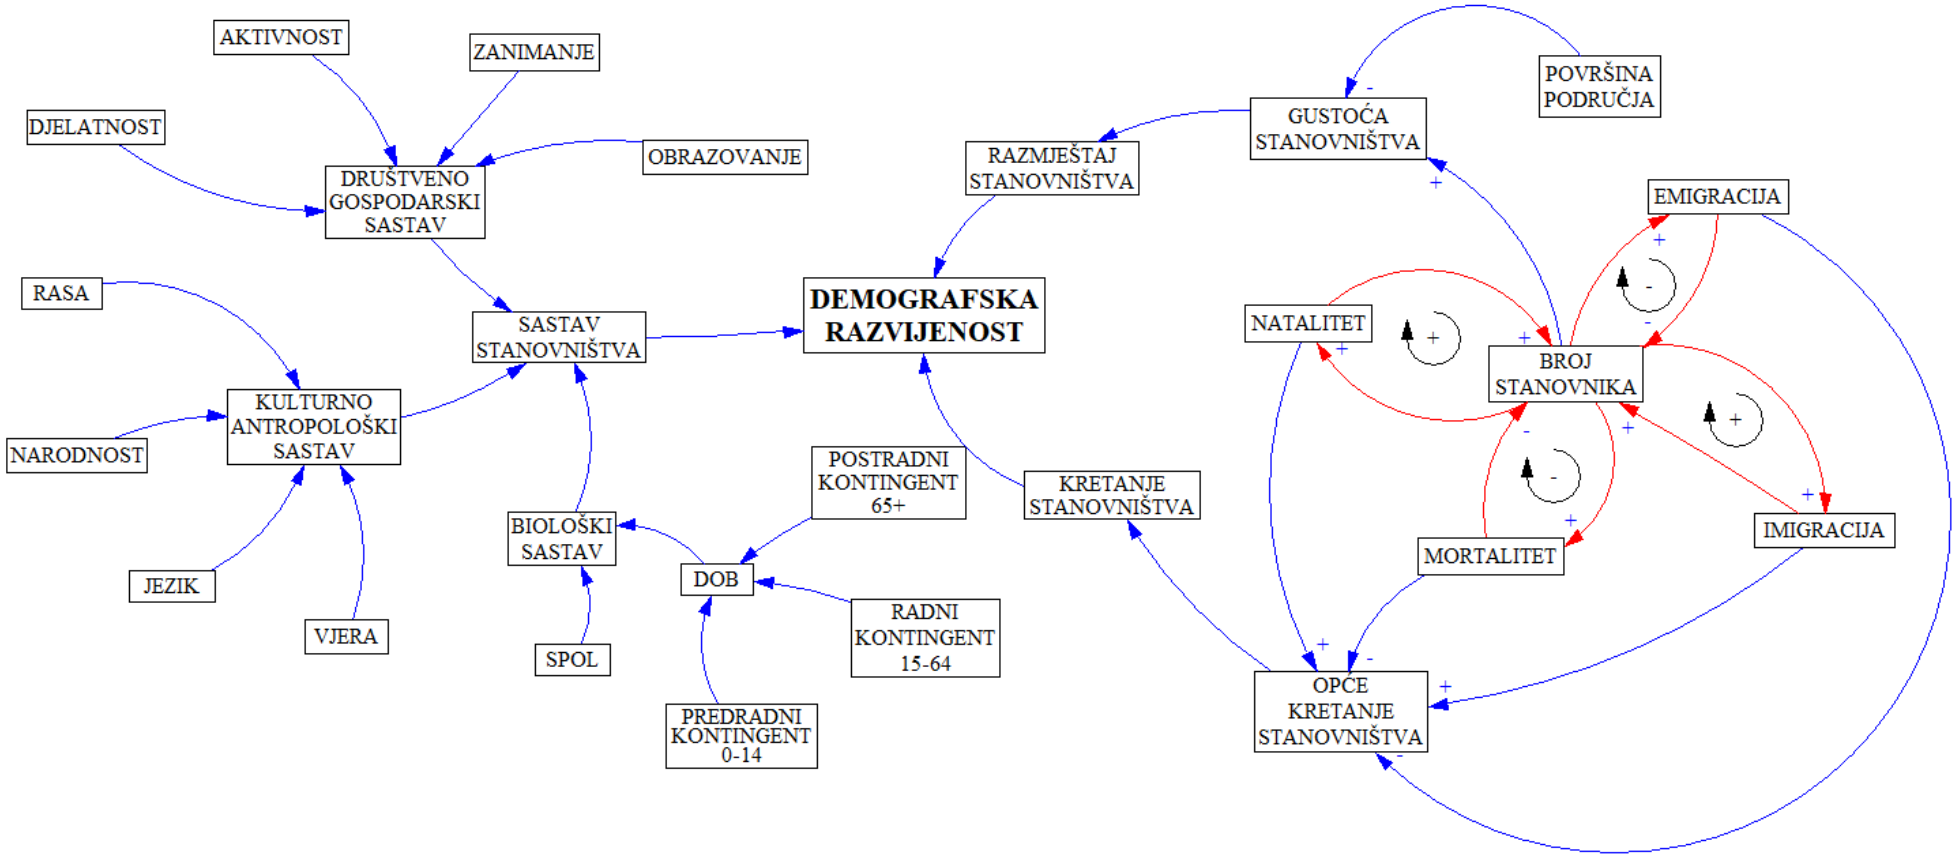

Slika 7. Dijagram uzročnih petlji demografskih kriterija razvijenosti

4.4. Sustavna dinamika gospodarske razvijenosti

Gospodarska razvijenost područja izravno pokazuje platežnu moć stanovništva koje prebiva na tom području. Može se prikazati kroz tri skupine pokazatelja koji su vezani uz dohodovnu stranu stanovništva, proračunsku stranu jedinica lokalne, odnosno područne (regionalne) samouprave i zapošljivost stanovnika. Potrebno je izgraditi konačan model sustavne dinamike gospodarskih kriterija razvijenosti postupno, kroz tri manja dijagrama uzročnih petlji.

Dohodovni pokazatelj razvijenosti stanovništva predstavlja prvi dijagram uzročnih petlji (Slika 8.), stoga je varijabla *dohodak po stanovniku* u izravnoj vezi s gospodarskom razvijenosti područja. S varijablom *dohodak po stanovniku* komuniciraju varijable *dohodak* i *broj stanovnika*, stoga je moguće uspostaviti uzročne veze sa smjerom prema varijabli *dohodak po stanovniku*. Između varijabli *dohodak* i *dohodak po stanovniku* postoji pozitivna veza jer se povećanjem prve varijable povećava druga varijabla, dok između varijable *broj stanovnika* i *dohodak* postoji negativna veza jer povećanje prve varijable uzrokuje smanjenje druge varijable. S varijablom *dohodak* pozitivnim vezama komuniciraju varijable *dohodak od kapitala*, *dohodak od nesamostalnoga rada*, *dohodak od samostalne djelatnosti* i *dohodak od imovine i imovinskih prava*.

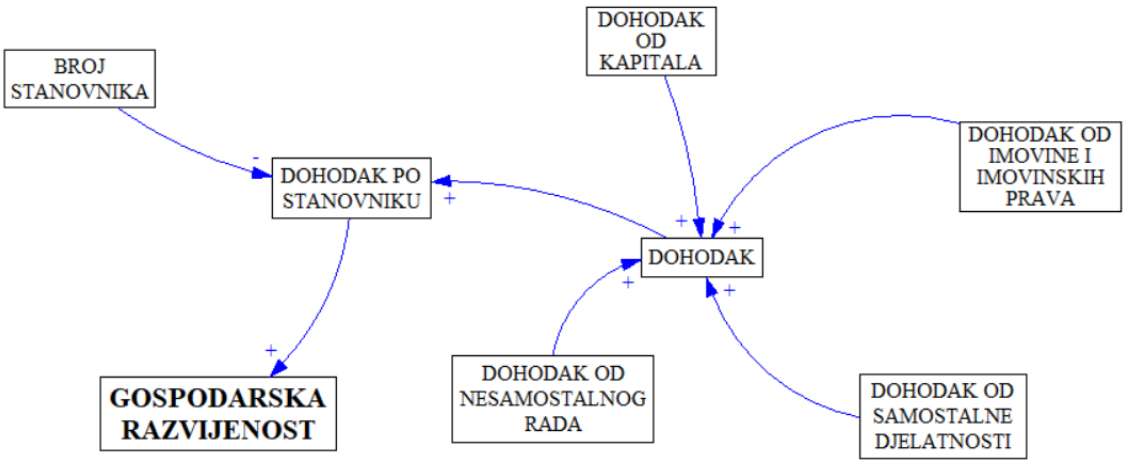

Slika 8. Dijagram uzročnih petlji dohodovne razvijenosti

Drugi dijagram uzročnih petlji (Slika 9.) odnosi se na pokazatelja proračunskih prihoda jedinice lokalne, odnosno područne (regionalne) samouprave. Varijabla *proračunski prihodi po stanovniku* izravno utječe na gospodarsku razvijenost područja koja je u uzročnoj vezi s

varijablama *proračunski prihodi* i *broj stanovnika*. Između varijabla *proračunski prihodi* i *proračunski prihodi po stanovniku* postoji pozitivna veza jer se povećanjem prve varijable povećava druga varijabla, dok između varijabla *broj stanovnika* i *proračunski prihodi po stanovniku* postoji negativna veza jer povećanje prve varijable uzrokuje smanjenje druge varijable. Na varijablu *proračunski prihodi* pozitivnim vezama utječu varijable *kapitalni prihodi, prihodi poslovanja* i *prihodi od donacija.* Isto tako pozitivnim vezama varijable *porezni prihodi* i *neporezni prihodi* komuniciraju s varijablom *prihodi poslovanja*. Varijabla *porezni prihodi* u komunikaciji je pozitivnim vezama vezana s varijablama *porez na dohodak, prirez na dohodak, porez na imovinu* i *porez na robu i usluge*.

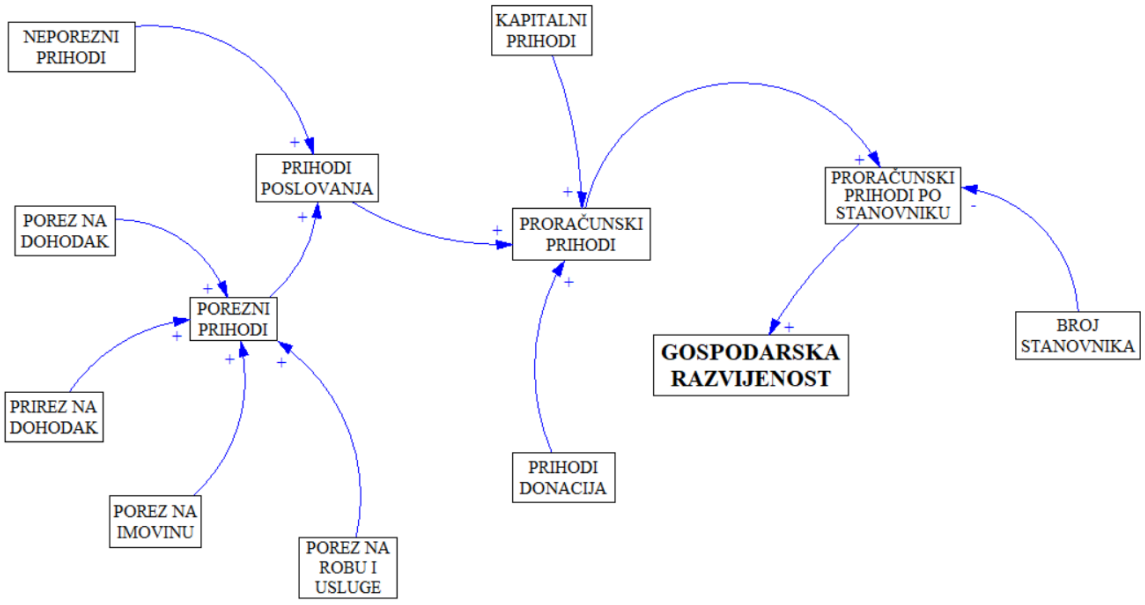

Slika 9. Dijagram uzročnih petlji razvijenosti proračunskih prihoda jedinice lokalne, odnosno područne (regionalne) samouprave

Pokazatelj zapošljivosti stanovništva predstavlja treći dijagram uzročnih petlji (Slika 10.). Predvodi ga varijabla *stopa nezaposlenosti* koja izravno utječe na gospodarsku razvijenost područja. Ona prikazuje broj nezaposlenoga stanovništva u odnosu na broj radne snage na nekom području.

Drugim riječima, s varijablom *stopa nezaposlenosti* komuniciraju varijable *broj nezaposlenih* i *radna snaga*. Između navedenih je varijabla moguće uspostaviti uzročne veze sa smjerom promjene prema varijabli *stopa nezaposlenosti*. Između varijabla *broj nezaposlenih* i *stopa nezaposlenosti* postoji pozitivna veza jer se povećanjem prve varijable povećava druga varijabla. Varijable *radna snaga* i *stopa nezaposlenosti* vezane su negativnom vezom jer se

povećanjem prve varijable uzrokuje smanjenje druge varijable. Na varijablu *radna snaga* pozitivno utječu varijable *broj stanovnika*, *broj zaposlenih* i *broj nezaposlenih* jer je pokazatelj radne snage predstavljen svim potvrđenim zaposlenim i nezaposlenim stanovnicima. Između varijabla *broj zaposlenih* i *broj nezaposlenih* javlja se pozitivna, odnosno potencirajuća petlja jer je paran broj negativnih uzročno-posljedičnih veza.

Uočava se djelomična pojava istih varijabla kod prvoga, drugoga i trećeg dijagrama uzročnih petlji, što će u konačnom modelu pridonijeti spajanju istih te povezivanju triju dijagrama uzročnim vezama.

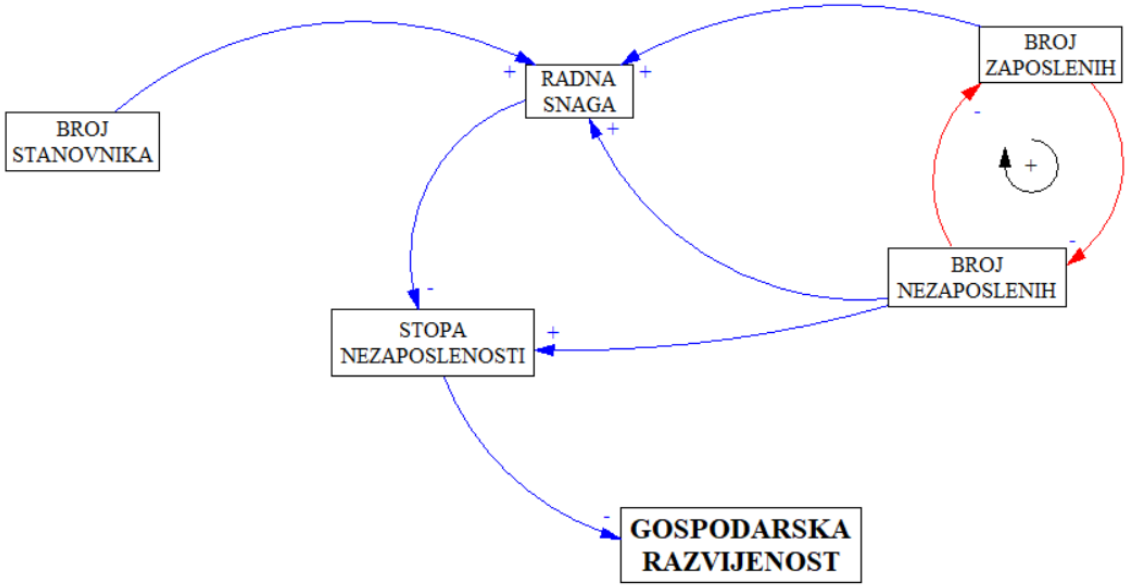

Slika 10. Dijagram uzročnih petlji razvijenosti prema zapošljivosti

Nakon što su izrađeni svi dijelovi dijagrama uzročnih petlji, može se pristupiti spajanju u konačan model (Slika 11.) uz upotrebu računalnoga alata *Vensim*.

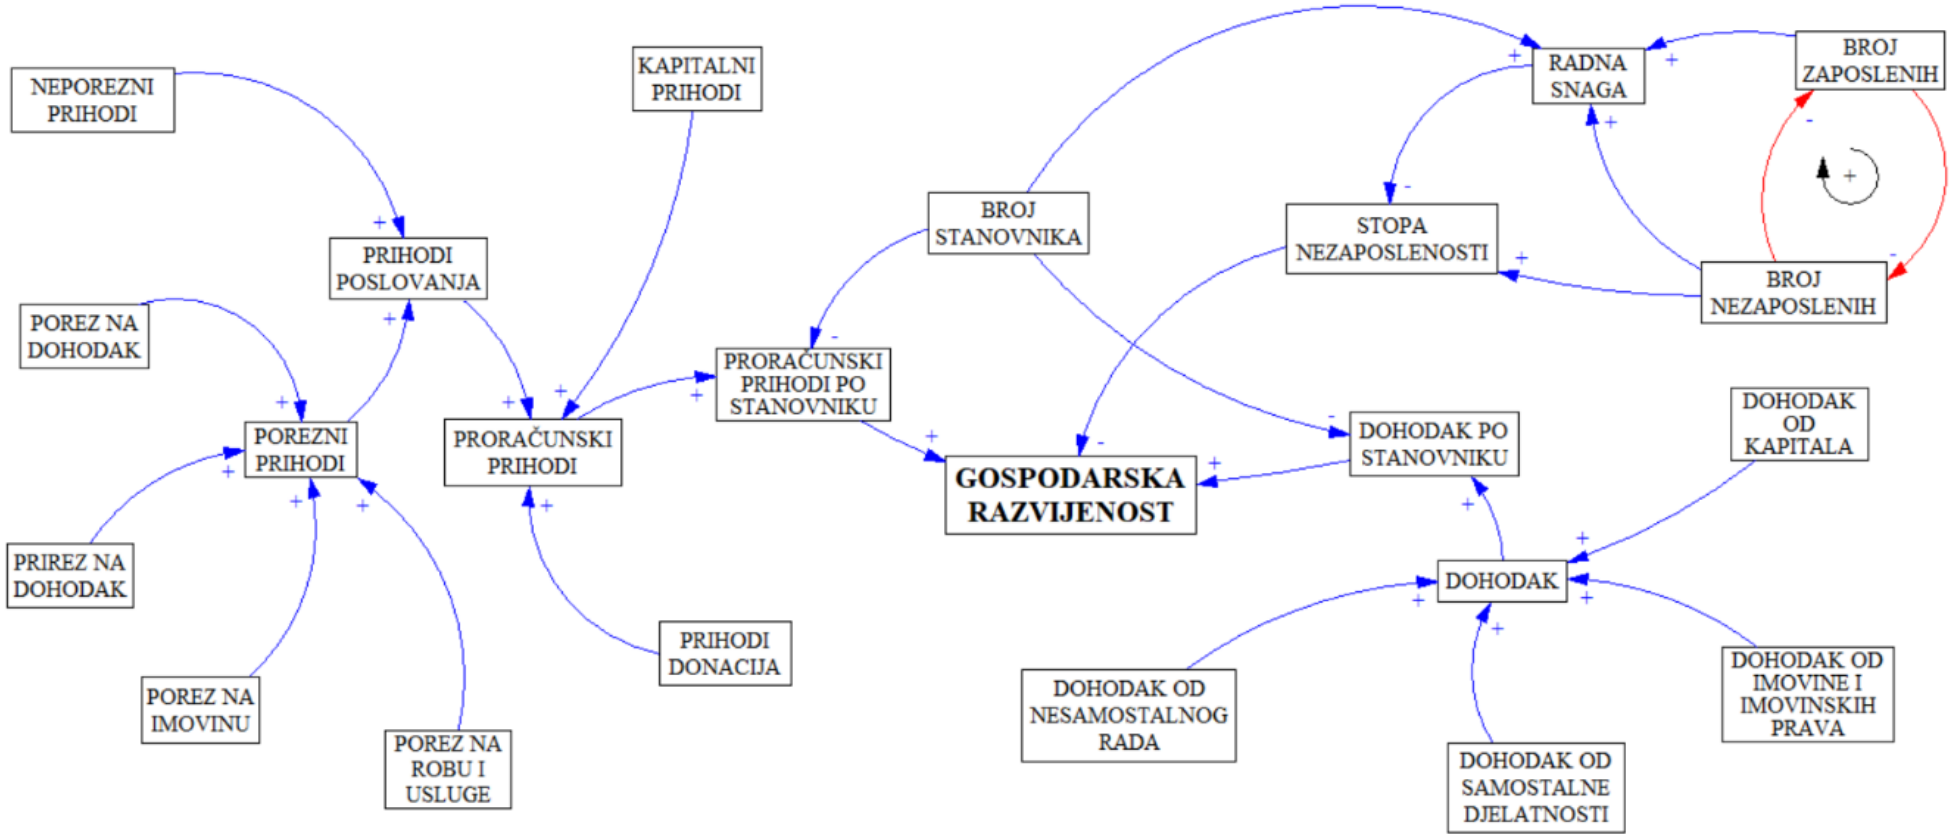

Slika 11. Dijagram uzročnih petlji gospodarskih kriterija razvijenosti

4.5. Sustavna dinamika razvijenosti javnoga prijevoza putnika

Struktura povratnih veza u sustavu kriterija razvijenosti javnoga prijevoza putnika može se učinkovito prikazati modeliranjem sustavne dinamike gradnjom modela kroz pet etapa koje se u posljednjoj etapi mogu povezati u jedan konačan model.

Prvi je dijagram uzročnih petlji (Slika 12.) vezan uz gustoću mreže javnoga prijevoza putnika (JPP-a). Varijabla *gustoća mreže javnoga prijevoza putnika* izravno utječe na razvijenost javnoga prijevoza putnika nekoga područja. Ona predstavlja odnos duljine mreže javnoga prijevoza putnika i površine područja. Samim time s njom komuniciraju varijable *duljina mreže JPP-a* i *površina područja*. Između navedenih je varijabla moguće uspostaviti uzročne veze sa smjerom promjene prema varijabli *gustoća mreže JPP-a*. Između varijabla *duljina mreže JPP-a* i *gustoća mreže JPP-a* postoji pozitivna veza jer se povećanjem prve varijable povećava druga varijabla. Varijable *površina područja* i *gustoća mreže JPP-a* vezane su negativnom vezom jer povećanje prve varijable uzrokuje smanjenje druge varijable. S varijablom *duljina mreže JPP-a* komuniciraju varijable *duljina prometnoga pravca* i *broj prometnih pravaca*. Između navedenih varijabla uspostavljaju se uzročne veze sa smjerom promjene prema varijabli *duljina mreže JPP-a*. U komunikacijama između varijabla *duljina prometnoga pravca* i *duljina mreže JPP-a* te varijabla *broj prometnih pravaca* i *duljina mreže JPP-a* uspostavljaju se pozitivne veze jer se povećanjem prvih varijabla povećavaju druge varijable.

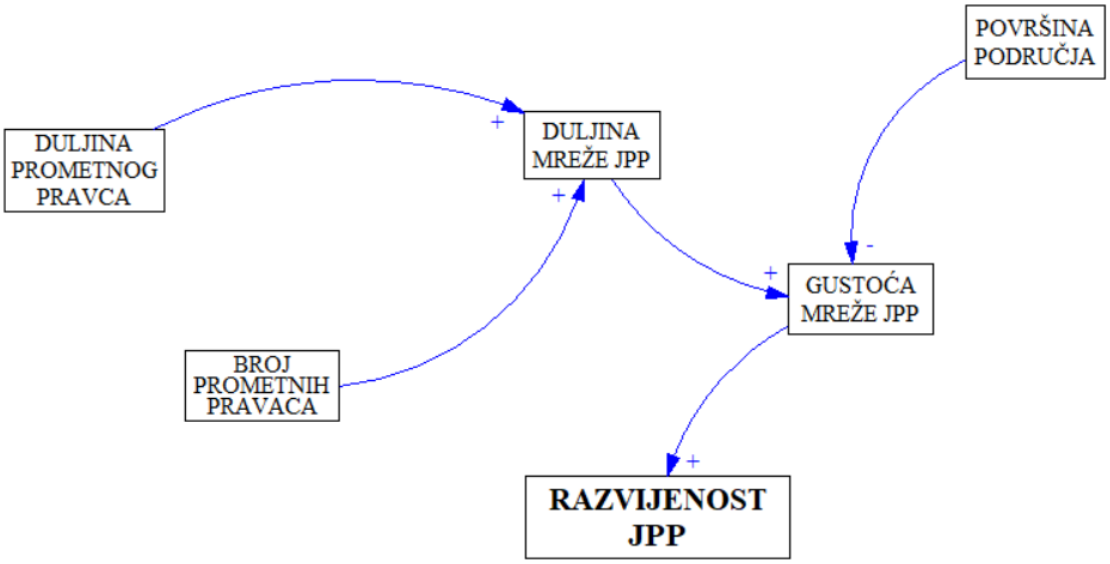

Slika 12. Dijagram uzročnih petlji razvijenosti gustoće mreže JPP-a

Razvijenost mreže JPP-a predstavlja drugi dijagram uzročnih petlji (Slika 13.). Na razvijenost JPP-a nekoga područja izravno utječe varijabla *razvijenost mreže JPP-a*. Ona se određuje na temelju duljine i broja prometnih pravaca na nekom području pa samim time s njom komuniciraju varijable *duljina prometnoga pravca* i *broj prometnih pravaca*. Unutar njihove komunikacije javljaju se pozitivne veze sa smjerom promjene prema varijabli *razvijenost mreže JPP-a* jer se povećanjem prvih varijabla povećavaju druge varijable.

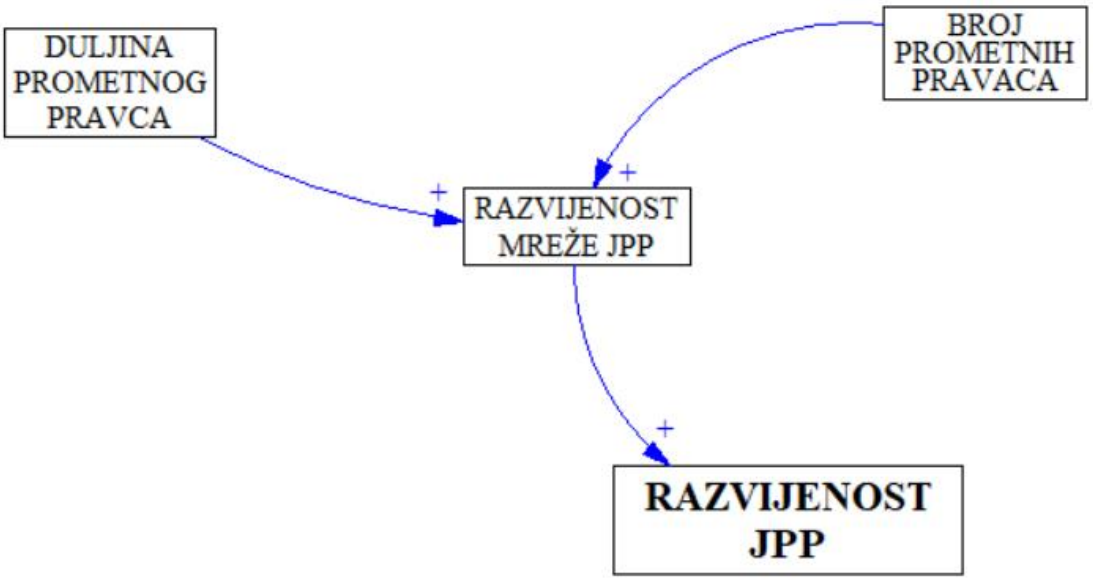

Slika 13. Dijagram uzročnih petlji razvijenosti mreže JPP-a

Djelomična pojava istih varijabla kod prvoga i drugoga dijagrama uzročnih petlji u posljednjoj će etapi, odnosno konačnom modelu uzrokovati povezivanje dvaju dijagrama uzročnim vezama.

Treći se dijagram uzročnih petlji (Slika 14.) odnosi na frekvenciju polazaka u javnom prijevozu putnika. Varijabla koja izravno utječe na razvijenost JPP-a jest *frekvencija polazaka*. Na varijablu frekvencija polazaka utječu varijable *vrijeme putovanja*, *komercijalna brzina*, *kapacitet vozila JPP-a* i *broj stanovnika*. Između njih se pojavljuju pozitivne i negativne uzročne veze sa smjerom promjene prema varijabli *frekvencija polazaka*. U komunikaciji varijabla *komercijalna brzina*, *kapacitet vozila JPP*-a i *broj stanovnika* s varijablom *frekvencija polazaka* pojavljuju se pozitivne uzročne veze jer se povećanjem prvih varijabla uzrokuje smanjenje druge varijable, dok se u komunikaciji između varijabla *vrijeme putovanja* i *frekvencija polazaka* javlja negativna veza jer povećanje prve varijable uzrokuje smanjenje

druge varijable. Na varijablu *komercijalna brzina* pozitivnim vezama utječu varijable *kvaliteta infrastrukture* i *kvaliteta vozila u JPP-u*, dok varijabla *komercijalna brzina* negativnom uzročnom vezom utječe na varijablu *vrijeme putovanja* jer povećanje komercijalne brzine u javnom prijevozu putnika uzrokuje smanjenje vremena putovanja.

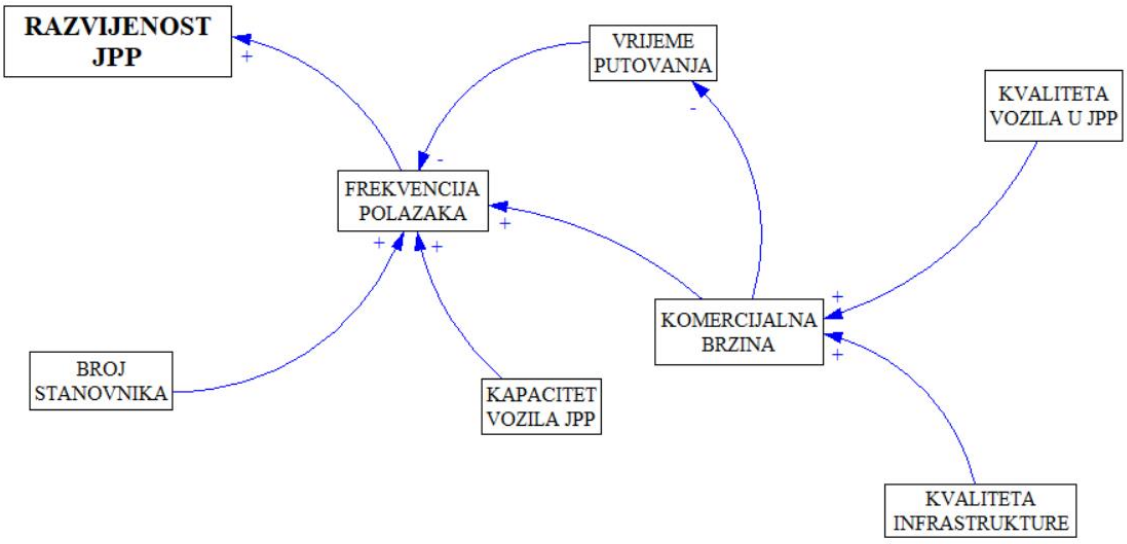

Slika 14. Dijagram uzročnih petlji razvijenosti frekvencije polazaka u JPP-u

Demografska je gustoća javnoga prijevoza putnika (Slika 15.) razrađena u četvrtom dijagramu uzročnih petlji. Varijabla *demografska gustoća JPP-a* izravno utječe na razvijenost javnoga prijevoza putnika nekoga područja. Ona se izračunava iz odnosa duljine prometne mreže i broja stanovnika koje prebiva u nekom području, stoga s njom komuniciraju varijable *duljina mreže JPP-a* i *broj stanovnika* sa smjerom promjene prema varijabli *demografska gustoća JPP-a*. Između varijabla *duljina mreže JPP-a* i *demografska gustoća JPP-a* postoji pozitivna veza jer se povećanjem prve varijable povećava druga varijabla. Varijable *broj stanovnika* i *demografska gustoća JPP-a* vezane su negativnom vezom jer povećanje prve varijable uzrokuje smanjenje druge varijable. Varijabla *duljina mreže JPP-a* komunicira pozitivnim vezama usmjerenima prema njoj samoj s varijablama *duljina prometnoga pravca* i *broj prometnih pravaca* koje se pojavljuju i u prvom dijagramu, što će u konačnom modelu uzrokovati povezivanje dijagrama.

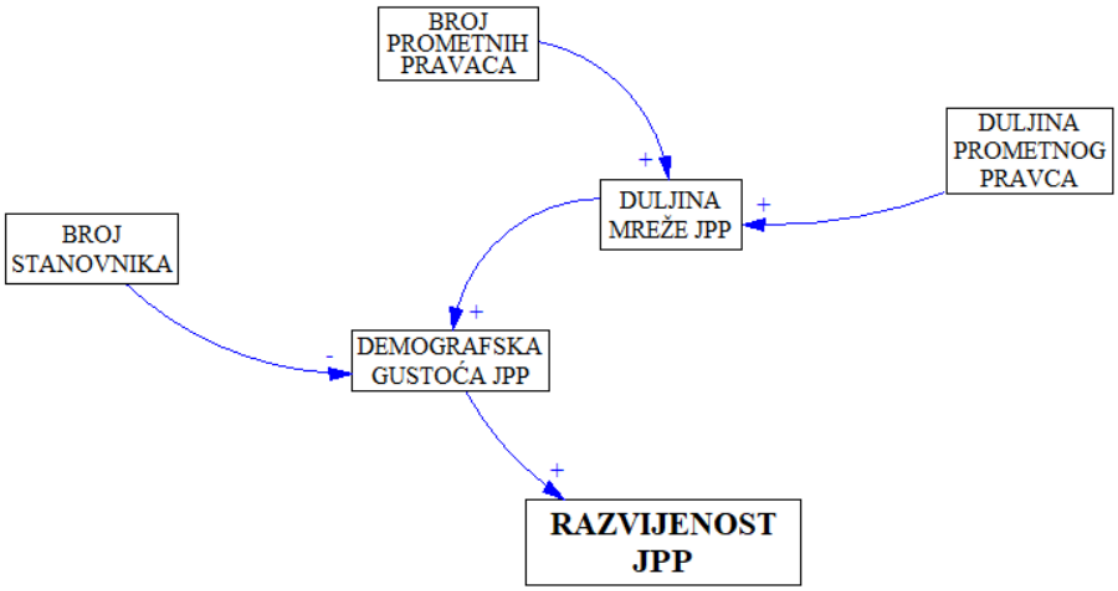

Slika 15. Dijagram uzročnih petlji razvijenosti demografske gustoće JPP-a

Peti dijagram uzročnih petlji opisuje utjecaj gustoće stajališta u javnom prijevozu putnika na razvijenost javnoga prijevoza putnika promatranoga područja (Slika 16.). Izravan je utjecaj varijable *gustoća stajališta JPP-a* na razvijenost javnoga prijevoza putnika nekoga područja.

S varijablom *gustoća stajališta JPP-a* komuniciraju varijable *površina područja*, *broj stajališta* i *broj stanovnika*. Između navedenih je varijabla moguće uspostaviti uzročne veze sa smjerom promjene prema varijabli *gustoća stajališta JPP-a*. Na varijablu *gustoća stajališta JPP-a* pozitivno utječe varijabla *broj stajališta* jer se s povećanjem broja stajališta povećava i gustoća stajališta u JPP-u. Negativna se veza javlja između varijabla *površina područja* i *gustoća stajališta JPP-a* zbog postojanja relacijskoga odnosa u kojem se s povećanjem prve varijable smanjuje druga. Između varijabla *broj stanovnika* i *gustoća stajališta JPP-a* javlja se pozitivna, odnosno potencirajuća petlja jer je paran broj negativnih uzročno-posljedičnih veza. Drugim riječima, moguće je stalno potencirati petlju u kojoj će se s povećanjem broja stanovnika na nekom području povećavati gustoća stajališta u JPP-u i potražnja će utjecati na ponudu. Također, povećanjem gustoće stajališta u JPP-u utjecat će se s ponudom na potražnju pa će se potencijalno povećati broj stanovništva na promatranom području.

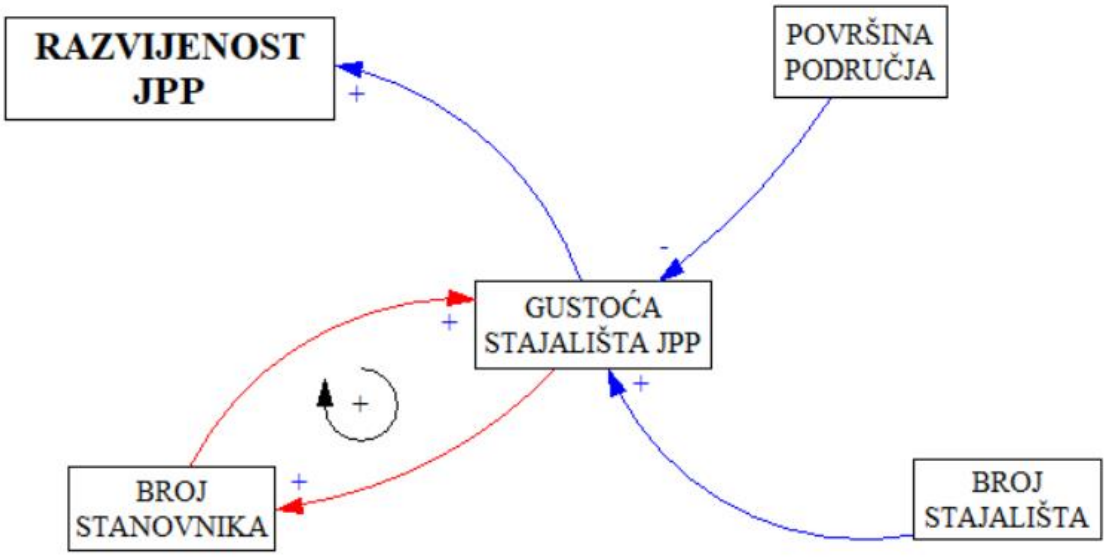

Slika 16. Dijagram uzročnih petlji razvijenosti gustoće stajališta JPP-a

Nakon što su izrađeni svi dijelovi dijagrama uzročnih petlji, može se pristupiti spajanju u konačan model sustavne dinamike prometnih kriterija razvijenosti u računalnom alatu *Vensim* (Slika 17.).

Konačnim je modelom sustavne dinamike prometnih kriterija razvijenosti završeno modeliranje sustavne dinamike kriterija koji sudjeluju u funkcioniranju sustava razvijenosti te se može krenuti u donošenje odluke o važnosti pojedinih kriterija i u njihovo uključivanje u model pravičnoga tarifnoga sustava.

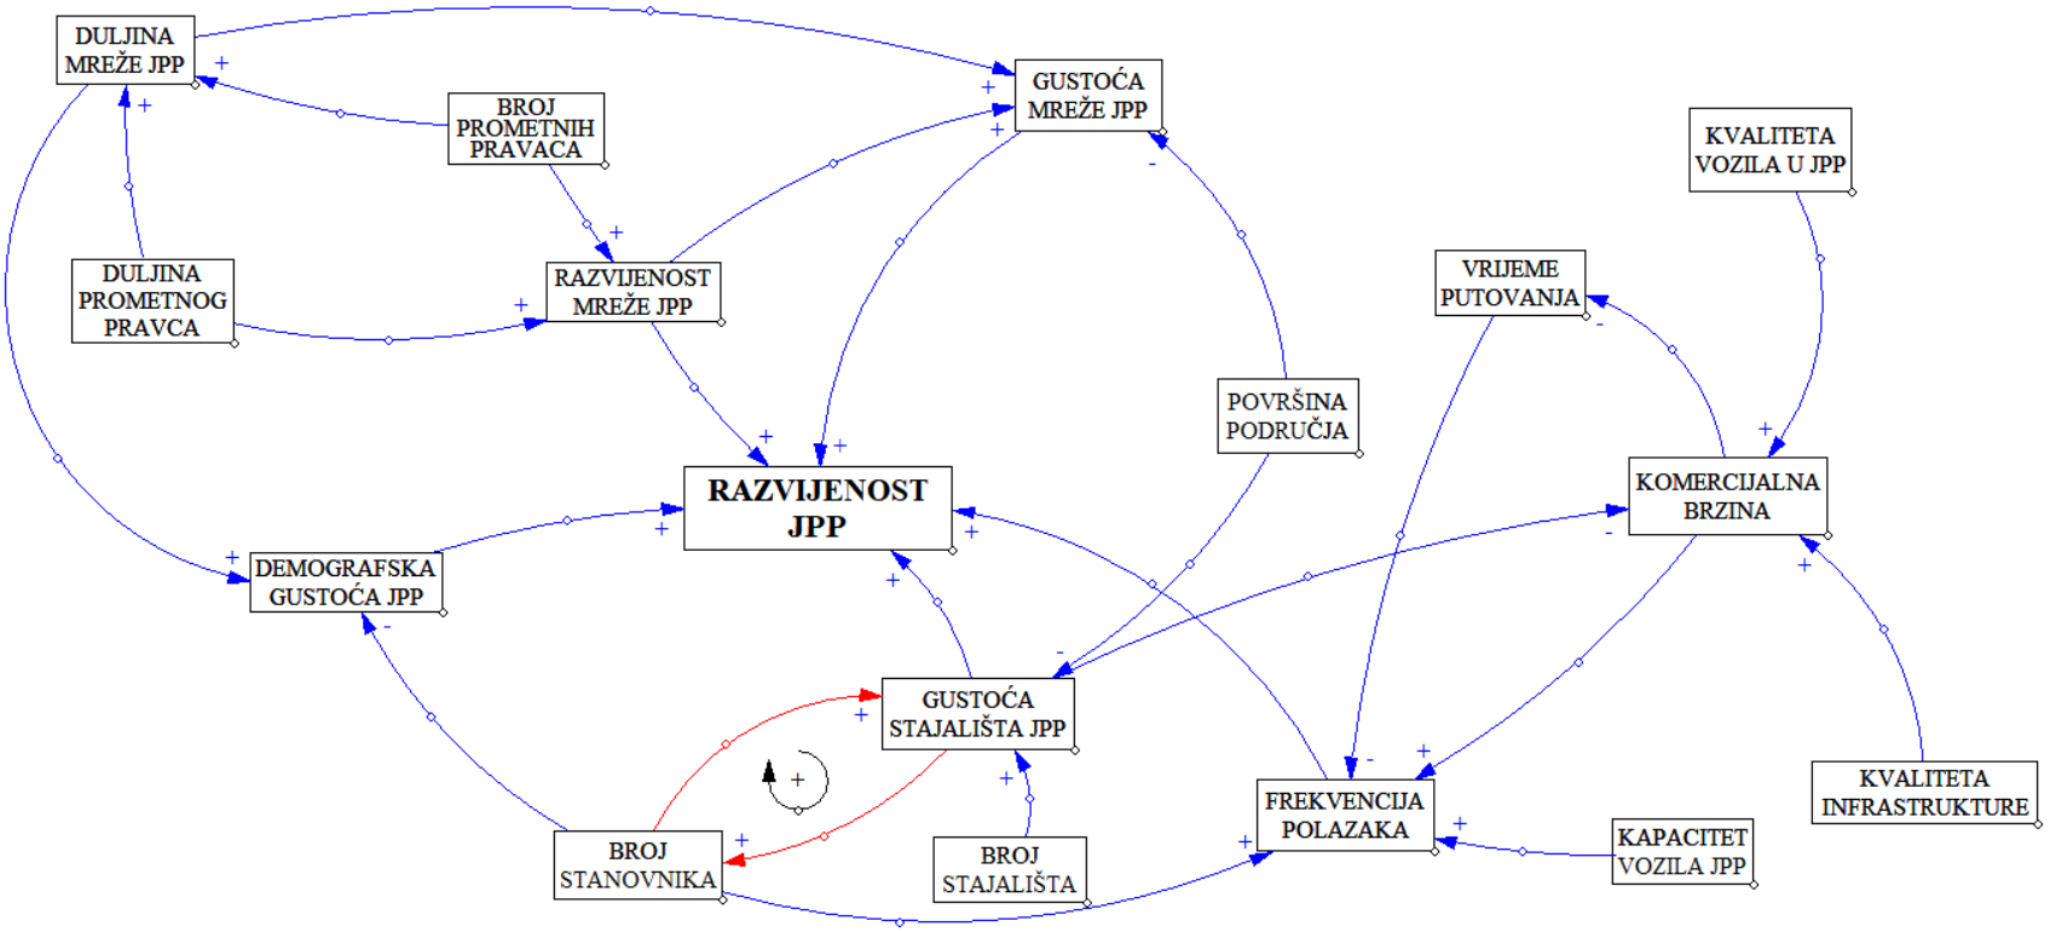

Slika 17. Dijagram uzročnih petlji prometnih kriterija razvijenosti

4.6. Pravični kriteriji pri određivanju tarifnih zona u integriranom prijevozu putnika

Najznačajniji problemi [39] koji se iščitavaju iz znanstvenih i stručnih radova odnose se na odabir reprezentativnih pokazatelja i njihove strukture. Naglašava se važnost reprezentativnosti pokazatelja koji su promatrani s različitih gledišta, kao što je razina teritorijalnoga prikaza, način vrednovanja odabranih pokazatelja, odabir jednostavnih ili višestrukih pokazatelja (indeksa) razvijenosti. Modeliranjem je sustavne dinamike omogućeno bolje razumijevanje funkcioniranja složenoga sustava i kroz dijagram uzročnih petlji ostvarena je mogućnost donošenja odluke o određivanju pravičnih kriterija pri određivanju tarifnih zona u integriranom prijevozu putnika.

Struktura povratnih veza u sustavu demografskih kriterija razvijenosti prikazala se modeliranjem sustavne dinamike kroz etape, odnosne dijelove modela i kao konačan model demografskih kriterija razvijenosti (Slika 7.). Prikazano je ukupno 28 varijabla koje međusobno komuniciraju uzročno-povratnim vezama i čine strukturu modela. Vizualiziranjem je središnje strukture sustava omogućen pronalazak temeljnih uzročnih veza u strukturi sustava, odnosno odabir pravičnih kriterija s gledišta demografske razvijenosti.

Prve varijable koje izravno ulaze u središnju varijablu *demografska razvijenost* jesu varijable *razmještaj stanovništva*, *kretanje stanovništva* i *sastav stanovništva*. Zanimljivo je da sve tri navedene varijable posjeduju smjer veze prema središnjoj varijabli, ali ne i uzročni utjecaj između varijabla koji se označava polaritetom „+“ ili „–„ te označavaju promjenu zavisne varijable kada se nezavisna varijabla promijeni. Razlogom je tomu činjenica da su navedene tri varijable strukturne opisne varijable koje se mogu kvantificirati podvarijablama unutar sustava. Ako pogledamo varijablu *razmještaj stanovništva*, vidljiva je njezina komunikacija s varijablom *gustoća stanovništva* koja se može kvantificirati i na koju uzročno, sa svojim polaritetima, utječu varijable *broj stanovnika* i *površina područja*. Time je dobiven prvi pravični kriterij iz kategorije demografskih kriterija razvijenosti, odnosno kriterij *gustoće stanovništva*.

Sljedeća varijabla koja se ne može kvantificirati, a izravno komunicira sa središnjom varijablom jest varijabla *kretanje stanovništva*. Navedena varijabla komunicira s varijablom *opće kretanje stanovništva* na koju uzročno utječu varijable *natalitet, mortalitet, emigracija* i *imigracija*. Varijablu *opće kretanje stanovništva* može se kvantificirati te time svrstati u drugi pravični kriterij.

Varijabla *sastav stanovništva*, kao i svi njezini ogranci, nema uzročne veze. Razlogom je tomu što se ne mogu uspostaviti uzročno-posljedične veze između varijabla, već samo smjer komunikacije. U skladu s navedenim i prema načelima za uspješno modeliranje sustavne dinamike potrebno je promisliti o posebnosti sustava koji se modelira i napraviti analizu varijabla kako bi se utvrdila moguća korisnost pojedinih varijabla za posebnu svrhu, odnosno u ovom slučaju za model pravičnoga tarifnoga sustava u integriranom prijevozu putnika. Varijabla *sastav stanovništva* komunicira s varijablama *društveno-gospodarski sastav*, *kulturno-antropološki sastav* i *biološki sastav*. Varijabla *društveno-gospodarski sastav* sa svim svojim podvarijablama ujedno je vezana i uz gospodarske kriterije razvijenosti koji su također detaljno razrađeni u svrhu istraživanja, stoga je nepotrebno razmatranje njihovoga odabira unutar demografskih kriterija razvijenosti, a s već navedenom posebnom svrhom. Varijabla *kulturno-antropološki sastav* razmatra demografsku razvijenost s gledišta narodnosti, jezika, vjere i rase. S obzirom na posebnu svrhu istraživanja može se zaključiti kako niti jedna od navedenih varijabla ne zahtijeva njihovo uključivanje u kriterij pravičnosti. Posljednja varijabla koja komunicira s varijablom *sastav stanovništva* jest varijabla *biološki sastav*. Ona razmatra razvijenost u odnosu na spol i dob. S obzirom na svrhu podjela stanovništva na spol nije odgovarajuća i ne može se razmatrati kao pravični kriterij demografske razvijenosti. U podjeli stanovništva na dob javljaju se varijable *predradni kontingent*, *radni kontingent* i *postradni kontingent*. Za funkcioniranje odnosa ponude i potražnje u javnom prijevozu putnika najvažniji je dionik unutar sustava stanovništvo koje svrstavamo u radni kontingent. Stanovništvo koje čini predradni i postradni kontingent u svim sustavima javnoga prijevoza putnika u praksi je subvencionirano i predstavlja dionike u sustavu koji imaju posebne pogodnosti pri korištenju javnoga prijevoza. Kod radnoga kontingenta to nije slučaj i treba ih se uzeti u obzir pri odabiru pravičnih kriterija demografske razvijenosti. U skladu s navedenim, treći pravični kriterij pri određivanju tarifnih zona u integriranom prijevozu putnika i posljednji iz demografskih kriterija razvijenosti jest kriterij *radni kontingent* koji označava razvijenost pojedinoga područja s gledišta brojnosti stanovništva iz kategorije od 15 do 64 godina.

Gospodarski su se kriteriji razvijenosti prikazali modeliranjem sustavne dinamike kroz tri etape i kao konačni model gospodarskih kriterija razvijenosti (Slika 11.). Prikazane su ukupno 23 varijable koje međusobno komuniciraju uzročno-povratnim vezama i čine strukturu modela. Vizualiziranjem je središnje strukture sustava omogućen pronalazak temeljnih uzročnih veza u strukturi sustava i odabir pravičnih kriterija s gledišta gospodarske razvijenosti.

Prve su varijable koje izravno ulaze u središnju varijablu *gospodarska razvijenost* varijable *stopa nezaposlenosti*, *dohodak po stanovniku* i *proračunski prihodi po stanovniku*. Sve tri navedene varijable posjeduju smjer veze i uzročni utjecaj prema središnjoj varijabli te označavaju promjenu zavisne varijable kada se nezavisna varijabla promijeni. Time su dobivena sva tri pravična kriterija iz kategorije gospodarskih kriterija razvijenosti, odnosno kriteriji *stopa nezaposlenosti*, *dohodak po stanovniku* i *proračunski prihodi po stanovniku*. Ostale varijable koje su uključene u strukturu povratnih veza sustavne dinamike gospodarskih kriterija razvijenosti izravno komuniciraju i utječu na ishod navedenih triju pravičnih kriterija i ne može ih se svrstati u relevantne kriterije jer bi se pojedini rezultati u modelu mogli pojavljivati višestruko, što bi utjecalo na točnost modela.

Varijable *dohodak po stanovniku* i *proračunski prihodi po stanovniku* komuniciraju sa središnjom varijablom pozitivnim uzročnim vezama jer se s povećanjem jedne varijable javlja povećanje druge varijable. U skladu s navedenim, može se utvrditi kako će veći dohodak po stanovniku i veći proračunski prihodi po stanovniku uzrokovati veću razvijenost promatranoga područja te će u pravičnom modelu utjecati na veću naplatu za razvijenija područja. Treća varijabla *stopa nezaposlenosti* komunicira sa središnjom varijablom negativnom uzročnom vezom jer se s povećanjem prve varijable javlja smanjenje druge varijable. Drugim riječima, ako je veća stopa nezaposlenosti, javlja se manja razvijenost promatranoga područja.

Struktura povratnih veza u sustavu prometnih kriterija razvijenosti prikazala se modeliranjem sustavne dinamike kroz pet etapa, odnosno dijelova modela i kao konačni model prometnih kriterija razvijenosti (Slika 17.). Prikazano je ukupno 17 varijabla koje međusobno komuniciraju uzročno-povratnim vezama i čine strukturu modela. Vizualiziranjem je središnje strukture sustava omogućen pronalazak temeljnih uzročnih veza u strukturi sustava, odnosno odabir pravičnih kriterija s gledišta prometne razvijenosti. Prve su varijable koje izravno ulaze u središnju varijablu *razvijenost JPP-a* varijable *gustoća mreže*, *razvijenost mreže JPP-a*, *demografska gustoća JPP-a*, *frekvencija polazaka* i *gustoća stajališta JPP-a*. Svih pet navedenih varijabla posjeduju smjer veze prema središnjoj varijabli, a uzročni je utjecaj između svih varijabla označen polaritetom „+“. One označavaju pozitivnu promjenu zavisne varijable kada se nezavisna varijabla promijeni. Ostale varijable koje su uključene u strukturu povratnih veza sustavne dinamike gospodarskih kriterija razvijenosti izravno komuniciraju i utječu na ishod navedenih pet pravičnih kriterija i ne može ih se svrstati u relevantne kriterije jer bi se pojedini rezultati u modelu mogli pojavljivati višestruko, što bi utjecalo na točnost modela. Posebnost je strukture povratnih veza kod prometnih kriterija razvijenosti pojava izravne

komunikacije između varijabla koje izravno utječu na središnju varijablu. Riječ je o komunikaciji varijable *razvijenost mreže JPP-a* s varijablom *gustoća mreže JPP-a* u smjeru varijable *gustoća mreže JPP-a*. Osim navedenoga vidljivo je kako se s povećanjem razvijenosti mreže JPP-a povećava i gustoća mreže JPP-a. Isto tako, kada se pogleda strukturu unutar navedenih varijabla, može se iščitati kako na gustoću mreže u JPP-u utječe duljina mreže. Samo duljina mreže ovisi o duljini i broju prometnih pravaca koji su sastavni dio razvijenosti mreže JPP-a. U skladu s tim zaključuje se kako varijabla *razvijenost mreže JPP-a* ne ulazi u kategoriju pravičnih kriterija jer je ona već sa svojim karakteristikama unutar sustava samim time što izravno utječe i komunicira s varijablom *gustoća mreže JPP-a*.

Time su dobivena četiri pravična kriterija iz kategorije prometnih kriterija razvijenosti, odnosno kriteriji gustoća mreže JPP-a, demografska gustoća JPP-a, frekvencija polazaka i gustoća stajališta JPP-a. Sve četiri varijable komuniciraju sa središnjom varijablom pozitivnim uzročnim vezama jer se s povećanjem jedne varijable javlja povećanje druge varijable. U skladu s navedenim može se utvrditi kako će veća gustoća mreže, demografska gustoća, frekvencija polazaka i gustoća stajališta uzrokovati veću razvijenost promatranoga područja te će u pravičnom modelu utjecati na veću naplatu za razvijenija područja.

Odabir je reprezentativnih pokazatelja, odnosno pravičnih kriterija pri određivanju tarifnih zona u integriranom prijevozu putnika napravljen modeliranjem sustavne dinamike s pomoću dijagrama uzročnih veza te su dobiveni sljedeći kriteriji i potkriteriji:

1. *demografska razvijenost*:
    a) gustoća stanovništva
    b) opće kretanje stanovništva
    c) radni kontingent
2. *gospodarska razvijenost*:
    a) stopa nezaposlenosti
    b) dohodak po stanovniku
    c) proračunski prihodi po stanovniku
3. *prometna razvijenost*:
    a) gustoća mreže JPP-a
    b) demografska gustoća JPP-a
    c) frekvencija polazaka
    d) gustoća stajališta JPP-a.

„Measurement is the first step that leads to control and eventually to improvement."

H. James Harrington

5. Vrednovanje pravičnih kriterija

Definiranjem je pravičnih kriterija pri određivanju tarifnih zona u integriranom prijevozu putnika ispunjen početni uvjet pri utvrđivanju utjecaja pravičnih kriterija na cijenu tarifnih zona. Kako bi definirani pravični kriteriji tvorili pravični tarifni model, potrebno je utvrditi utjecaj svakoga pojedinačnoga kriterija. Utjecaj kriterija odredit će se vrednovanjem definiranih pravičnih kriterija s pomoću metode analitičkoga hijerarhijskoga procesa kao jedne od najpoznatijih metoda za višekriterijsko odlučivanje. Ovo je poglavlje podijeljeno na četiri potpoglavlja. Prvo potpoglavlje opisuje metodu analitičkoga hijerarhijskoga procesa. Potom je razrađena metodologija vrednovanja pravičnih kriterija i prikazana anketa za vrednovanje koja je poslana stručnjacima prema zadanoj metodologiji. Posljednje potpoglavlje daje prikaz rezultata provedenoga vrednovanja pravičnih kriterija.

5.1. Analitički hijerarhijski proces

Utjecaj kriterija može se odrediti vrednovanjem definiranih pravičnih kriterija s pomoću metode [52, 53] analitičkoga hijerarhijskoga procesa, odnosno popularno zvane AHP metode (engl. *Analytic Hierarchy Process*). U području višekriterijskoga odlučivanja za donošenje odluka koriste se metode ELECTRE (fran. *ELimination Et Choix Traduisant la REalité*), metoda PROMETHEE (engl. *Preference Ranking Organization METHod for Enrichment of Evaluations*) i metoda TOPSIS (engl. *Technique for Order of Preference by Similarity to Ideal Solution*). Jedna je od najpoznatijih i najviše primijenjenih metoda višekriterijskoga odlučivanja za oblikovanje i analizu hijerarhije odlučivanja metoda AHP. Razvio ju je *Thomas Saaty*, profesor sa Sveučilišta *Pittsburgh*, 70-tih godina prošloga stoljeća. Ubraja se u klasu metoda za meku optimizaciju gdje se prvo omogućava interaktivno kreiranje hijerarhije problema kao priprema za scenarij odlučivanja, a zatim se vrednuju parovi elemenata hijerarhije. U konačnici je rezultat sinteza vrednovanih elemenata po strogo utvrđenom matematičkom modelu koji određuje težinske koeficijente elemenata hijerarhije. Primjena je AHP metode široka zbog svoje hijerarhijske strukture u modelu odlučivanja, stoga donositelji odluka u svim vrstama struke pronalaze svoju primjenu AHP metode s pomoću koje dolaze do optimalnijih i značajnijih odluka [54].

Rješavanje problema AHP metodom sastoji se od četiriju dijelova koji su sljedeći:

1. strukturiranje problema
2. prikupljanje podataka
3. ocjenjivanje relativnih težina
4. određivanje rješenja problema.

Prvi je korak strukturiranje problema odlučivanja u obliku hijerarhijske strukture. Hijerarhijska se struktura ovakvoga modela odlučivanja sastoji od triju razina pri čemu je cilj na najvišoj razini. Kriteriji mogu biti rastavljeni na potkriterije na srednjoj razini i alternative na najnižoj razini [54]. Alternative mogu biti predstavljene kao objekti, kandidati i odluke, a ne moraju nužno predstavljati samo po sebi lako razumljivo predočavanje realnoga procesa tijekom procesa odlučivanja.

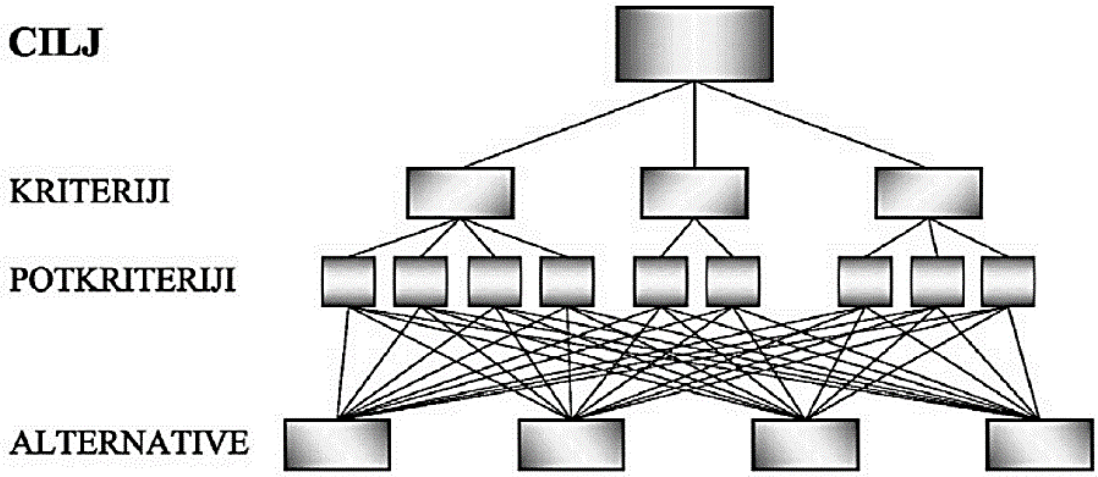

Slika 18. Hijerarhijska struktura AHP metode [54]

Nakon postavljanja hijerarhijske strukture potrebno je prikupiti podatke na temelju kojih će se ocjenjivati relativne težine kriterija. Tada se može započeti s ocjenjivanjem relativnih težina unutar razina hijerarhijske strukture. Na svakoj se razini hijerarhije, osim na najvišoj razini na kojoj se nalazi *cilj*, uspoređuju svi elementi u parovima na istoj razini. Usporedba se obavlja interpretacijom relativne važnosti dvaju kriterija s pomoću *Saatyjeve* skale (Tablica 2.).

Tablica 2. *Saatyjeva* skala vrednovanja relativne važnosti dvaju kriterija [54]

Intenzitet važnosti	Interpretacija
1	kriterij *i* i *j* jednake su važnosti
3	kriterij *i* umjereno je važniji od kriterija *j*
5	kriterij *i* jako je važniji od kriterija *j*
7	kriterij *i* vrlo je jako važniji od kriterija *j*
9	kriterij *i* ekstremno je važniji od kriterija *j*
2, 4, 6, 8	međuvrijednosti

U postupku usporedbe relativne važnosti parova kriterija postavlja se matematički model na temelju kojega se dobivaju važnosti kriterija i potkriterija u zadanom optimizacijskom problemu.

Usporedba je parova određena matricom $A_n \times A_n$ elemenata koji predstavljaju vrijednost uspoređenih parova:

$$A = A_1, A_2, A_3, \dots A_n \tag{10.}$$

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} \tag{11.}$$

U prikazanoj matrici svi se parovi ocjenjuju u obliku dominacije atributa a_i nad a_j u obliku:

$$a_{ij} = \frac{w_i}{w_j} \text{ – omjer težina alternativa } A_i \; i \; A_j, \tag{12.}$$

pri čemu je w_i – težina, odnosno prioritet alternativa A_i.

$$A = a_{ij} \begin{bmatrix} \frac{w_1}{w_1} & \frac{w_1}{w_2} & \dots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & \frac{w_2}{w_2} & \dots & \frac{w_2}{w_n} \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \dots & \frac{w_n}{w_n} \end{bmatrix} \tag{13.}$$

Zbog ljudskih čimbenika i nesavršenosti mjernih skala oblikovana matrica često sadrži nekonzistentne procjene. Za provjeru konzistentnosti koriste se sljedeće formule:

$$\begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} * \begin{bmatrix} w_1 \\ w_2 \\ \dots \\ \dots \\ w_n \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ \dots \\ \dots \\ b_n \end{bmatrix} \tag{14.}$$

Matrica usporedbe parova množi se s vektorom težinskih koeficijenata kako bi se odredio vektor **b**. Vektor **λ** dobiva se dijeljenjem korespondentnih elemenata vektora **b** i **w**:

$$\begin{bmatrix} \frac{b_1}{w_1} \\ \frac{b_2}{w_2} \\ \dots \\ \dots \\ \frac{b_n}{w_n} \end{bmatrix} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \dots \\ \dots \\ \lambda_n \end{bmatrix} \tag{15.}$$

Dobivanjem vektora **λ** može se dobiti najveća svojstvenu vrijednost matrice λ_{max}:

$$\lambda_{max} = \frac{1}{n}\sum_{i=1}^{n} \lambda_i \tag{16.}$$

Kako bi se došlo do omjera konzistentnosti CR, potrebno je izračunati indeks konzistencije CI te odrediti prosječnu vrijednost konzistencije RI:

$$CI = \frac{\lambda_{max} - n}{n-1} \tag{17.}$$

$$CR = \frac{CI}{RI} \tag{18.}$$

Prosječna vrijednost konzistencije RI [54] uzima se iz tablice (Tablica 3.) ovisno o veličini matrice (N).

Tablica 3. Prosječna vrijednost konzistencije RI [54]

N	1	2	3	4	5	6	7	8	9	10
RI	0	0	0,52	0,89	1,11	1,25	1,35	1,40	1,45	1,49

Matrica A smatra se prihvatljivom ako je omjer konzistencije CR ≤ 0,10. Ako navedeni uvjet nije zadovoljen, matrica se ne smatra prihvatljivom, odnosno inkonzistencija je procjena

neprihvatljivo visoka ili niska, stoga je potrebno istražiti razloge takvoga rezultata te napraviti izmjene u metodologiji.

Za rješavanje problema s pomoću objašnjene metode AHP razvijen je programski paket *Expert Choice*. S pomoću programskoga paketa *Expert Choice* mogu se jednostavnije izračunavati svi koraci koji su karakteristični za metodu AHP. Program omogućava strukturiranje hijerarhijskoga modela problema odlučivanja i uspoređivanje svih parova unutar hijerarhijske strukture. Navedenim matematičkim izrazima dolazi do rezultata vrednovanja kriterija i potkriterija uz podatak o konzistentnosti unesenih podataka.

5.2. Metodologija vredovanja pravičnih kriterija

Za uspješno je vrednovanje pravičnih kriterija potrebno metodološki isplanirati sve postupke tijekom takvoga procesa. Početna je etapa određivanje stručnih skupina relevantnih za kriterije koji se vrednuju. AHP metoda provedena je na stručnjacima iz područja koja su važna za pravični tarifni model. To su prometni, ekonomski i demografski stručnjaci. Odabir relevantnih stručnjaka smatra se nultim korakom pri rješavanju problema vrednovanja kriterija zbog kvalitete rezultata koji su dobiveni na temelju odgovora stručnjaka.

Sljedeća je etapa određivanje veličine uzorka koja je izrazito važna zbog relevantnosti dobivenih rezultata i smatra se prvim te najvažnijim korakom u osmišljavanju istraživanja [55]. Kako bi se utvrdila potrebna veličina uzorka, nužno je znati svrhu istraživanja, veličinu populacije, odnosno broj stručnjaka, rizik od odabira krivoga uzorka i dopuštene pogreške u uzorkovanju. Postoji niz formula s pomoću kojih se dolazi do veličine uzorka, ali i gotove tablice [56]. Potrebna je veličina uzorka prikazana u Tablici 4.

Tablica 4. Potrebna veličina uzorka za ± 3 %, ± 5%, ± 7 %, i ±10 % stupanj preciznosti uz razinu pouzdanosti od 95 % [50]

Veličina populacije	**Potrebna veličina uzorka s preciznošću od:**			
	± 3 %	**± 5 %**	**± 7 %**	**± 10 %**
500	a	222	145	83
600	a	240	152	86
700	a	255	158	88
800	a	267	163	89
900	a	277	166	90
1000	a	286	169	91

2000	714	333	185	95
3000	811	353	191	97
4000	870	364	194	98
5000	909	370	196	98
6000	938	375	197	98
7000	959	378	198	99
8000	976	381	199	99
9000	989	383	200	99
10000	1000	385	200	99
15000	1034	390	201	99
20000	1053	392	204	100
25000	1064	394	204	100
50000	1087	397	204	100
100000	1099	398	204	100
> **100000**	1111	400	204	100
a = premala veličina populacije pa cijela populacija treba biti uzorkovana				

Ako se uzme da je više od 100 000 stručnjaka u svijetu iz ranije navedenih područja, može se zaključiti kako je potrebno provesti anketiranje na najmanje 100 stručnjaka uz preciznost od oko 10 % kako bi se dobilo razinu pouzdanosti uzorka od 95 %.

Vrednovanje pravičnih kriterija provelo se putem elektroničke pošte, slanjem *Google Forms* obrasca. Anketni je upitnik poslan na adrese stručnjaka iz 19 zemalja Europe. Osim iz Hrvatske uključeni su stručnjaci iz Austrije, Bosne i Hercegovine, Bugarske, Češke, Francuske, Grčke, Italije, Litve, Mađarske, Nizozemske, Njemačke, Poljske, Rumunjske, Slovačke, Slovenije, Srbije, Švedske i Ujedinjenoga Kraljevstva. Anketni su upitnici poslani 17. lipnja 2019. godine i bili su otvoreni mjesec dana, odnosno do 17. srpnja.

Nakon provedbe anketnoga upitnika rezultati su uneseni u programsku podršku za AHP metodu *Expert Choice* te je dobiven konačan rezultat vrednovanja pravičnih kriterija.

5.3. Anketa za vrednovanje pravičnih kriterija

Anketni je upitnik (Prilog 1.) sastavljen od 5 cjelina, u potpunosti je anoniman i za ispunjavanje je potrebno otprilike 15 minuta. Prva je cjelina anketnoga upitnika namijenjena kasnijem uspoređivanju odgovora različitih karakteristika između odabranih stručnjaka, a u njoj se nalazi 6 uvodnih pitanja:

1. U kojoj državi radite?
2. Gdje ste trenutno zaposleni?
3. Koliko ste dugo zaposleni na trenutačnom radnom mjestu?
4. Koja je Vaša stručna sprema?
5. Na Vašem radnom mjestu najviše se bavite sljedećom problematikom: [nadopisati].
6. U kojoj mjeri Vaš trenutačni posao utječe na problematiku ankete?

Druga je cjelina određivanje važnosti kriterija za definiranje cijene tarifne zone koja je podijeljena na dva dijela. Prvo je potrebno rangirati zadane kriterije (promet, gospodarstvo i demografija) po redoslijedu važnosti po principu ocjenjivanja ocjenama od 1 do 3 (1 – najvažniji kriterij, 2 – srednje važan kriterij i 3 – najmanje važan kriterij). Drugi je dio druge cjeline bilo pojedinačno uspoređivanje relativnih važnosti kriterija po AHP principu. Razlog je uvođenja rangiranja po redoslijedu važnosti zadanih kriterija želja za postizanjem boljega razumijevanja ponuđenih kriterija i njihovoga položaja unutar zadanoga skupa kriterija, odnosno postizanje što bolje konzistentnosti odgovora.

Prema istom su principu napravljene i preostale tri cjeline u kojima su stručnjaci vrednovali potkriterije ranije rangiranih triju kriterija.

Prije slanja anketnoga upitnika stručnjacima iz problematike disertacije napravljena je predanketa na malom uzorku (pet) eksperata. Anketni je upitnik je poslan e-mailom na pet adresa stručnjaka iz područja prometa, ekonomije i demografije kako bi se uočili mogući problemi pri rješavanju upitnika te kako bi isti na vrijeme bili otklonjeni. Navedena je predanketa pokazala probleme razumijevanja AHP metode vrednovanja, stoga je došlo do nadopune tekstualnoga dijela anketnoga upitnika prije samoga početka vrednovanja. Kako bi se olakšalo razumijevanje AHP metode vrednovanja, napravljena je razumljivija *Saatyjeva* skala vrednovanja relativne važnosti dvaju kriterija koja je imala jednake opise važnosti, ali je brojčano bila iskazana od 1 do 5:

1 – jednako važno

2 – umjereno važno

3 – strogo važnije

4 – vrlo strogo, dokazana važnost

5 – ekstremna važnost.

Nakon dobivenih rezultata odgovori stručnjaka usklađivali su se s teorijom AHP-a, odnosno skala od 1 do 5 pretvorena je u standardnu *Saatyjevu* skalu od 1 do 9.

Anketni je upitnik poslan na 150 e-mail adresa uz očekivanje od najmanje 100 odgovorenih upitnika kako bi upitnik bio u skladu s potrebnim minimalnim uzorkom.

5.4. Rezultati vrednovanja pravičnih kriterija

Anketni upitnici poslani na 150 e-mail adresa u Hrvatskoj i u inozemstvu rezultirali su sa 117 odgovorenih upitnika, odnosno 78 % od ukupno poslanih ili 17 upitnika više od potrebnih prema metodologiji dobivanja potrebne veličine uzorka. U Tablici 5. prikazan je postotak dobivenih odgovora prema zemljama zaposlenja stručnjaka.

Tablica 5. Postotak odgovorenih upitnika prema zemljama zaposlenja stručnjaka

Država	**Broj anketnih upitnika**	**Postotni udjel [%]**
Austrija	3	2
Bosna i Hercegovina	1	1
Češka	1	1
Francuska	1	1
Hrvatska	84	72
Italija	1	1
Litva	6	5
Mađarska	1	1
Poljska	7	6
Rumunjska	4	3
Slovačka	3	2
Slovenija	1	1
Srbija	2	2
Velika Britanija	2	2

Prispjeli odgovoreni anketni upitnici obuhvaćaju stručnjake koji su bili zaposleni u obrazovnim institucijama (sveučilište ili veleučilište), tvrtkama koje su upravitelji

infrastrukture, prijevozničkim tvrtkama, tijelima državne uprave (ministarstvo, grad, općina), institutima i ostalim tvrtkama koje su relevantne za istraživanje (Tablica 6.).

Tablica 6. Postotak odgovorenih upitnika prema institucijama zaposlenja stručnjaka

Institucija zaposlenja	Broj anketnih upitnika	Postotni udjel [%]
obrazovna institucija	61	52
upravitelj infrastrukture	6	5
prijevoznička tvrtka	15	13
tijelo državne uprave	22	19
institut	3	3
ostalo	10	8

Prema godinama zaposlenja na trenutačnom radnom mjestu unutar struke relevantne za provedbu anketnoga upitnika najviše je stručnjaka bilo zaposleno do 10 godina, zatim od 11 do 20 godina, a najmanje onih koji su zaposleni više od 30 godina (Tablica 7.). Problem je najmanjega odaziva stručnjaka s duljim zaposlenjem od 30 godina prisutan u svim anketama iz više razloga, no njihova je prisutnost u ovoj i sličnim anketama iznimno značajna za mehanizam zaključivanja. Neki su od razloga manje prisutnosti spomenutih stručnjaka zauzetost poslovima koji su njima važniji, neslaganje s ovakvim načinom komunikacije ili manjak želje za sudjelovanjem u radu i doprinosu mlađim kolegama.

Tablica 7. Postotak odgovorenih upitnika prema godinama zaposlenja stručnjaka

Godine zaposlenja	Broj anketnih upitnika	Postotni udjel [%]
do 10 godina	50	43
od 11 do 20 godina	45	38
od 21 do 30 godina	17	15
više od 30 godina	5	4

Prema stručnoj spremi stručnjaci su imali visoku stručnu spremu, magisterij znanosti, sveučilišnu specijalizaciju ili doktorat znanosti. Njihov je udio prikazan u Tablici 8.

Tablica 8. Postotak odgovorenih upitnika prema stručnoj spremi stručnjaka

Stručna sprema	Broj anketnih upitnika	Postotni udjel [%]
visoka stručna sprema	57	49
magistar znanosti	4	3
sveučilišni specijalist	5	4
doktor znanosti	51	44

Udio je stručnjaka koji se na svom radnom mjestu pretežno bave prometnom, gospodarskom ili demografskom problematikom prikazan u Tablici 9. Može se primijetiti najveći odaziv stručnjaka iz sektora prometa, što je rezultat tematike samoga anketnoga upitnika, odnosno značaja za prometni sektor.

Tablica 9. Postotak odgovorenih upitnika prema ekspertizi stručnjaka

Ekspertiza	Broj anketnih upitnika	Postotni udjel [%]
promet	95	81
gospodarstvo	13	11
demografija	9	8

S obzirom na utjecaj trenutačnoga posla stručnjaka koji su sudjelovali u anketi na problematiku ankete najviše je bilo onih na koje problematika anketnoga upitnika srednje i jako utječe (63 %), što govori o kvalitetnom odabiru stručnjaka koji imaju izravnu vezu s problematikom tarifnih sustava u integriranom prijevozu putnika (Tablica 10.).

Tablica 10. Postotak odgovorenih upitnika prema utjecaju problematike ankete

Utjecaj	Broj anketnih upitnika	Postotni udjel [%]
uopće ne utječe	11	9
slabo utječe	14	12
srednje utječe	36	31
jako utječe	37	32
ekstremno utječe	19	16

Nakon analize odgovora prve cjeline anketnoga upitnika, koji je bio namijenjen usporedbi različitih karakteristika stručnjaka uključenih u anketiranje, druga je cjelina, odnosno određivanje važnosti pojedinih kriterija, u cijelosti obrađena u programskom paketu *Expert Choice*.

Prvi je korak u rješavanju problema s pomoću programskoga paketa *Expert Choice* strukturiranje hijerarhijskoga modela problema odlučivanja (Slika 19.), zatim uspoređivanje svih parova unutar hijerarhijske strukture i na kraju analiza dobivenih rezultata vrednovanja kriterija i potkriterija uz podatak o konzistentnosti unesenih podataka.

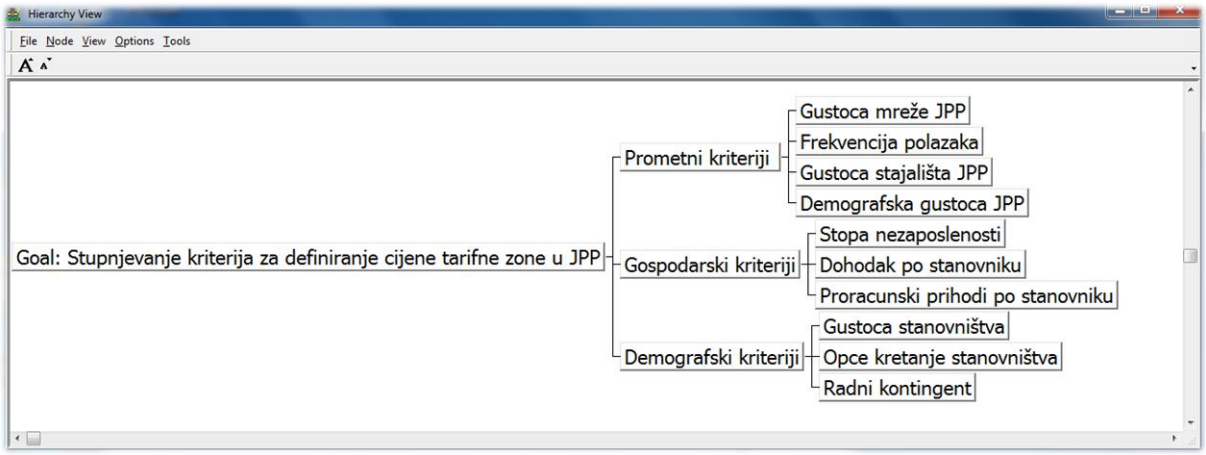

Slika 19. Hijerarhijska struktura AHP modela

Stručnjaci su prvo rangirali važnosti kriterija za definiranje cijene tarifne zone. Nakon unosa pojedinačnih usporedaba kriterija svih 117 uključenih stručnjaka dobiva se važnost prometnih kriterija razvijenosti od 45 %, gospodarskih kriterija razvijenosti od 32 % te demografskih kriterija razvijenosti od 23 % (Slika 20.).

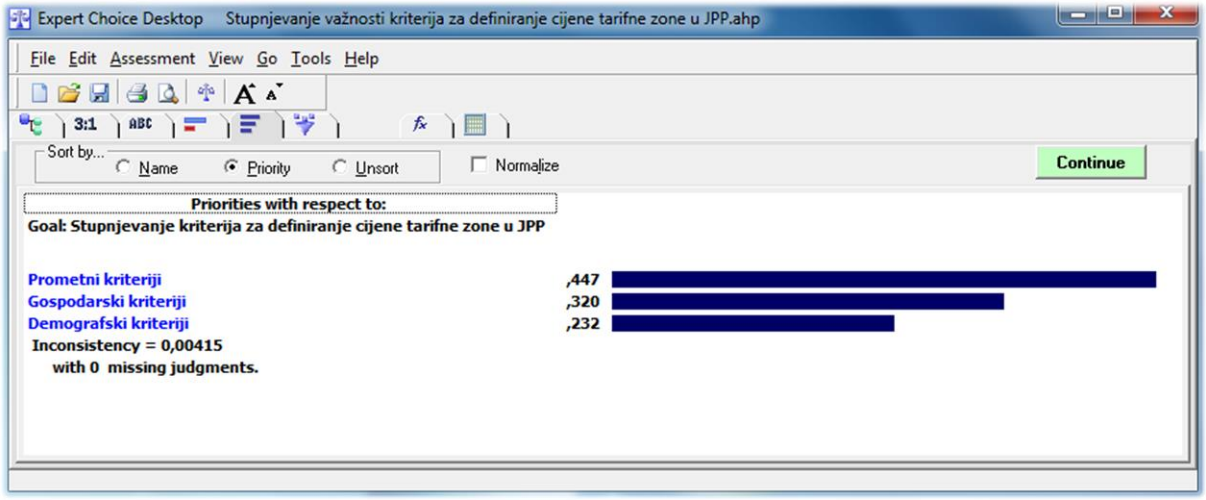

Slika 20. Rezultati vrednovanja kriterija s pripadajućim težinskim koeficijentima AHP modela

Potkriteriji prometne razvijenosti rangirani su i uneseni u *Expert Choice* (Slika 21.). Dobiva se najveća važnost potkriterija *frekvencija polazaka* od 38 %, zatim potkriterija *gustoća mreže* od 29 %, *demografska gustoća* od 17 % te najmanja važnost potkriterija *gustoća stajališta* od 16 %.

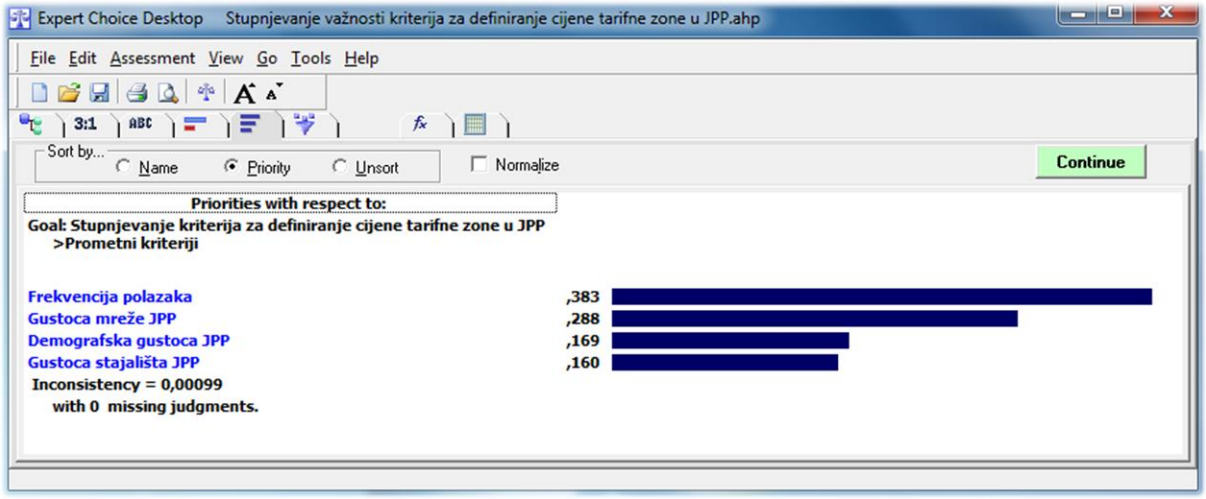

Slika 21. Rezultati vrednovanja prometnih kriterija, odnosno potkriterija AHP modela s pripadajućim težinskim koeficijentima

Kod gospodarskih potkriterija razvijenosti vrednovani su redom po važnosti dohodak po stanovniku s 39 %, stopa nezaposlenosti s 34 % i proračunski prihodi po stanovniku s 27 % (Slika 22.).

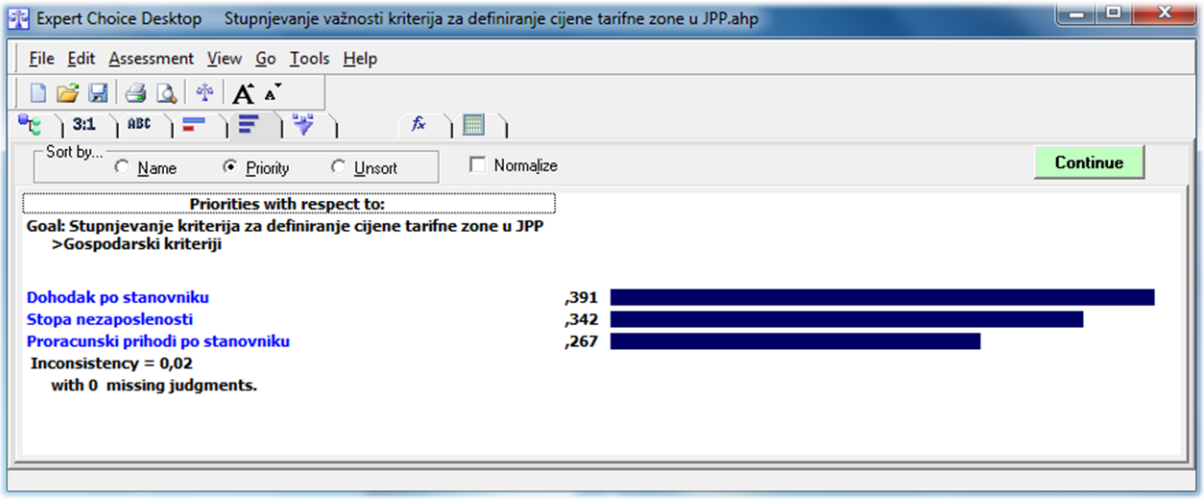

Slika 22. Rezultati vrednovanja gospodarskih kriterija, odnosno potkriterija AHP modela s pripadajućim težinskim koeficijentima

Stručnjaci su kod demografskih kriterija razvijenosti (Slika 23.) dali najveću važnost gustoći stanovništva, 40 %, zatim općem kretanju stanovništva, 35 %, te radnom kontingentu, 25 %.

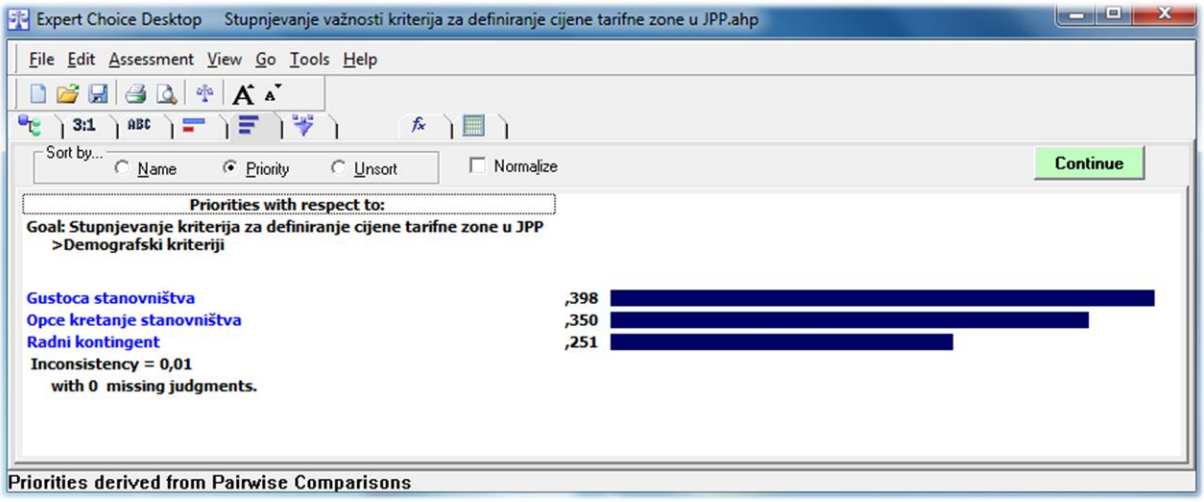

Slika 23. Rezultati vrednovanja demografskih kriterija, odnosno potkriterija AHP modela s pripadajućim težinskim koeficijentima

Nakon dobivenih važnosti napravljena je analiza osjetljivosti kriterija i potkriterija kako bi se ispitao učinak različitih kriterija na konačnu odluku. Na Slici 24. prikazana je analiza osjetljivosti gdje lijeva strana y osi označava težinu kriterija, dok desna daje prednost svakoj alternativi. Uz dinamičku osjetljivost mogu se prepoznati promjene u težini kriterija i rezultati koje uzrokuju na konačnoj odluci. Služi za određivanje snage i slabosti alternativa i može se očitati dominacija potkriterija *frekvencije polazaka*.

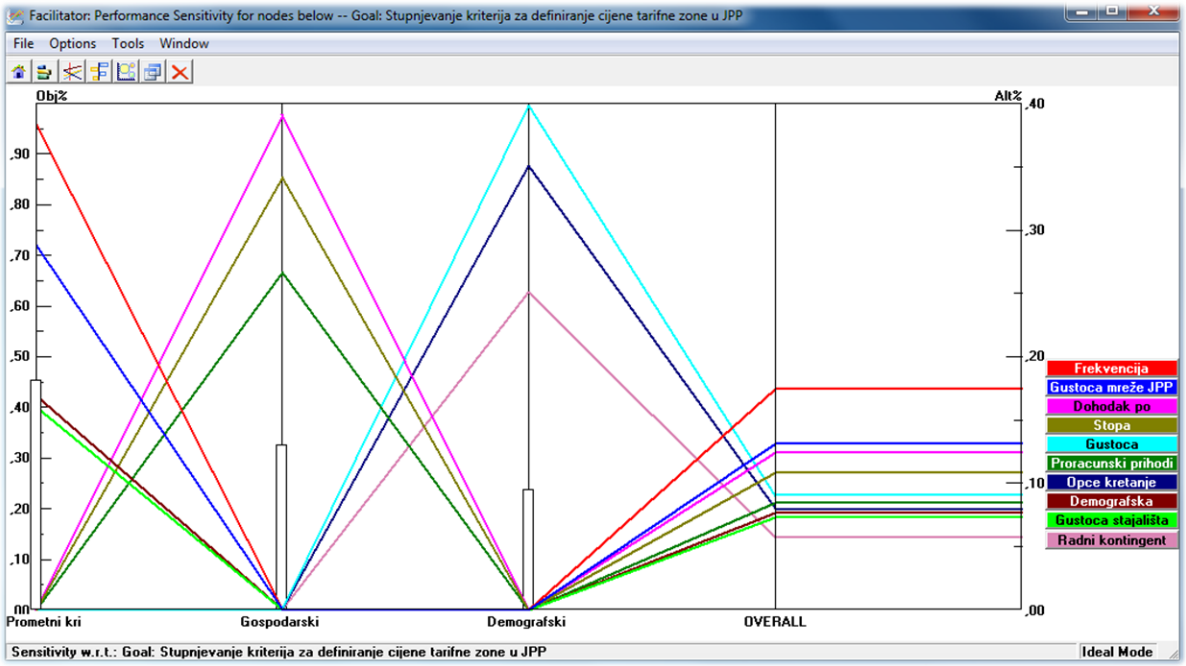

Slika 24. Analiza osjetljivosti kriterija i potkriterija na temelju pripadajućih težinskih koeficijenata AHP modela

Konačni su rezultati vrednovanja kriterija i potkriterija za definiranje cijene tarifne zone u AHP modelu prikazani u programskom paketu *Expert Choice* na Slici 25.

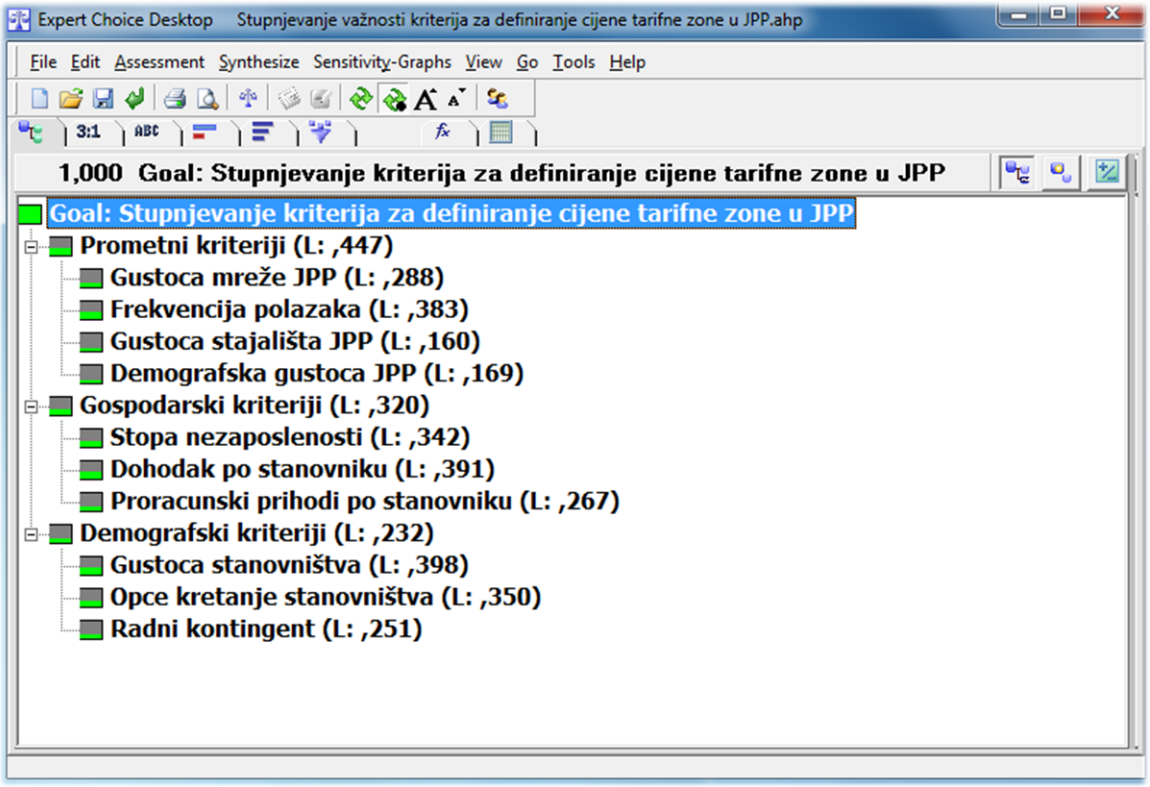

Slika 25. Rezultat vrednovanja kriterija i potkriterija za definiranje cijene tarifne zone u AHP modelu

Stručnjaci koji su vrednovali kriterije i potkriterije bili su iz Republike Hrvatske i iz inozemstva. Na Slici 26. usporedno su prikazani rezultati vrednovanja stručnjaka iz Hrvatske, stručnjaka iz inozemstva i ukupni rezultati.

Usporedni rezultati vrednovanja ukazuju na velike sličnosti u odgovorima stručnjaka iz Hrvatske i iz drugih zemalja Europe. Odstupanja su u većini odgovora na razini statističke pogreške, što dokazuje kompetentnost odabranih stručnjaka, njihovo znanje i iskustvo. Kod svih je rezultata omjer konzistencije CR daleko manji od 0,1, što ukazuje na visoku prihvatljivost rezultata i dobro postavljenu metodologiju.

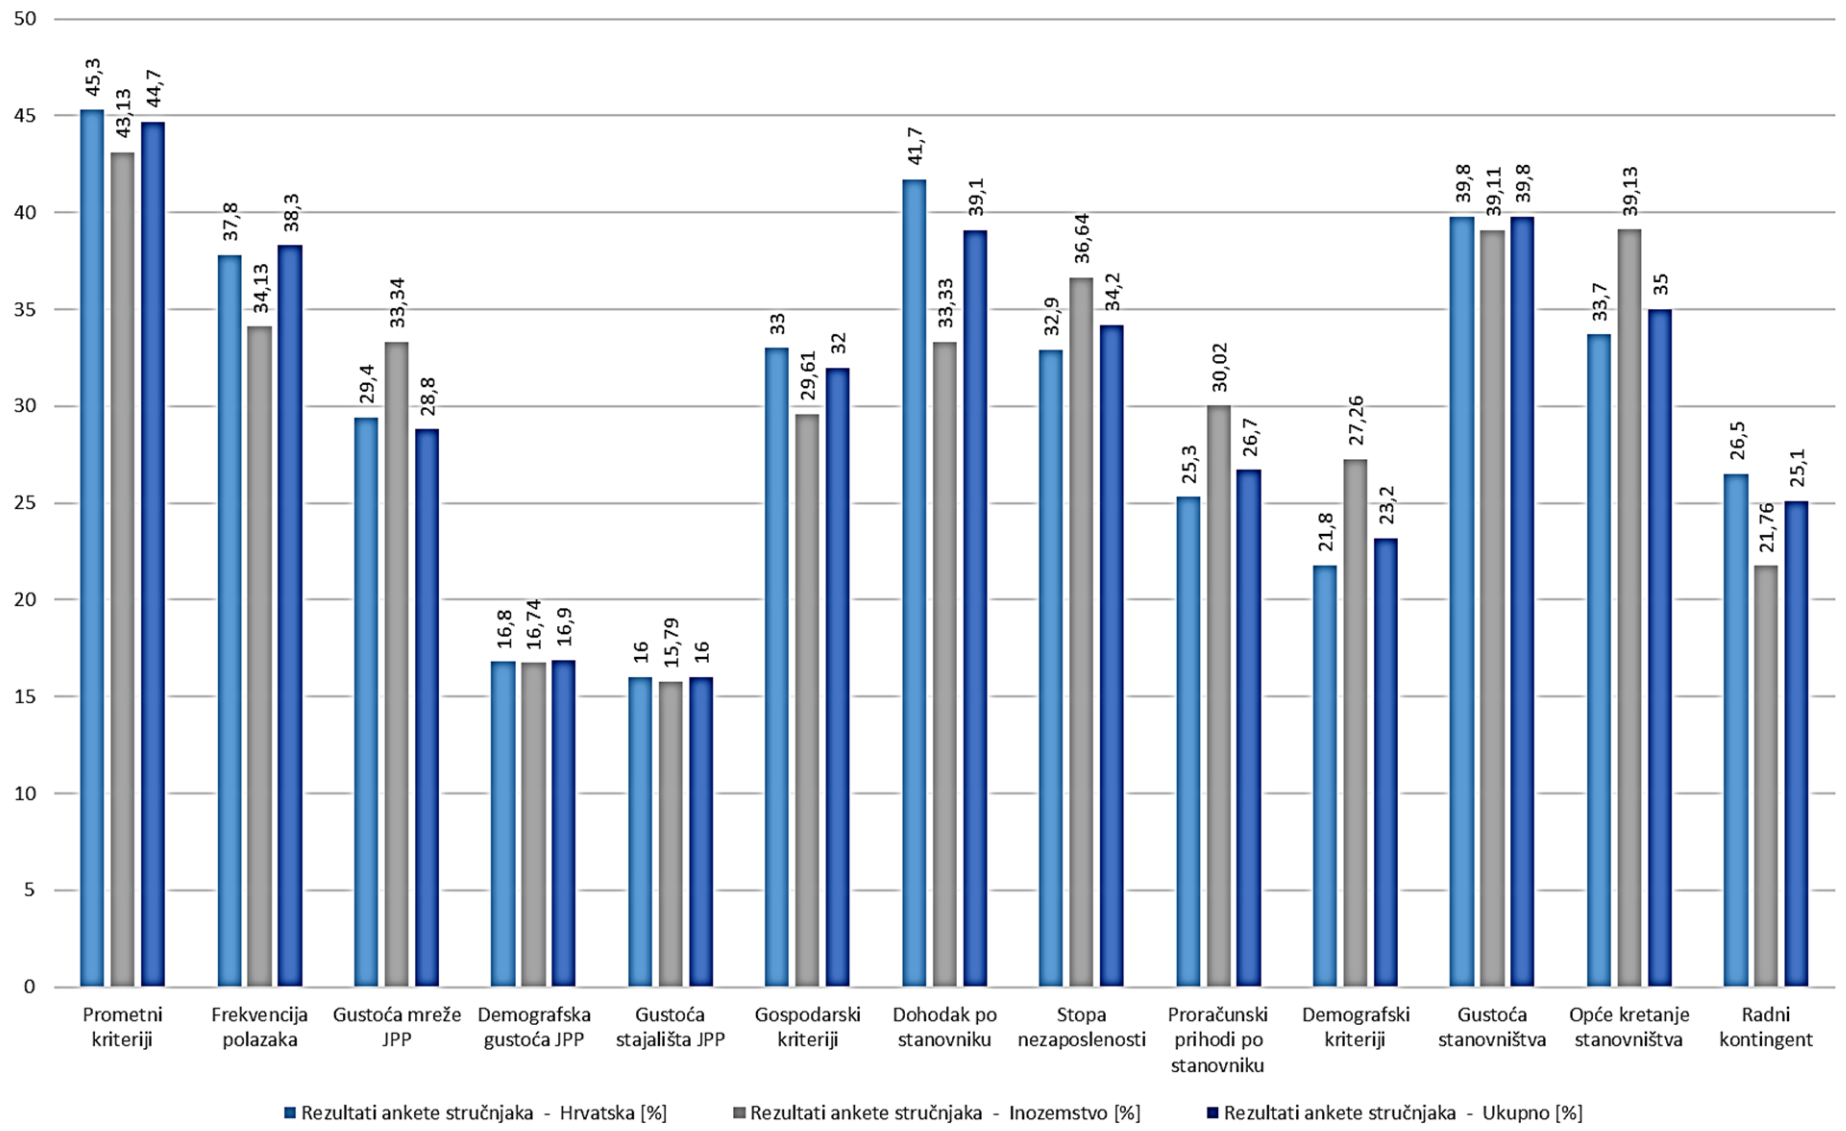

Slika 26. Usporedni rezultati vrednovanja kriterija i potkriterija stručnjaka iz Republike Hrvatske, stručnjaka iz inozemstva i ukupnih rezultata

„Progress is impossible without change, and

those who cannot change their minds cannot change anything."

George Bernard Shaw

6. Model pravičnoga tarifnoga sustava u integriranom prijevozu putnika

U prethodnom su poglavlju dobiveni težinski koeficijenti utvrđenih pravičnih kriterija i potkriterija, što je preduvjet za izradu modela pravičnoga tarifnoga sustava u integriranom prijevozu putnika. U ovom je poglavlju razvijen model pravičnoga tarifnoga sustava u integriranom prijevozu putnika. On predstavlja nadogradnju osnovnoga matematičkoga modela za izračun cijene jednokratnoga putovanja unutar zone uvođenjenjem koeficijenta pravičnosti. Time se postiže promjena iz jednakosti u pravičnost i cjenovna regulacija s gledišta jednake prometne, gospodarske i demografske razvijenosti svake pojedine tarifne zone u integriranom prijevozu putnika.

U javnom prijevozu putnika, kao i u njegovom konceptu integriranoga prijevoza putnika, postoji nekoliko načina za definiranje cijena prijevoznih usluga od kojih su najpopularniji sljedeći [21]:

- relacijski tarifni sustav
- jedinstveni tarifni sustav
- zonski tarifni sustav.

Relacijski se tarifni sustav temelji na duljini putovanja putnika i određen je udaljenošću između stajališta s kojega putnik kreće na putovanje i stajališta na kojemu putnik završava putovanje javnim prijevozom. Smatra se poštenim jer se za kilometarski dulje putovanje plaća veća cijena prijevozne usluge.

Jedinstveni se tarifni sustav smatra najjednostavnijim tarifnim sustavom zbog toga što je cijena ista za sva putovanja neovisno o prijeđenoj udaljenosti na putovanju. Ne smatra se poštenim jer kratka putovanja između dvaju susjednih stajališta imaju istu cijenu kao i dulja putovanja unutar takvoga sustava.

Zonski tarifni sustav karakterizira podjela područja primjene takvoga tarifnoga sustava na potpodručja koja mogu biti dizajnirana u obliku koncentričnih krugova, saća i ostalih nepravilnih oblika koji se određuju prema raznim parametrima. Cijena u zonskom tarifnom sustavu ovisi o broju prijeđenih zona unutar putovanja i o cijenama svake zone pojedinačno. Unutar zonskoga tarifnoga sustava cijena svake zone može se pojedinačno odrediti dizajniranjem zonskoga tarifnoga sustava na dva načina:

- naplatom s arbitrarnim cijenama
- naplatom zbrajanjem zona.

Zonski tarifni sustav naplate s arbitrarnim cijenama opisuje proizvoljno određivanje cijena za svaki par zona unutar kojih se nalazi stajalište s kojega putnik započinje i završava putovanje. Druga je varijanta zonski tarifni sustav naplate zbrajanjem zona koji opisuje ovisnost o broju prijeđenih zona i ista cijena za putovanja unutar istoga broja prijeđenih zona neovisno o kojim se zonama unutar sustava radi.

Zonski tarifni sustavi moraju što preciznije predstavljati cijene relacijskoga tarifnoga sustava [21] koji se smatra najpoštenijim u odnosu na ostale, što je izrazito važno kod prelaska s relacijskoga na zonski sustav. Prelaskom s relacijskoga na zonski tarifni sustav ne smije biti umanjen profit koji se ostvaruje prijevozom putnika, a isto tako ne smije doći do povećanja cijene koja bi uzrokovala smanjenje potražnje.

Analiziranjem radova o dizajniranju zonskoga tarifnoga sustava u javnom prijevozu [15, 57 – 62] dolazi se do niza načina za određivanje cijene tarifne zone za koju svako prijevozničko nadležno tijelo određuje uvijete unutar matematičkih modela. To je posebice naglašeno kod arbitrarnoga modela kod kojega prijevozničko tijelo proizvoljno određuje cijenu svake zone. Svi se modeli temelje na određivanju rubova svake pojedine tarifne zone i udaljenosti stajališta u javnom prijevozu koja se nalaze unutar tarifnih zona. Cijena tarifne zone oblikuje se na temelju izrade matrice mogućih putovanja korisnika unutar zone i uvođenja cijene putovanja po kilometru koja je bila korištena u dotada korištenom relacijskom tarifnom sustavu. Svrha je navedenoga težnja za izračunom cijene tarifne zone u kojoj neće biti velikih odstupanja od prijašnje cijene zbog činjenice da se relacijski tarifni sustav općenito smatra najpoštenijim.

Kako bi tarifni sustav bio pravičan, potrebno je tarifne zone svesti na najmanju teritorijalnu jedinicu za koju se mogu odrediti i utvrditi pravični kriteriji i potkriteriji. Time se tarifne zone svode na teritorijalnu razinu naselja koja unutar sebe imaju uslugu javnoga prijevoza putnika i za koja se mogu odrediti vrijednosti ranije navedenih kriterija i potkriterija.

Osnovni i općeniti matematički model za izračun cijene jednokratnoga putovanja unutar zone [14, 57] glasi:

$$p_z^{ST}(y) = p^b + p^{pk} \cdot l_p, \tag{19.}$$

pri čemu je:

$p_z^{ST}(y)$ – cijena zonske karte za jednokratno putovanje (ST) unutar zone (y)

p^b – osnovna cijena

p^{pk} – cijena po kilometru

l_p – srednja duljina linije unutar zone.

Osnovnu je cijenu odredilo svako nadležno prijevozničko tijelo i temelji se na određivanju dijela cijene tarifne zone koja je neovisna o duljini linija javnoga prijevoza te predstavlja fiksni trošak putovanja unutar tarifne zone. Cijenu po kilometru također je odredilo prijevozničko nadležno tijelo. Ona predstavlja varijabilni trošak u pružanju usluge javnoga prijevoza putnika sadržavajući u sebi jedinične troškove osoblja, energenata i sl. Veliki značaj u cijeni po kilometru ima degresivnost cijena koja se javlja s prelaskom većega broja kilometara, odnosno s prelaskom više tarifnih zona. Duljina linije unutar zone predstavlja srednju duljinu putovanja unutar zone. Ona je kod tarifnih zona u brojnim ruralnim područjima jednostavna za izračun jer su ruralna područja često pokrivena jednom prijevoznom linijom i njezina duljina predstavlja referentnu srednju duljinu putovanja unutar zone. Ako tarifna zona, u ovom slučaju naselje, ima više prijevoznih linija [58], onda se srednja duljina linije unutar zone, odnosno srednja duljina putovanja korisnika javnoga prijevoza promatra kao medijalna vrijednost duljina prijevoznih linija promatrana prema rubovima tarifnih zona, odnosno naselja. Nakon svake je promjene iz relacijskoga u zonski tarifni sustav potrebno provjeriti različitost u cijeni za moguća putovanja korisnika te utvrditi njihovu sličnost, odnosno težnju da se napravi pravični zonski tarifni sustav kao što je relacijski.

Za izračun pravičnoga tarifnoga modela u integriranom prijevozu putnika te izračun cijene jednokratnoga putovanja unutar zone $p_{ez}^{ST}(y)$ osnovnom je modelu uveden koeficijent pravičnosti C_e te matematički model glasi:

$$p_{ez}^{ST}(y) = \left[(p^b + p^{pk} \cdot l_p)\right] \cdot C_e \qquad (20.)$$

Koeficijent pravičnost C_e omogućuje regulaciju cijene tarifne zone i promjene iz jednakosti u pravičnost. Jednaka je dostupnost kod dosadašnjih tarifnih sustava predstavljena kao jednaka cijena po kilometru za svakoga korisnika prijevozne usluge, dok se uvođenjem koeficijenta pravičnosti jednaka dostupnost razmatra s gledišta jednake prometne, gospodarske i demografske razvijenosti područja koja su obuhvaćena javnim prijevozom, odnosno naselja kao tarifne zone. Koeficijent pravičnosti u pravičnom tarifnom modelu kreće se između 0 i 2. Ako je njegova vrijednost ispod srednje vrijednost 1, on predstavlja koeficijent umanjenja za slabije razvijena područja, a ako je iznad 1, predstavlja koeficijent uvećanja za razvijenija

područja. Time se postiže davanje dodatnoga značaja tarifnim zonama u nepovoljnijem položaju s ciljem izjednačavanja i omogućavanja pravičnosti.

Koeficijent pravičnosti C_e određuje se matematičkim izrazom:

$$C_e = e_{cpT} \cdot w_{cT} + e_{cpE} \cdot w_{cE} + e_{cpD} \cdot w_{cD} \,, \tag{21.}$$

pri čemu je:

C_e – koeficijent pravičnosti

e_{cpT} – parametar pravičnoga kriterija PROMET

w_{cT} – težinski koeficijent kriterija PROMET

e_{cpE} – parametar pravičnoga kriterija GOSPODARSTVO

w_{cE} – težinski koeficijent kriterija GOSPODARSTVO

e_{cpD} – parametar pravičnoga kriterija DEMOGRAFIJA

w_{cD} – težinski koeficijent kriterija DEMOGRAFIJA.

Težinski su koeficijenti kriterija promet, gospodarstvo i demografija određeni vrednovanjem kriterija u 5. poglavlju doktorskoga rada koje su izvršili stručnjaci iz navedenih područja, dok parametri pravičnih kriterija promet, gospodarstvo i demografija predstavljaju zbrojeve umnožaka parametara njihovih potkriterija i težinskih koeficijenata potkriterija:

$$e_{cpT} = \sum_{i=1}^{4} e_{spi} \cdot w_{sci} \tag{22.}$$

$$e_{cpE} = \sum_{i=5}^{7} e_{spi} \cdot w_{sci} \tag{23.}$$

$$e_{cpD} = \sum_{i=8}^{10} e_{spi} \cdot w_{sci} \ , \qquad (24.)$$

pri čemu je:

e_{cpT} – parametar pravičnoga kriterija PROMET

e_{spi} – parametar pravičnoga potkriterija

w_{sci} – težinski koeficijent potkriterija

e_{cpE} – parametar pravičnoga kriterija GOSPODARSTVO

e_{cpD} – parametar pravičnoga kriterija DEMOGRAFIJA.

Parametri pravičnih potkriterija e_{spi} i njihovi težinski koeficijenti w_{sci} odnose se na potkriterije koji su utvrđeni u 4. poglavlju. Prikazani su u Tablici 11.

Tablica 11. Prikaz pravičnih kriterija i potkriterija s njihovim težinskim koeficijentima

i	Potkriterij	Težina	Kriterij	Težina
1.	frekvencija polazaka	0,38	promet	0,45
2.	gustoća mreže	0,29		
3.	demografska gustoća	0,17		
4.	gustoća stajališta	0,16		
5.	dohodak po stanovniku	0,39	gospodarstvo	0,32
6.	stopa nezaposlenosti	0,34		
7.	proračunski prihodi po stanovniku	0,27		
8.	gustoća stanovništva	0,40	demografija	0,23
9.	opće kretanje stanovništva	0,35		
10.	radni kontingent	0,25		

Parametar svakoga pravičnoga potkriterija određuje se matematičkim izrazom:

$$e_{spi} = \begin{cases} \dfrac{x_i - x_{Me}}{\max(x_i) - x_{Me}} + 1 & , \quad x_i > x_{Me} \\ 1 - \dfrac{x_i - x_{Me}}{\min(x_i) - x_{Me}} & , \quad x_i < x_{Me} \\ 1 & , \quad x_i = x_{Me} \end{cases} , \qquad (25.)$$

pri čemu je:

e_{spi} – parametar pravičnoga potkriterija

x_i – vrijednost potkriterija u zoni

x_{Me} – srednja vrijednost potkriterija na mreži (medijan)

$\max(x_i)$ – najveća vrijednost potkriterija na mreži

$\min(x_i)$ – najmanja vrijednost potkriterija na mreži.

Kako bi se mogao odrediti parametar svakoga pojedinoga pravičnog potkriterija unutar zone, potrebno je napraviti analizu vrijednosti svakoga naselja, odnosno zone na mreži te odrediti najveću $\max(x_i)$ i najmanju $\min(x_i)$ vrijednost potkriterija na mreži, vrijednost potkriterija unutar zone x_i i srednju položajnu, odnosno medijalnu vrijednost potkriterija x_{Me} na mreži.

Medijan je [63] vrijednost obilježja koja se nalazi u sredini niza čiji su podatci uređeni po veličini od najmanje do najveće vrijednosti, odnosno vrijednost koja čitav niz podataka dijeli na dva jednakobrojna dijela tako da jedna polovina ima manju, a druga polovina veću vrijednost od medijana. Predstavlja položajnu srednju vrijednost. Za razliku od aritmetičke sredine na vrijednost medijana ne utječu ekstremne vrijednosti obilježja zbog čega je pogodna kao srednja vrijednost u rasporedima frekvencija s otvorenim intervalima. Općenito, ako vrijednosti obilježja u distribuciji znatno variraju, medijan je bolja mjera centralne tendencije od aritmetičke sredine. Stoga je medijalna srednja vrijednost idealna za podjelu kriterija razvijenosti na dva dijela koja će prikazati razliku između razvijenijih i nerazvijenijih naselja,

odnosno zona. U navedenom je matematičkom izrazu (25.) parametar svakoga pravičnoga potkriterija određen funkcijom u kojoj se on dobiva na temelju vrijednosti potkriterija u zoni x_i. Ako je x_i jednak medijalnoj srednjoj vrijednosti potkriterija na mreži x_{Me}, onda je njegova vrijednost 1 i predstavlja srednju vrijednost na mreži čime je pravičnost osigurana bez potrebe za smanjenjem ili uvećanjem cijene prema osnovnom matematičkom modelu. Kada je x_i manji od medijalne srednje vrijednosti potkriterija na mreži, onda se njegova vrijednost izračunava na temelju drugoga dijela funkcije matematičkoga modela (25.) unutar kojega se vrijednost parametra pravičnoga potkriterija e_{spi} kreće između medijalne vrijednosti i najmanje vrijednosti potkriterija na mreži $\min(x_i)$. Ovisno o navedenim vrijednostima on se kreće u granicama između 0 i 1. Time se dobiva koeficijent umanjenja za naselja manje razvijenosti od srednje razvijenih naselja, odnosno medijana razvijenosti. Ukoliko je x_i veći od srednje vrijednosti potkriterija na mreži x_{Me}, onda se njegova vrijednost izračunava na temelju prvoga dijela funkcije matematičkoga modela (25) unutar kojega se vrijednost parametra pravičnoga potkriterija e_{spi} kreće između medijalne vrijednosti i najveće vrijednosti potkriterija na mreži $\max(x_i)$. Ovisno o navedenim vrijednostima on se kreće u granicama između 1 i 2. Time se dobiva koeficijent uvećanja za naselja veće razvijenosti od srednje razvijenih naselja, odnosno medijana razvijenosti.

Uvrštavanjem vrijednosti u model dobiva se koeficijent pravičnosti C_e u granicama između 0 i 2 koji regulira cijenu tarifne zone na temelju vrijednosti pravičnih kriterija i potkriterija zone, odnosno njezine razvijenosti u odnosu na sve zone u mreži. Time se postiže promjena iz jednakosti u pravičnost, odnosno cjenovna regulacija s gledišta jednake prometne, gospodarske i demografske razvijenosti područja koja su obuhvaćena javnim prijevozom, odnosno naselja kao tarifne zone.

„Testing a product is a learning process"

Brian Marick

7. Testiranje modela

Točnost modela utvrđuje se testiranjem na konkretnoj studiji slučaja. Zbog bolje vizualizacije demografskih, gospodarskih i prometnih različitosti unutar županije testiranje se provodi na županiji koja je svrstana u najnižu skupinu razvijenosti. Model pravičnoga tarifnoga sustava sa svojim rezultatima u konkretnoj studiji slučaja daje prikaz promjene u odnosu na osnovni tarifni sustav, odnosno prikaz promjene u kojoj naplata javnoga prijevoza putnika postaje pravična. Osim usporedne analize rezultata osnovnoga i pravičnoga tarifnoga sustava na studiji slučaja u ovom se poglavlju nalazi i diskusija dobivenih rezultata.

7.1. Metodologija testiranja modela

Uspostava modela pravičnoga tarifnoga sustava u integriranom prijevozu putnika zahtijeva niz organizacijskih, zakonodavnih i društvenih izazova kojima prethodi kvalitetna analiza mogućnosti njegove primjene, no ponajprije je potrebno testirati model na konkretnoj studiji slučaja. Također, u doktorskom je radu postavljena temeljna znanstvena hipoteza koja kaže kako je moguće izraditi model pravičnoga tarifnoga sustava u integriranom prijevozu putnika na temelju novodefiniranih pravičnih kriterija. Kako bi se dokazala znanstvena hipoteza, odnosno znanstveno utemeljena pretpostavka, potrebno ju je testirati kroz rezultate znanstvenoga istraživanja. Primjenom modela pravičnoga tarifnoga sustava na konkretnoj studiji slučaja znanstvena se hipoteza može dokazati ili opovrgnuti kroz analizu rezultata znanstvenoga istraživanja studije slučaja.

U Republici Hrvatskoj nema potpune integracije javnoga prijevoza putnika, stoga je implementaciju modela moguće testirati uvođenjem tarifne integracije postojeće organizacije javnoga prijevoza putnika. Tarifna integracija kao jedna od ključnih stavaka pri uvođenju integriranoga prijevoza putnika predstavlja osnovu za potpunu integraciju svih načina prijevoza na nekom području [64 – 66].

U svrhu testiranja modela potrebno je izabrati jednu od županija u Republici Hrvatskoj. Zbog bolje vizualizacije demografskih, gospodarskih i prometnih različitosti unutar županije odabir županije potrebno je napraviti iz I. skupine jedinica područne (regionalne) samouprave prema *Odluci o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti* [67], a koja predstavlja najniže rangiranu skupinu razvijenosti. Unutar I. skupine nalaze se Bjelovarsko-bilogorska županija, Brodsko-posavska županija, Ličko-senjska županija, Sisačko-moslavačka županija, Virovitičko-podravska županija i Vukovarsko-srijemska županija. Sisačko-moslavačka županija, čija je vrijednost indeksa razvijenosti manja od 75 % prosjeka Republike Hrvatske, predstavlja pogodno područje za primjenu modela pravičnoga tarifnoga sustava u integriranom prijevozu putnika i njegovo testiranje.

Kako bi se postiglo testiranje modela unutar Sisačko-moslavačke županije, u prvoj je etapi potrebno napraviti detaljnu analizu pravičnih kriterija i potkriterija, odnosno analizu demografskih, gospodarskih i prometnih pokazatelja koji su navedeni u ranijim poglavljima na razini naselja koja imaju organiziran javni putnički prijevoz. Njihovim se uvođenjem u model

pravičnoga tarifnoga sustava dobiva izračun koeficijenta pravičnosti koji regulira osnovni, odnosno općeniti matematički model za izračun cijene jednokratnoga putovanja unutar zone.

Druga etapa predstavlja analizu ostalih parametara unutar osnovnoga matematičkoga modela za izračun cijene jednokratnoga putovanja unutar zone, odnosno analizu osnovne cijene, cijene po kilometru i srednje duljine linije unutar zone.

Treća je i konačna etapa analiza rezultata cijena zonskih karata za jednokratno putovanje unutar zone, odnosno naselja te potvrda provedenoga znanstvenoga istraživanja s ciljem dokazivanja hipoteze.

7.2. Geografske značajke Sisačko-moslavačke županije

Sisačko-moslavačka županija nalazi se u južnom dijelu središnjega dijela Republike Hrvatske. Graniči sa Zagrebačkom, Karlovačkom, Bjelovarsko-bilogorskom, Brodsko-posavskom i Požeško-slavonskom županijom, a na jugu državnom granicom s Bosnom i Hercegovinom (Slika 27.). U prometnom smislu predstavlja prometno čvorište zbog povoljnoga prirodnoga i prometno-geografskoga položaja. Smještena je na sjecištu dvaju značajnih cestovnih i željezničkih prometnih pravaca: Posavskoga koridora, koji povezuje Zagreb i Slavonski Brod, odnosno zemlje zapadne i srednje Europe s jugoistočnom Europom i Bliskim istokom, te prometnoga pravca koji povezuje Mađarsku i Podravinu s Hrvatskim primorjem i Mediteranom. Sa svojom površinom od 4468 km^2 ubraja se među najveće županije u Republici Hrvatskoj te zauzima oko 7,9 % kopnenoga teritorija Republike Hrvatske. Prema trenutačnom je teritorijalnom ustroju podijeljena na 19 jedinica lokalne samouprave koje čini 7 gradova (Sisak, Glina, Hrvatska Kostajnica, Kutina, Novska, Petrinja i Popovača), 12 općina (Donji Kukuruzari, Dvor, Gvozd, Hrvatska Dubica, Jasenovac, Lekenik, Lipovljani, Majur, Martinska Ves, Popovača, Sunja, Topusko i Velika Ludina) te 456 naselja [68]. Političko, administrativno, gospodarsko i kulturno središte županije jest Grad Sisak. Prema indeksu razvijenosti Sisačko-moslavačka županija uvrštena je u I. skupinu jedinica područne (regionalne) samouprave čija je vrijednost indeksa razvijenosti manja od 75 % prosjeka Republike Hrvatske.

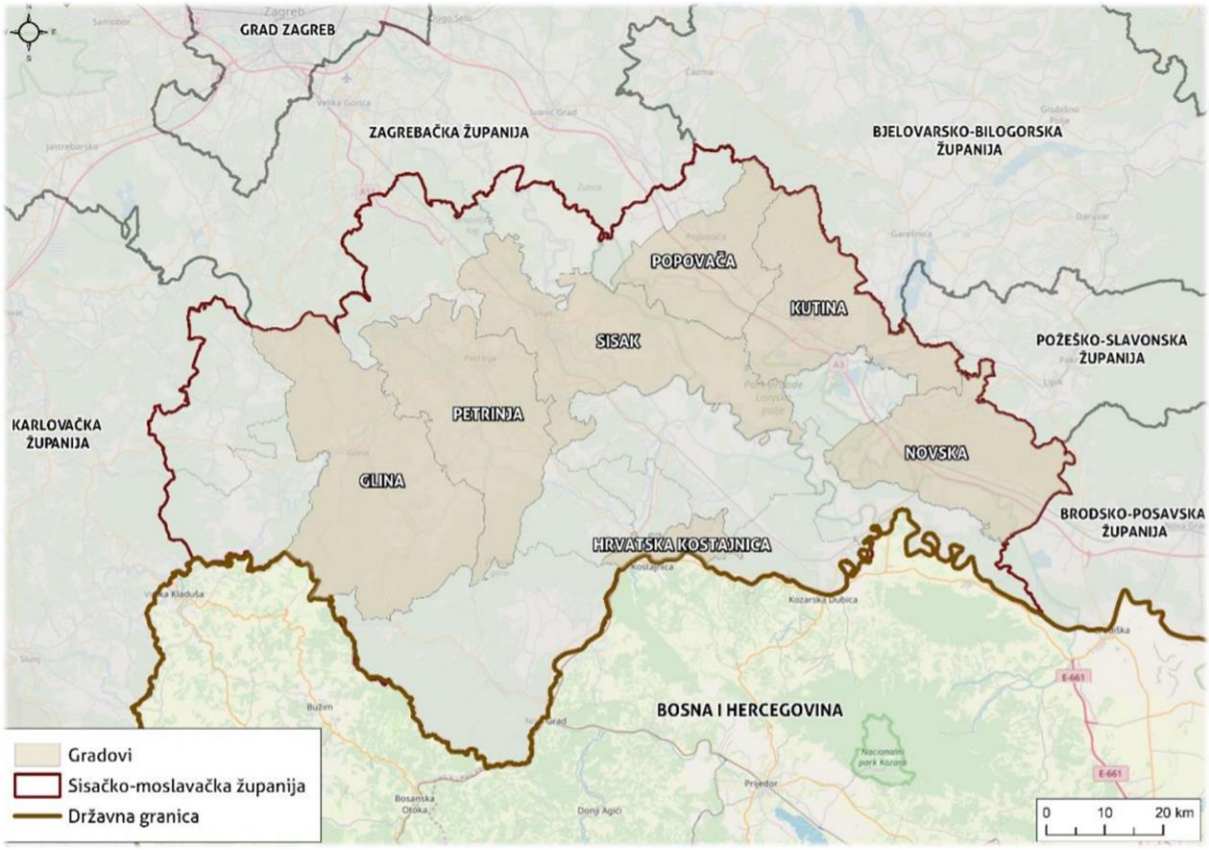

Slika 27. Položaj Sisačko-moslavačke županije u odnosu na granične županije [69]

Prema posljednjem popisu stanovništva iz 2011. godine na području Sisačko-moslavačke županije živi 172 439 stanovnika, što predstavlja 4,02 % ukupnoga stanovništva u Republici Hrvatskoj. Gustoća naseljenosti iznosi 38,60 st/km², što je osjetno manje od prosjeka Republike Hrvatske koji iznosi 75,70 st/km². Sisačko-moslavačku županiju karakterizira neravnomjerna naseljenost koja je izražena gustom naseljenošću gradskih sredina (Sisak, Petrinja, Kutina, Novska) te znatno slabijom naseljenošću ruralnih sredina. Slaba je naseljenost ruralnih naselja posebno izražena na području općina Dvor, Jasenovac, Topusko, Gvozd, Hrvatska Dubica i Donji Kukuruzari gdje su poneka ruralna naselja potpuno nenaseljena. Takav problem neravnomjerne naseljenosti uzrokuje i znatne razlike u stupnju razvijenosti pojedinih dijelova Županije. Ukupno je demografsko kretanje na području Sisačko-moslavačke županije negativno, tj. broj stanovnika stalno se smanjuje, tako se broj stanovnika između popisa stanovništva iz 2001. godine i popisa stanovništva iz 2011. godine smanjio za 6,98 %. Glavni se uzroci takvoga depopulacijskoga kretanja mogu pripisati iseljavanju mladih osoba u potrazi za radnim mjestom, ali i otprije izraženom procesu deruralizacije.

U razlikovanju ruralnih i urbanih područja u Hrvatskoj se primjenjuje kriterij *Organizacije za gospodarsku suradnju i razvoj* (OECD-a) koji je zasnovan na gustoći naseljenosti. Prag koji dijeli ruralna od urbanih područja jest 150 stanovnika na km^2. Prema kriterijima OECD-a područje Županije (Slika 28.) pripada u pretežno ruralne regije s oko 7 % urbanih naselja u kojima živi oko 53 % stanovništva. Zbog veličine i geografskih obilježja te zbog gustoće naseljenosti u Sisačko-moslavačkoj županiji prisutna su značajna razvojna ograničenja, posebno u pogledu razvijenosti i povezanosti općina s većim gradskim središtima [70].

Kartogram je podjele Županije na naselja izvorno dobiven od Zavoda za prostorno uređenje Sisačko-moslavačke županije, dok su svi dodatni podatci, koji su uneseni tijekom istraživanja, značajno utjecali na konačni izgled kartograma. Kartogrami su napravljeni u računalnom alatu *AutoCAD*.

Glavne su gospodarske djelatnosti na području Županije industrija (energetika, naftna industrija, petrokemija i kemijska industrija, metalurgija i metaloprerađivačka industrija, prehrambena industrija), poljoprivreda i šumarstvo, trgovina, ugostiteljstvo, graditeljstvo, promet i veze. U manjoj su mjeri zastupljene i ostale gospodarske djelatnosti i obrtništvo.

Prometna se povezanost u putničkom prijevozu unutar Županije odnosi na cestovni i željeznički promet. Cestovna se infrastruktura sastoji od dviju autocesta, A3 (Bregana – Zagreb – Kutina – Novska – Lipovac) i A11 (Zagreb – Sisak) ukupnih duljina 48,1 km te 11 km, 9 državnih cesta ukupne duljine 385 km, 68 županijskih cesta duljine 668 km, 160 lokalnih cesta ukupne duljine 640 km te nekoliko km nerazvrstanih cesta. Željeznička infrastruktura unutar Županije sadrži međunarodne, regionalne i lokalne pruge. Međunarodne su pruge: M 103 Dugo Selo – Novska ukupne duljine 50,9 km, M 104 Novska – Vinkovci – Tovarnik – DG (Šid) duljine 14,5 km i M 502 Zagreb GK – Sisak – Novska duljine 91,3 km. Važna je željeznička pruga za regionalni promet R 102 Sunja – Volinja – DG duljine 21,57 km. Unutar Županije su i lokalne pruge L 204 Banova Jaruga – Pčelić duljine 6,65 km i L 210 Sisak Caprag – Petrinja duljine 11,01 km, koja je zatvorena za promet 1991. godine [71,72]. Cestovna je i željeznička infrastruktura na urbanim i ruralnim područjima Sisačko-moslavačke županije prikazana na Slici 29.

Javni prijevoz putnika unutar Županije obavljaju tri prijevoznika od kojih su dva u autobusnom prijevozu (Auto promet Sisak i Čazmatrans – Nova) i jedan u željezničkom prijevozu (HŽ Putnički prijevoz). Grad Sisak kao središte županije jedini ima razvijen gradski

prijevoz koji obavlja autobusni prijevoznik Auto promet Sisak na 5 linija gradskoga prometa. Osim navedenoga, Grad Sisak posjeduje i izgrađene biciklističke staze koje su značajan čimbenik u privlačenju turista i budućem razvoju integriranoga prijevoza putnika. Prema udjelu korištenja načina prijevoza tijekom putovanja u Gradu Sisku najveći su udio putovanja osobnim automobilima i pješačenjem, dok se u manjoj mjeri koristi javni prijevoz, bicikl i motocikl (Slika 30.).

Osim gradskoga prijevoza unutar Grada Siska, koji obavlja autobusni prijevoznik Auto promet Sisak, na području Županije obavlja se i javni prijevoz u prigradskom, županijskom i međužupanijskom prometu. Sve su linije javnoga prijevoza putnika u autobusnom i željezničkom prijevozu prikazane na Slici 31.

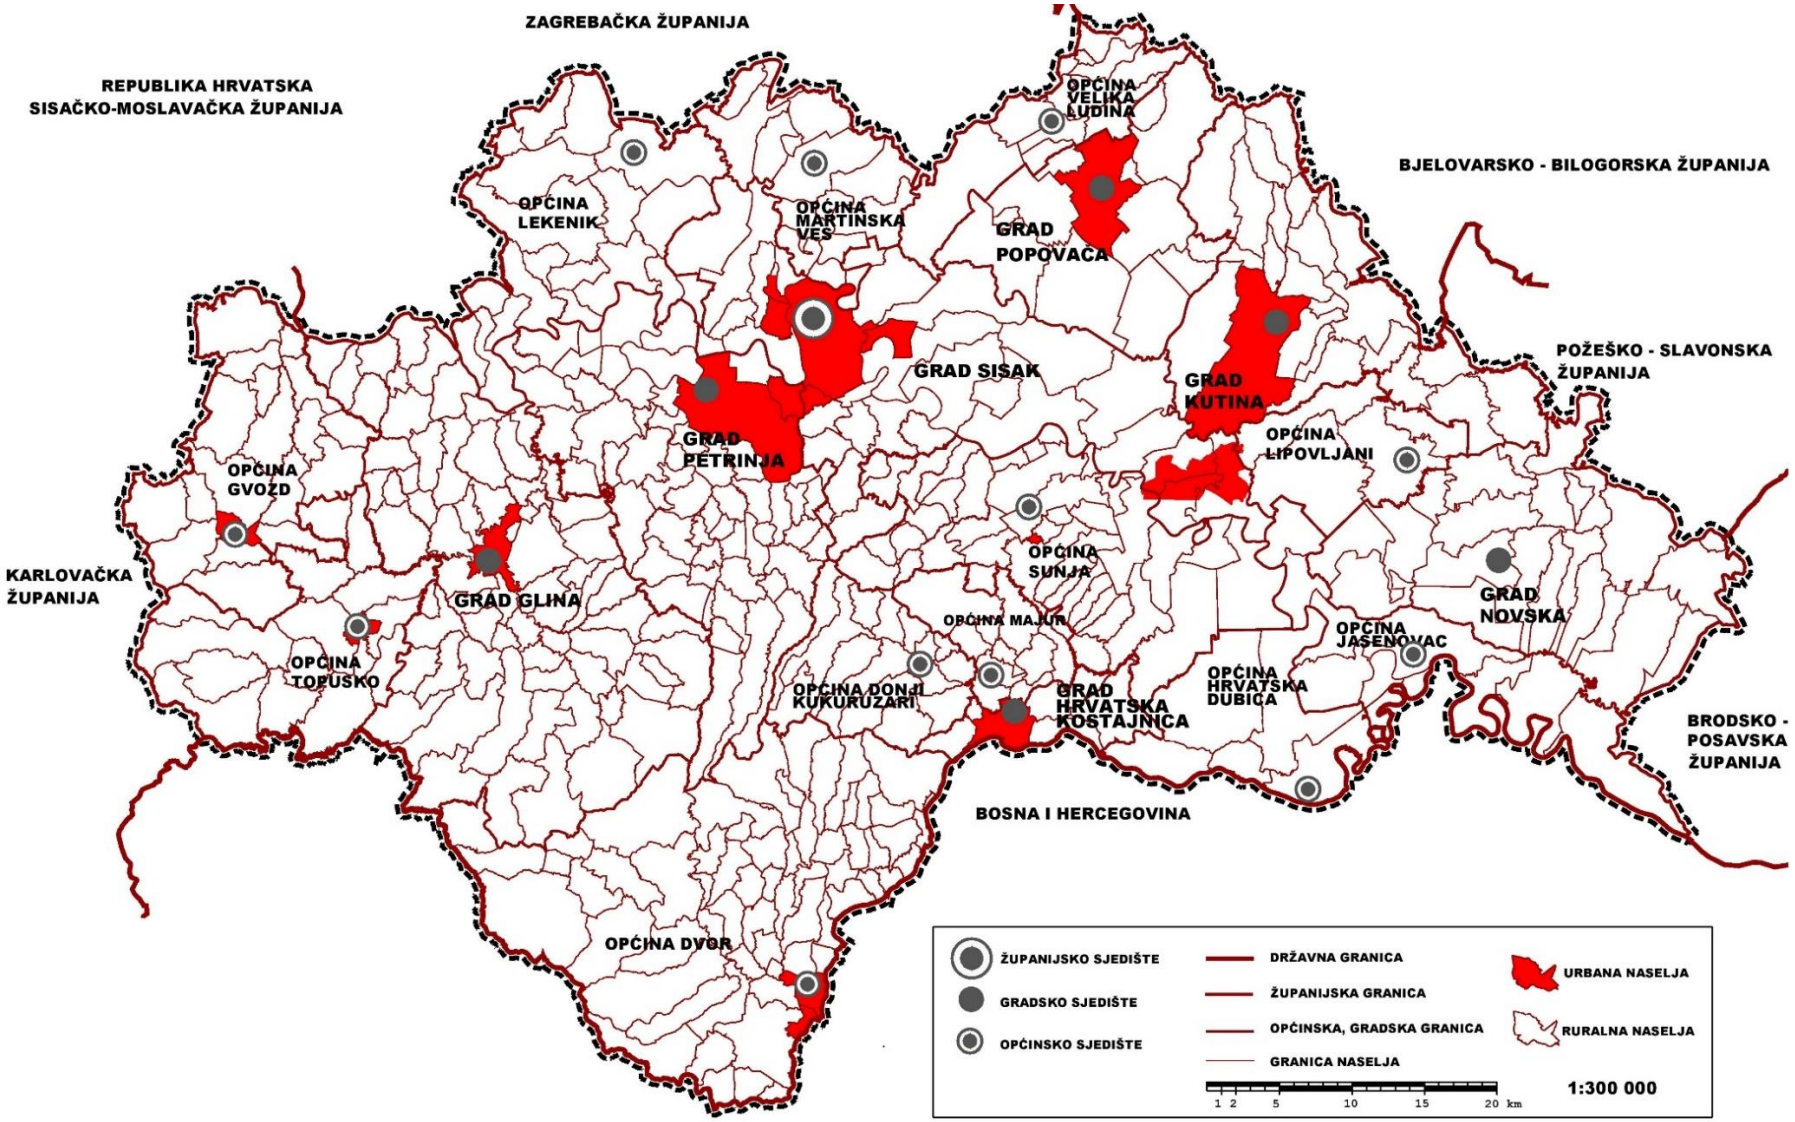

Slika 28. Podjela Sisačko-moslavačke županije na urbana i ruralna naselja [70]

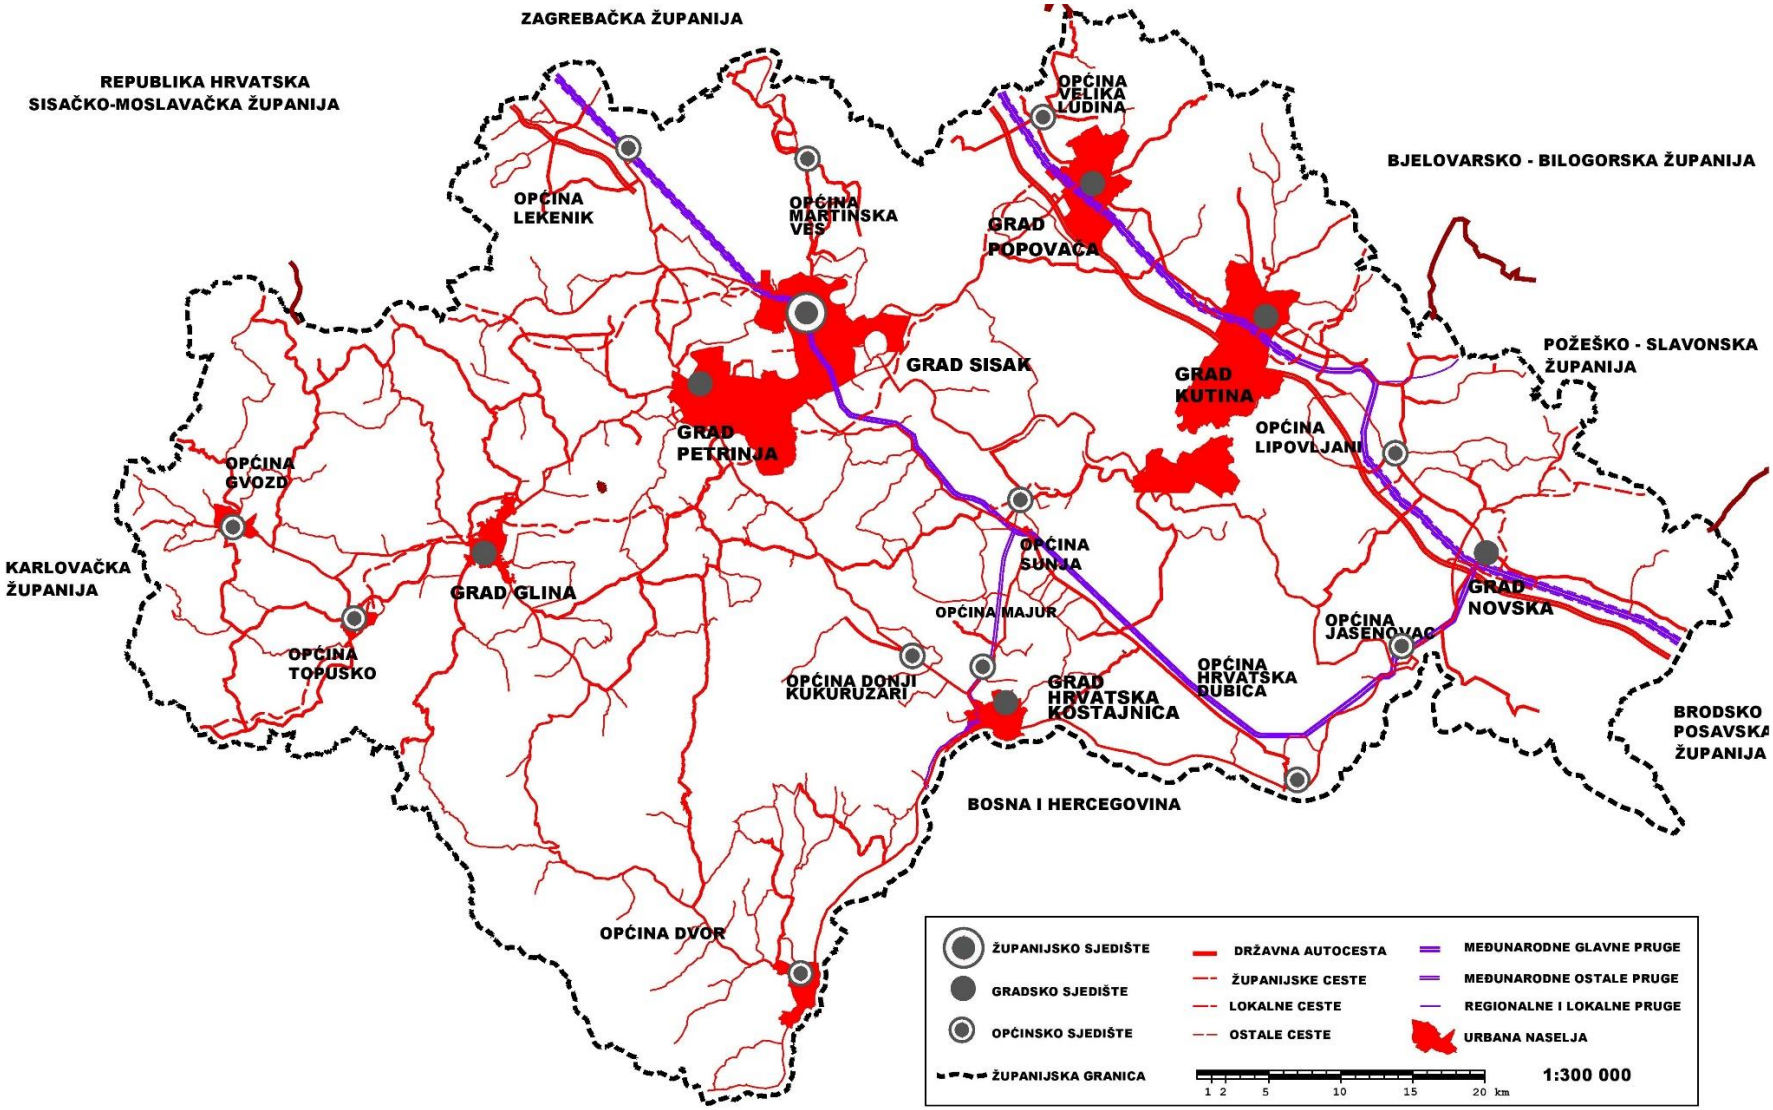

Slika 29. Cestovna i željeznička infrastruktura na području Sisačko-moslavačke županije s prikazom urbanih i ruralnih područja

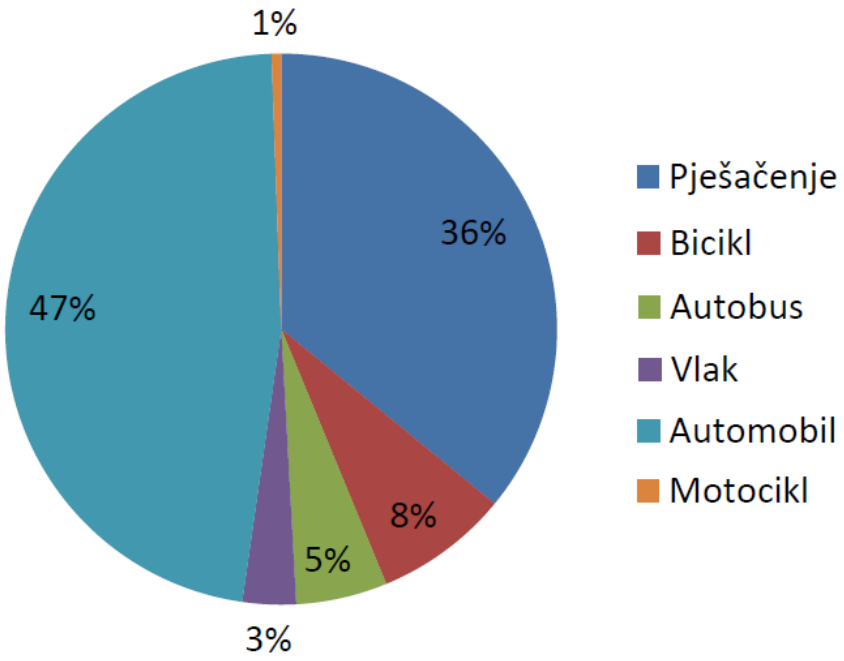

Slika 30. Udio korištenih načina prijevoza tijekom putovanja u Gradu Sisku [73]

Ukupna duljina autobusnih linija javnoga prijevoza unutar Sisačko-moslavačke županije iznosi 443,23 km, dok ukupna duljina željezničke infrastrukture na kojoj se obavlja javni prijevoz putnika iznosi 170,66 km.

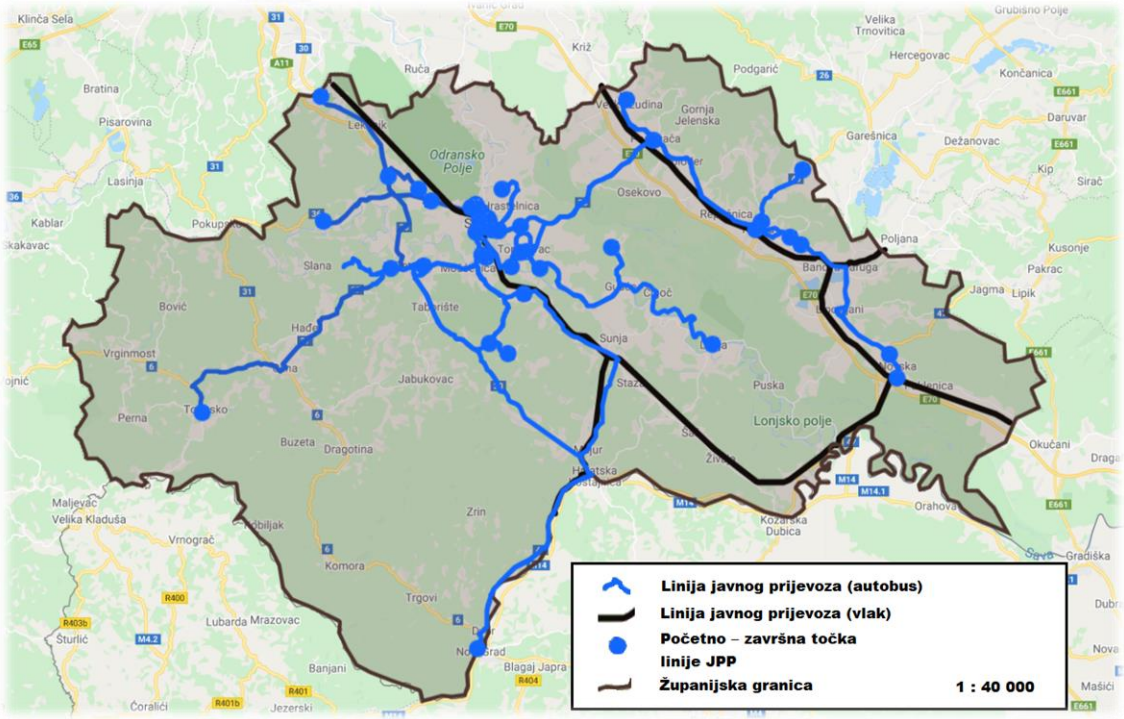

Slika 31. Linije javnoga prijevoza putnika u autobusnom i željezničkom prijevozu unutar Sisačko-moslavačke županije

Na području Županije nalaze se 242 stajališta za prihvat i otpremu putnika u autobusnom prijevozu te 35 stajališta u željezničkom prijevozu. Na Slici 32. prikazana su sva stajališta u javnom prijevozu putnika na području Županije. Crnim su krugom (oznaka vlaka) prikazana stajališta u željezničkom prometu koji obavlja prijevoznik HŽ Putnički prijevoz, dok su plavom i ružičastom bojom s oznakama autobusa u sredini kruga označena stajališta prijevoza koji obavljaju autobusni prijevoznici Auto promet Sisak (plava) i Čazmatrans – Nova (ružičasta). Unutar Grada Siska i na relaciji Sisak – Zagreb postoje stajališta koja su zajednička za autobusne prijevoznike.

S obzirom na postojanje javnoga prijevoza putnika unutar Županije koja se sastoji od 7 gradova, 12 općina te 456 naselja primjećuje se nepostojanje javnoga prijevoza putnika u Općini Gvozd i Martinska Ves. Ako se promatraju naselja, unutar Županije nema javnoga prijevoza putnika unutar 317 naselja. Na Slici 33. prikazana su naselja te cestovna i željeznička infrastruktura unutar kojih se obavlja javni prijevoz putnika i koje predstavljaju tarifne zone za uspostavu pravičnoga tarifnoga sustava unutar integriranoga prijevoza putnika. Integrirani je prijevoz putnika unutar Županije moguće uspostaviti unutar 139 naselja, 10 općina i 7 gradova.

Izrađen je i *Masterplan prometnoga razvoja Sisačko-moslavačke županije* kojemu je cilj promicanja lokalne i regionalne mobilnosti unutar Županije te koji predstavlja osnovu za daljnji održivi razvoj i planiranje projekata u području prometa koji su usmjereni na unaprjeđenje infrastrukture, poboljšanje operativne funkcionalnosti i povezanosti, povećanje razine dostupnosti i sigurnosti, smanjenje negativnoga utjecaja na okoliš, unaprjeđenje ekološke učinkovitosti i poboljšanje financijske održivosti prometnoga sustava.

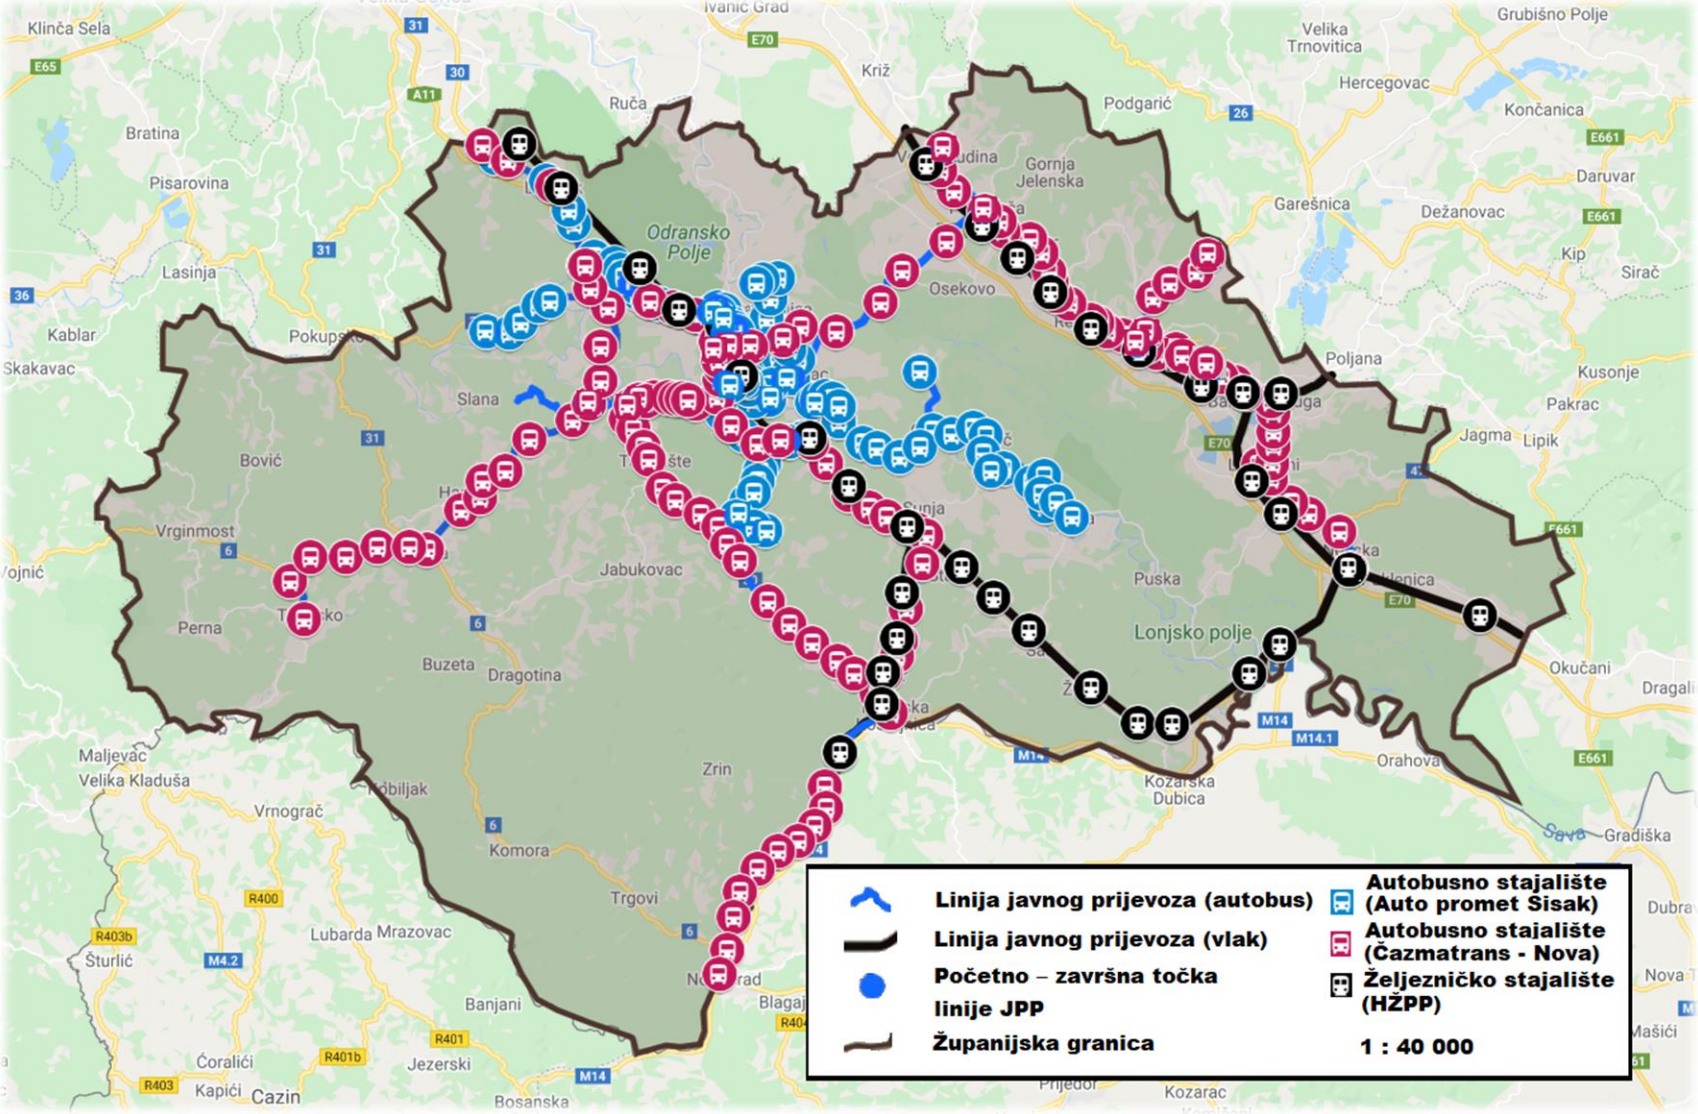

Slika 32. Stajališta javnoga prijevoza putnika u autobusnom i željezničkom prijevozu unutar Sisačko-moslavačke županije

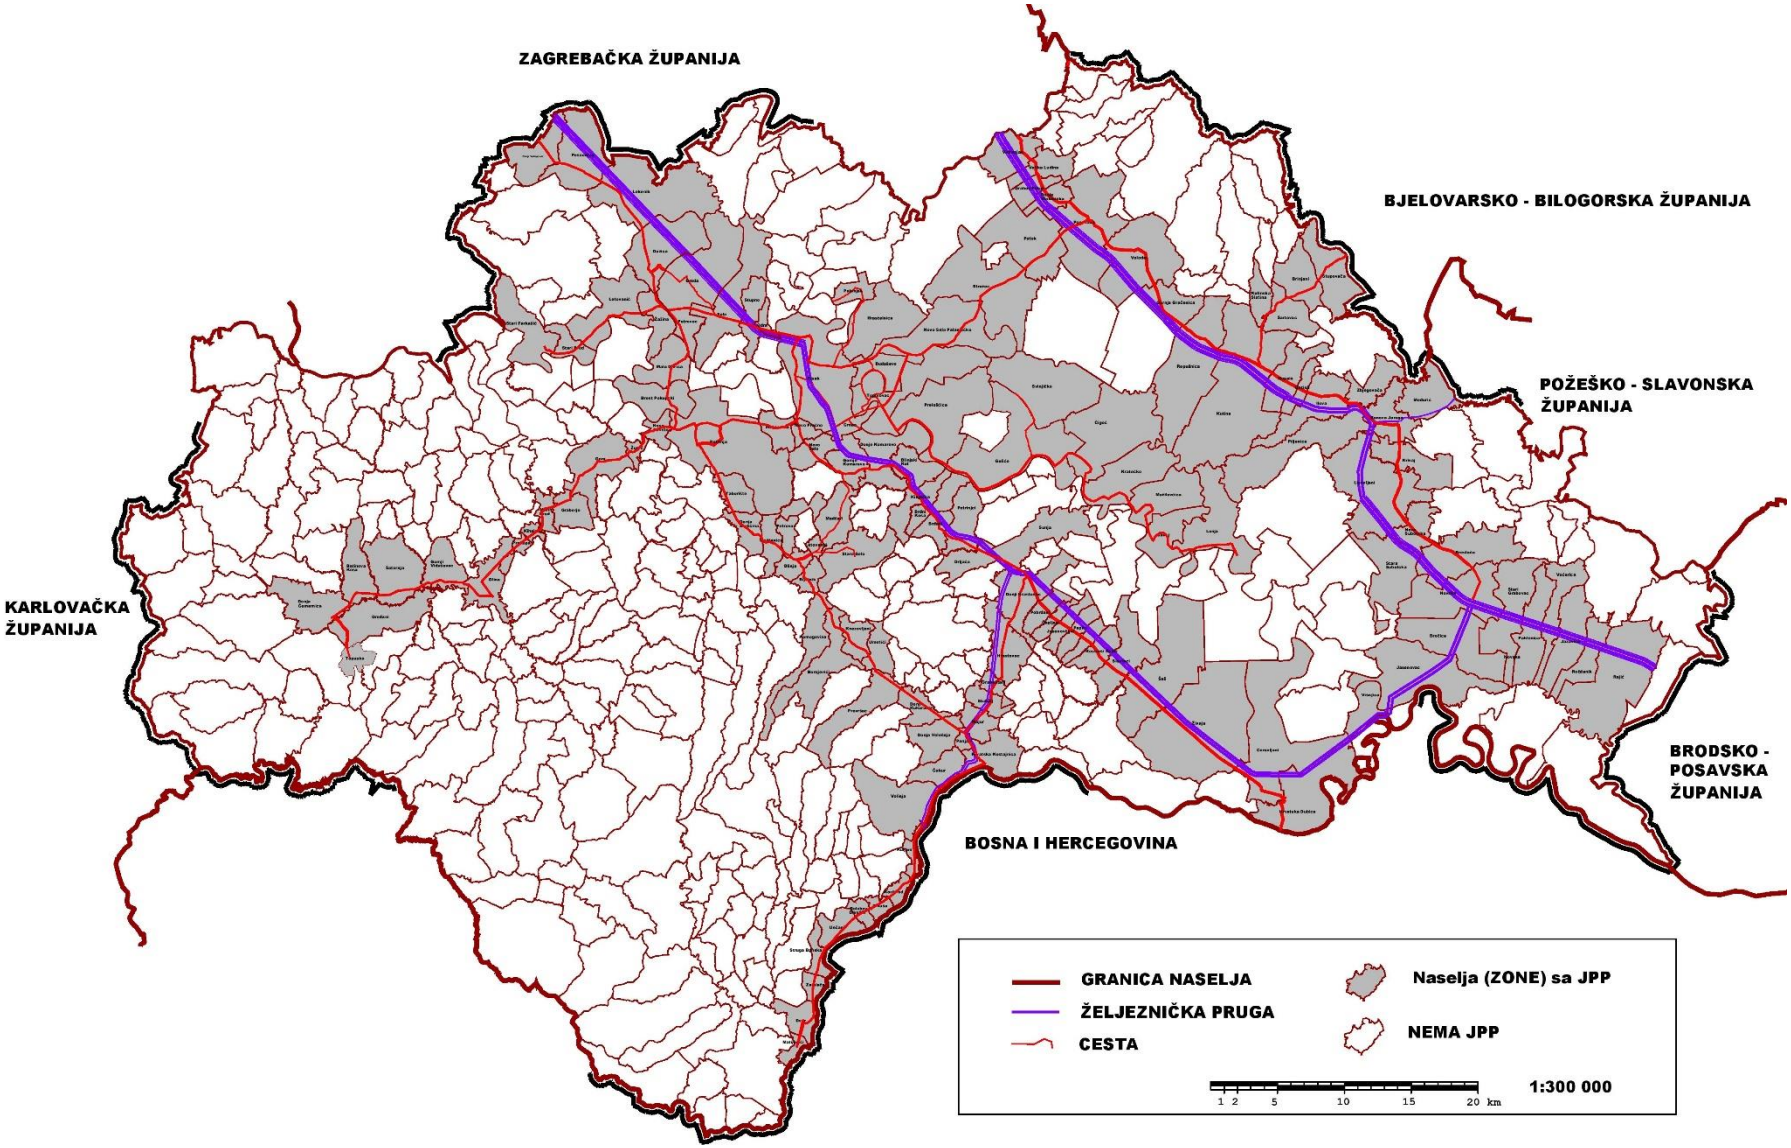

Slika 33. Analiza JPP-a u naseljima Sisačko-moslavačke županije

7.3. Analiza pravičnih kriterija u naseljima Sisačko-moslavačke županije

Prva je etapa testiranja modela pravičnoga tarifnoga sustava u integriranom prijevozu putnika analiza pravičnih kriterija i potkriterija unutar Sisačko-moslavačke županije na razini 139 naselja u kojima se provodi javni prijevoz putnika. Napravljena je analiza demografskih, gospodarskih i prometnih kriterija redoslijedom prema vrednovanim težinskih koeficijentima iz Tablice 11. Za analizu su korišteni podatci za 2017. godinu te posljednji popis stanovništva iz 2011. godine. Prvo su analizirani prometni kriteriji frekvencija polazaka, gustoća mreže, demografska gustoća i gustoća stajališta. Nakon prometnih kriterija napravljena je analiza gospodarskih kriterija dohodak po stanovniku, stopa nezaposlenosti i proračunski prihodi po stanovniku te potom analiza demografskih pravičnih kriterija gustoća stanovništva, opće kretanje stanovništva i radni kontingent.

7.3.1. Prometni kriteriji razvijenosti

Analiza je dnevne frekvencije polazaka po stajalištima unutar naselja Županije (Prilog 2.) pokazala da je najveća frekvencija polazaka u naselju Žažina koje pripada Općini Lekenik zbog sjecišta prometnih pravaca Zagreb – Sisak i Zagreb – Petrinja. U naselju Žažina vozila javnoga prijevoza putnika 43 puta dnevno polaze u jednom smjeru, što je najveći broj polazaka po stajalištima unutar Sisačko-moslavačke županije. Drugo je naselje Sisak unutar Grada Siska koje ima 35,07 polazaka po stajalištu javnoga prijevoza. Unutar naselja Sisak u jednom je smjeru ukupno 1578 polazaka zbog postojanja gradskih, prigradskih, županijskih i međužupanijskih linija koja se obavljaju na 45 stajališta. Prema broju stajališta naselje Sisak najveće je naselje i samim je time umanjen broj polazaka po stajalištu. Na području su Županije 22 naselja koja nemaju stajališta javnoga prijevoza putnika, ali kroz koja prolaze linije javnoga prijevoza i kroz koja putnici tranzitiraju do svojih odredišta. Medijalna je vrijednost frekvencije polazaka po stajalištu u naselju Lipovljani te iznosi 4,50 polazaka po stajalištu. U Prilogu 2. prikazana su sva naselja prema broju dnevnih polazaka po stajalištu poredana po visini izračuna parametra pravičnoga potkriterija. Najveći parametar pravičnoga potkriterija imaju naselja Žažina (2,00) i Sisak (1,79), dok najmanji imaju 22 naselja (0,00) u kojima ne postoji način ulaska u sustav javnoga prijevoza putnika zbog nepostojanja stajališta. Na Slici 34. prikazana

je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom frekvencije polazaka po stajalištu.

Gustoća je mreže javnoga prijevoza putnika analizirana po naseljima unutar Županije i prikazana u Prilogu 3. Prema gustoći mreže naselje Vedro unutar Općine Sunja i naselje Panjani unutar Grada Hrvatske Kostajnice imaju najveće vrijednosti, odnosno 3,48 i 2,03 km mreže javnoga prijevoza putnika po km^2, dok je naselje Sisak na petom mjestu s gustoćom mreže od 1,32 km mreže javnoga prijevoza putnika po km^2. Naselja Vedro i Panjani posebna su po tome što, za razliku od naselja Sisak, imaju relativno veliku duljinu mreže javnoga prijevoza u odnosu na malu površinu koja je 0,44 km^2 u naselju Vedro i 1,37 km^2 u naselju Panjani. Medijalnu vrijednost gustoće mreže ima naselje Greda unutar Grada Siska te ona iznosi 0,38 km mreže javnoga prijevoza putnika po km^2. Najmanju gustoću mreže javnoga prijevoza imaju naselja Pobrđani, Stari Farkašić i Međurić (0,02 km mreže javnoga prijevoza putnika po $km^{2)}$. Najveći parametar pravičnoga potkriterija ima naselje Vedro Polje (2,00) i Panjani (1,53), dok najmanji imaju Pobrđani, Stari Farkašić i Međurić (0,00). Na Slici 35. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom gustoće mreže javnoga prijevoza putnika.

Demografska gustoća prometne mreže u javnom prijevozu putnika predstavlja odnos duljine mreže javnoga prijevoza putnika i broja stanovnika koje prebiva na promatranom području i treći je prometni kriterij razvijenosti. U Prilogu 4. prikazana su sva naselja prema demografskoj gustoći javnoga prijevoza putnika poredana po visini izračuna parametra pravičnoga potkriterija. Naselje Suvoj unutar Grada Siska s 0,088 km mreže javnoga prijevoza putnika po stanovniku ima najveću demografsku gustoću i parametar pravičnoga potkriterija 2,00. Medijalnu vrijednost demografske gustoće imaju naselja Brinjani, Greda, Petrovec, Zamlača i Palanjek te ona iznosi 0,010 km mreže javnoga prijevoza putnika po stanovniku. Najmanju demografsku gustoću i parametar pravičnoga potkriterija 0,00 ima naselje Međurić unutar Grada Kutine s 0,0004 km mreže javnoga prijevoza putnika po stanovniku. Na Slici 36. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom demografske gustoće javnoga prijevoza putnika.

Četvrti je prometni kriterij razvijenosti koji ulazi u pravični tarifni model kriterij gustoće stajališta javnoga prijevoza putnika. Gustoća je stajališta javnoga prijevoza putnika po naseljima unutar Županije analizirana i prikazana u Prilogu 5. Prema gustoći stajališta naselje Vedro unutar Općine Sunja i naselje Sisak unutar Grada Siska imaju najveće vrijednosti, odnosno 2,27 i 1,41 stajališta po km^2. Medijalnu vrijednost gustoće stajališta imaju naselja

Donje Komarevo, Drljača, Staro Selo i Žažina te ona iznosi 0,16 stajališta po km^2. Najmanju gustoću stajališta javnoga prijevoza imaju 22 naselja (0,00) u kojima ne postoji stajalište za ulazak u sustav javnoga prijevoza putnika. Na Slici 37. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom gustoće stajališta javnoga prijevoza putnika.

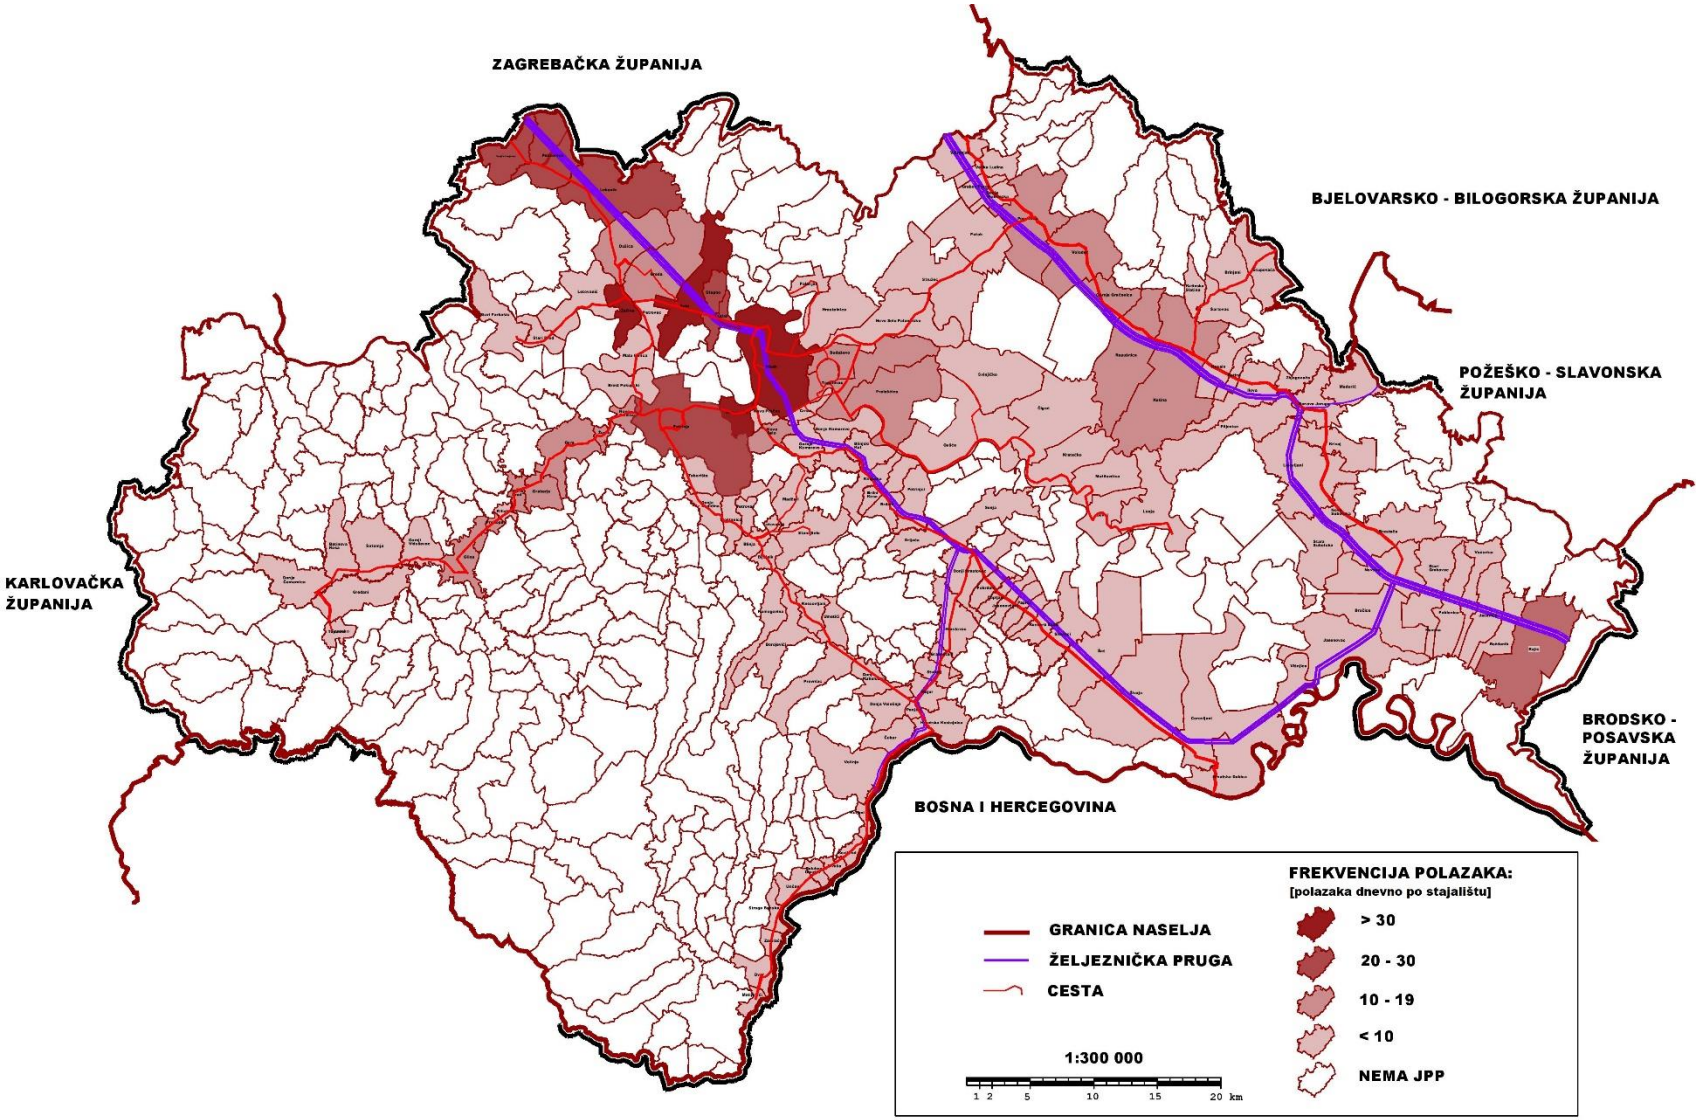

Slika 34. Analiza frekvencije polazaka po stajalištima unutar naselja Sisačko-moslavačke županije

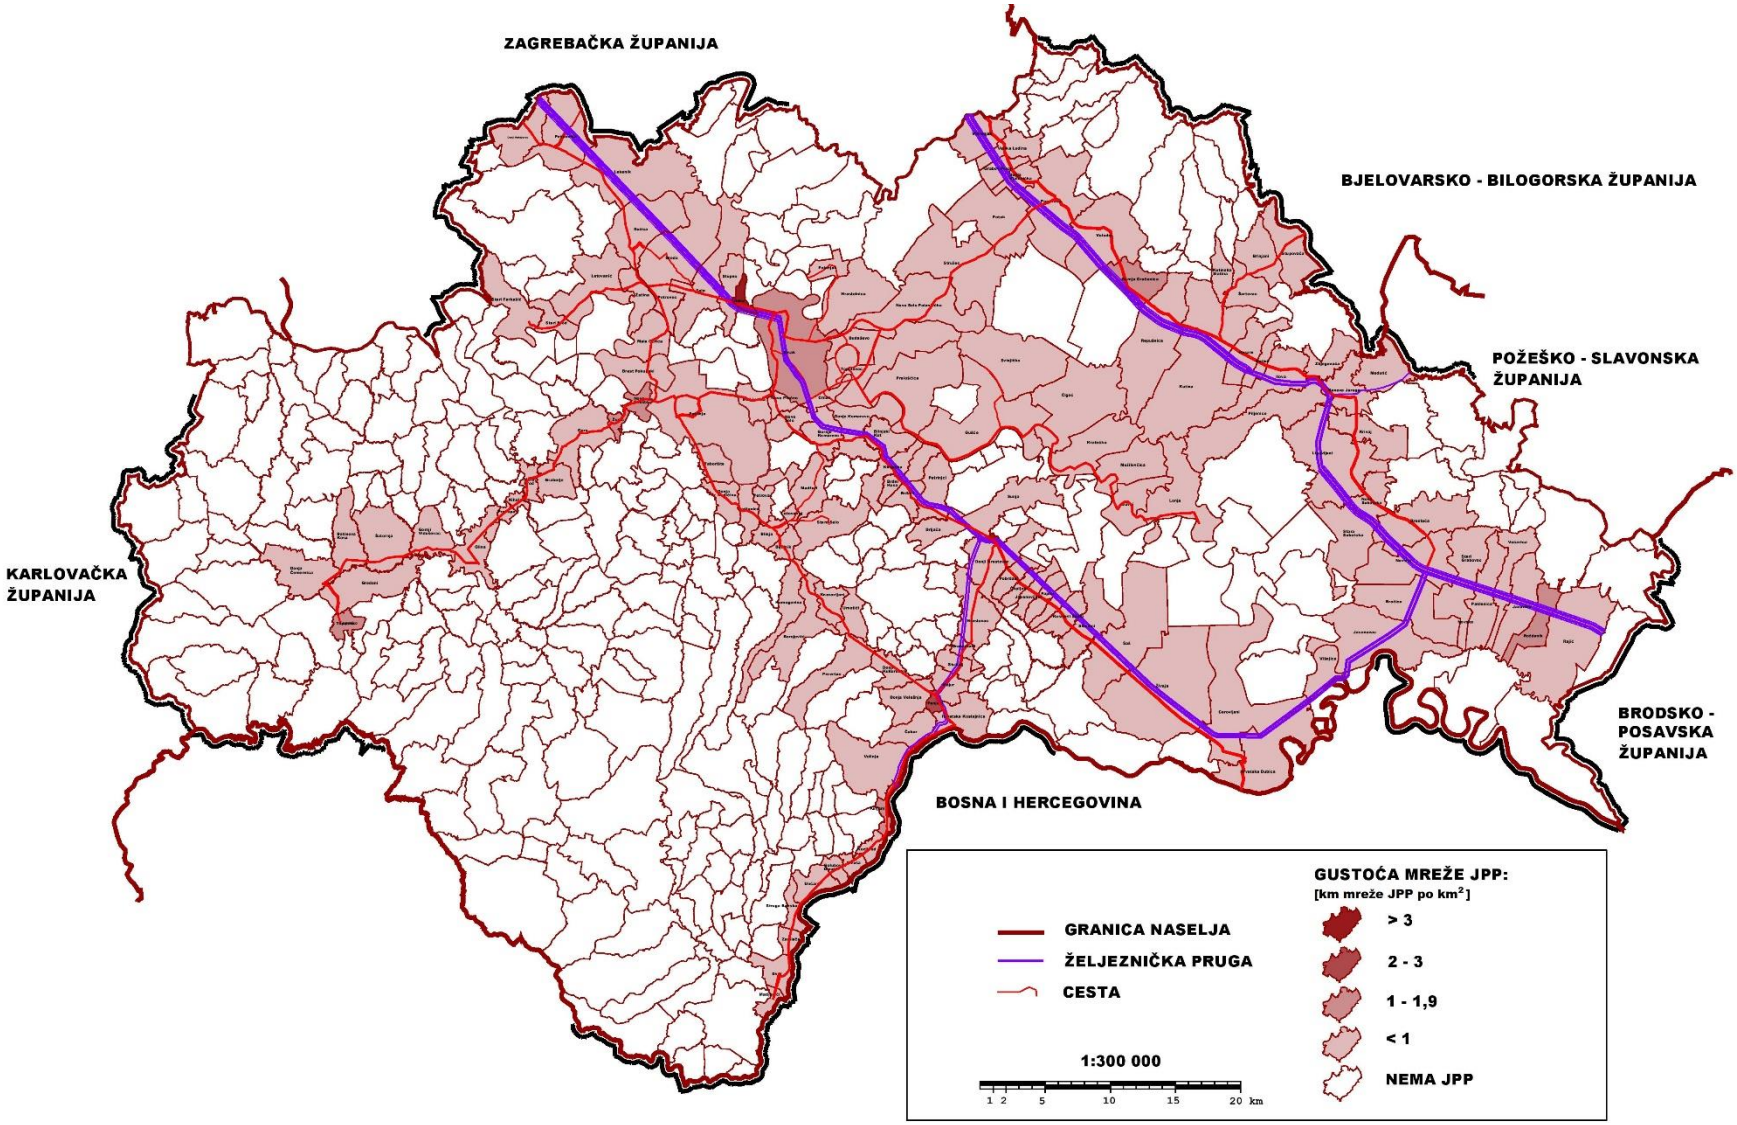

Slika 35. Analiza gustoće mreže JPP-a unutar naselja Sisačko-moslavačke županije

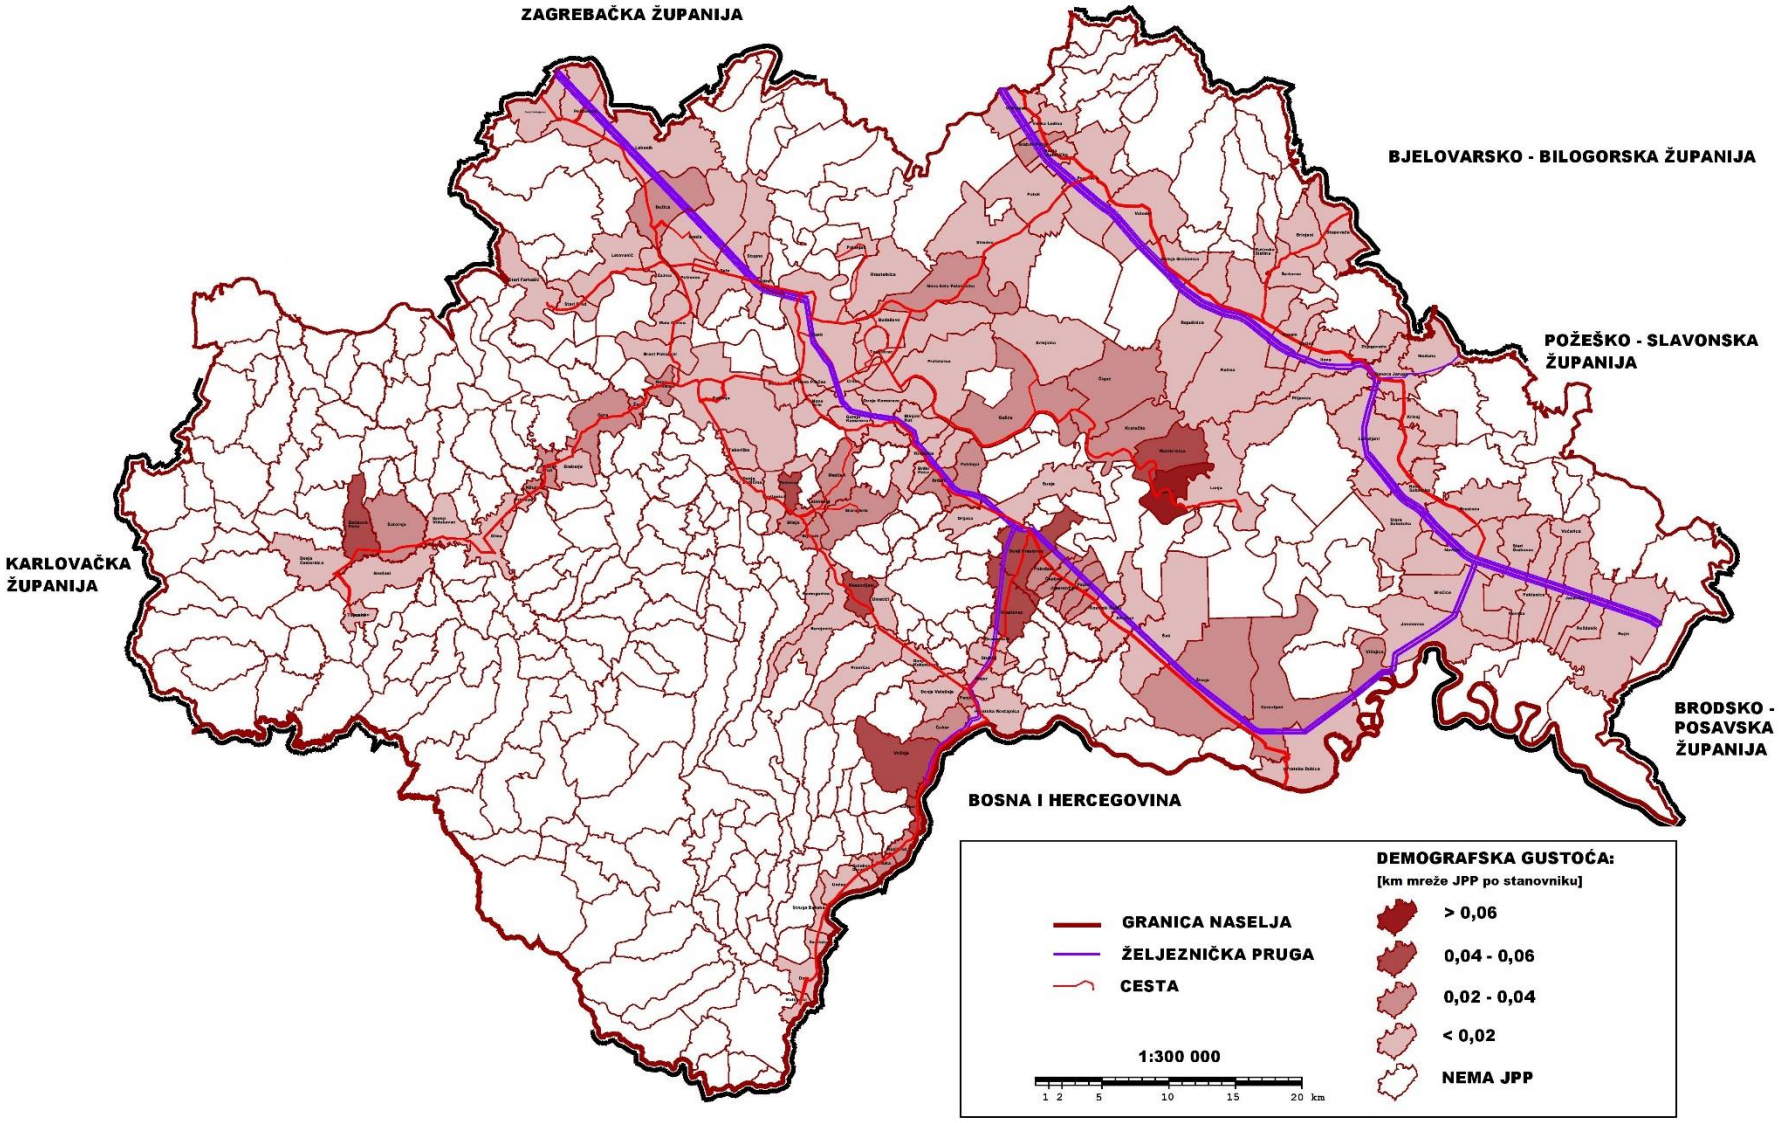

Slika 36. Analiza demografske gustoće mreže JPP-a unutar naselja Sisačko-moslavačke županije

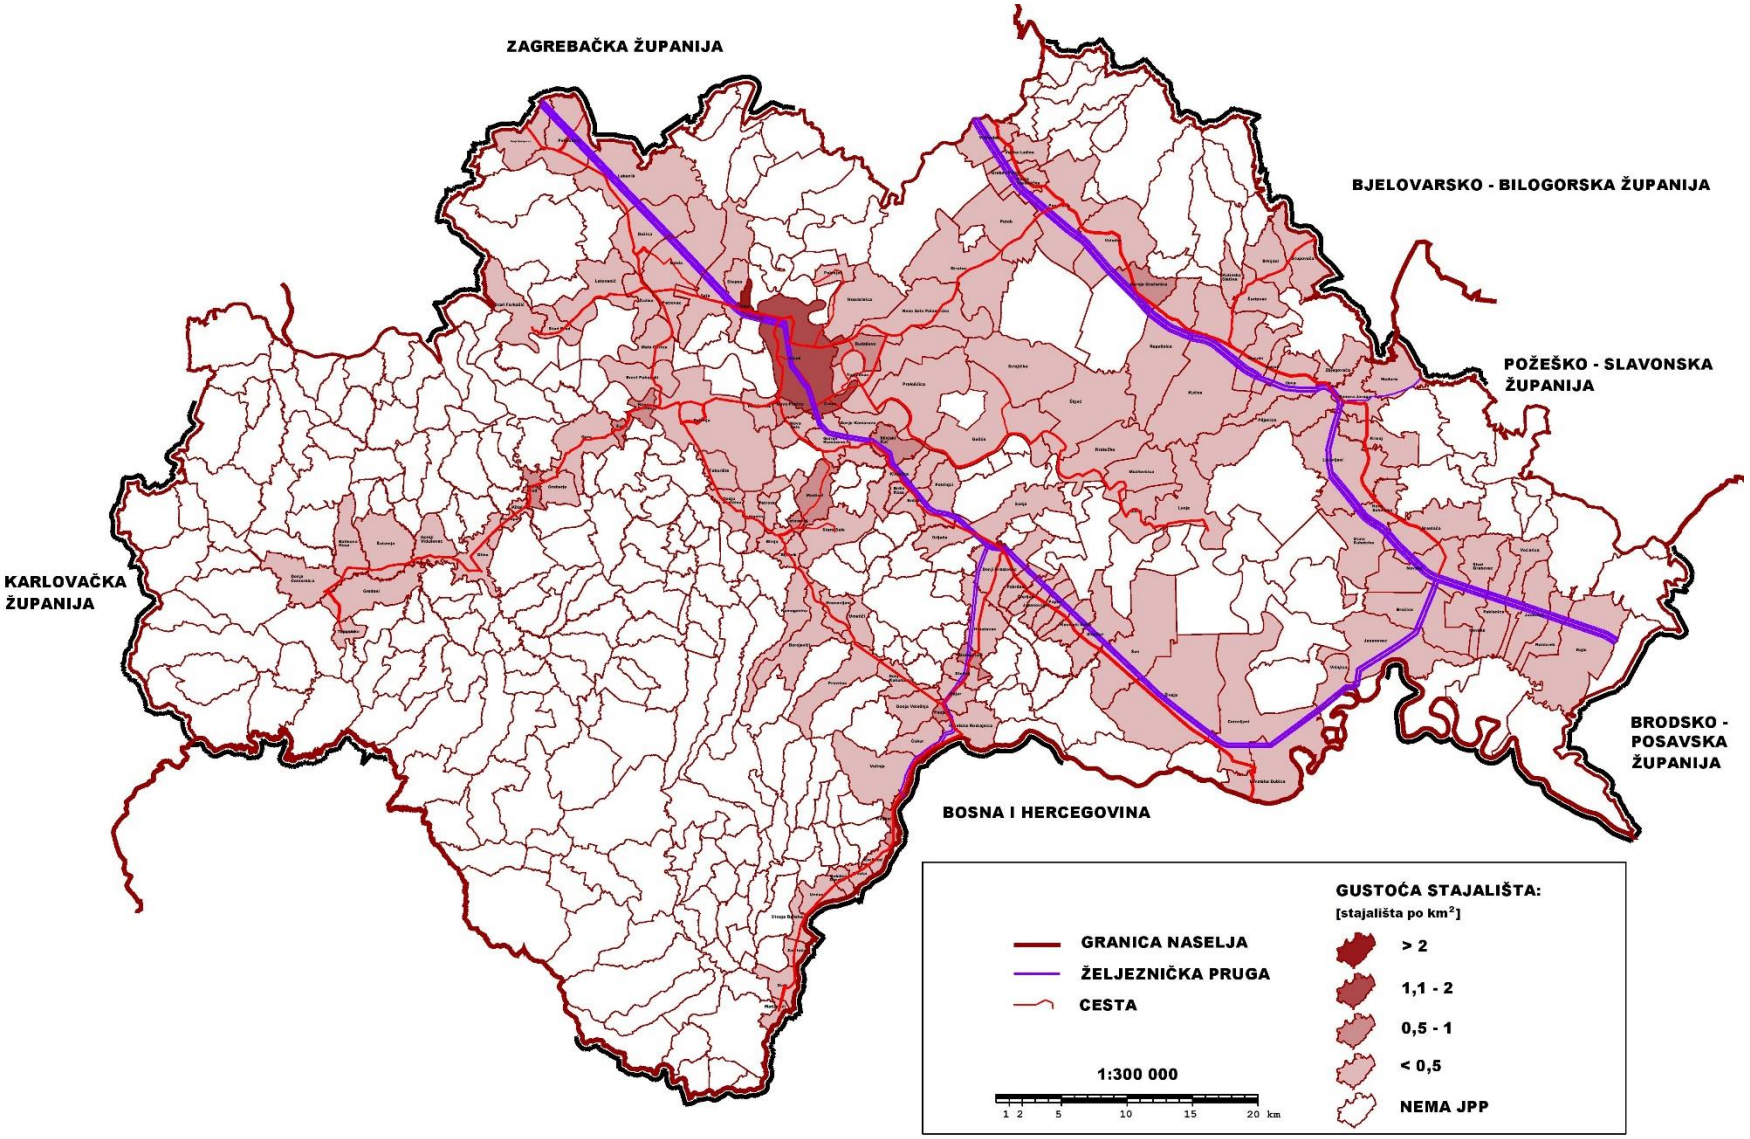

Slika 37. Analiza gustoće stajališta u JPP-u unutar naselja Sisačko-moslavačke županije

7.3.2. Gospodarski kriteriji razvijenosti

Analizu gospodarskih kriterija razvijenosti nije moguće napraviti na razini naselja zbog nepostojanja načina skupljanja podataka na manjoj jedinici lokalne, odnosno područne (regionalne) samouprave od razine općine, odnosno grada. S obzirom na to da gospodarski kriteriji razvijenosti utječu na tarifnu strukturu i cijenu koja se naplaćuje za pružanje prijevozne usluge u pojedinoj tarifnoj zoni neizravno pokazujući prosječnu platežnu moć stanovništva koje prebiva na tom području, napravljena je analiza odabranih kriterija na razini općina i gradova unutar kojih se obavlja javni prijevoz putnika. Naselja koja se nalaze unutar analiziranih podataka za općine i gradove sastavni su dio njihove gospodarske razvijenosti te su poprimila njihove karakteristike. Gospodarski su kriteriji razvijenosti kao i prometni kriteriji razvijenosti analizirani za 2017. godinu s osvrtom na gospodarska dostignuća u prethodnoj 2016. godini. Unutar Općina Gvozd i Martinska Ves ne postoji usluga javnoga prijevoza putnika, stoga su navedene općine izuzete iz analize gospodarskih kriterija razvijenosti.

Prvi je gospodarski kriterij razvijenosti dohodak po stanovniku. Stanovništvo je Sisačko-moslavačke županije imalo najveći dohodak po stanovniku unutar grada Siska u iznosu od 33.082,60 kn po stanovniku u 2016. godini. Samim time Grad Sisak nosi parametar pravičnoga potkriterija 2,00. Medijalna je vrijednost u Općini Topusko koja ima dohodak po stanovniku u iznosu od 23.426,16 kn te parametar pravičnoga potkriterija 1,00. Najniži je dohodak po stanovniku ostvarila općina Donji Kukuruzari u iznosu od 13.110,16 kn te je preuzela parametar pravičnoga potkriterija 0,00. U Tablici 12. prikazani su dohodci po stanovniku i parametri pravičnoga potkriterija za općine i gradove u Sisačko-moslavačkoj županiji.

Tablica 12. Dohodak po stanovniku u općinama i gradovima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

	Dohodak stanovnika u 2016. godini [kn]	**Procijenjeni broj stanovnika 2016. godine**	**Dohodak po stanovniku [kn]**	**Parametar pravičnoga potkriterija e_{sp5}**
Gradovi:				
Glina	168.623.859	7408	**22.762,40**	**0,94**
Hrvatska Kostajnica	53.568.221	2197	**24.382,44**	**1,10**
Kutina	649.022.116	21427	**30.289,92**	**1,71**
Novska	306.453.013	12453	**24.608,77**	**1,12**
Petrinja	577.071.023	22128	**26.078,77**	**1,27**
Popovača	280.481.748	11367	**24.675,09**	**1,13**

Sisak	1.469.231.349	44411	**33.082,60**	**2,00**
Općine:				
Donji Kukuruzari	16.663.013	1271	**13.110,16**	**0,00**
Dvor	63.493.127	4019	**15.798,24**	**0,26**
Gvozd	33.387.145	2173	**15.364,54**	**–**
Hrvatska Dubica	28.813.726	1693	**17.019,33**	**0,38**
Jasenovac	40.072.182	1754	**22.846,17**	**0,94**
Lekenik	161.669.113	5842	**27.673,59**	**1,44**
Lipovljani	85.088.800	3245	**26.221,51**	**1,29**
Majur	20.096.192	927	**21.678,74**	**0,83**
Martinska Ves	66.394.048	3206	**20.709,31**	**–**
Sunja	93.406.550	4650	**20.087,43**	**0,68**
Topusko	59.970.970	2560	**23.426,16**	**1,00**
Velika Ludina	55.149.721	2520	**21.884,81**	**0,85**

Izvor: Obrada autora prema podatcima koji je ustupilo *Ministarstvo regionalnog razvoja i fondova Europske unije*

Na Slici 38. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom dohotka po stanovniku.

Stopa nezaposlenosti jedan je od najvažnijih gospodarskih kriterija razvijenosti koji nam neizravno govori o uspješnosti gospodarstva na nekom području. Predstavlja odnos broja nezaposlenih stanovnika prema ukupnom broju potvrđene radne snage i drugi gospodarski kriterij razvijenosti. Najveću razvijenost u Sisačko-moslavačkoj županiji promatrajući kriterij stope nezaposlenosti ima Grad Kutina s najmanjom stopom u iznosu od 12,65 %, potom slijedi Grad Sisak sa stopom nezaposlenosti od 18,21 %. Time im pripadaju parametri pravičnoga potkriterija 2,00 i 1,75. Medijalna je vrijednost u Općini Majur koja ima stopu nezaposlenosti 35,34 % te parametar pravičnoga potkriterija 1,00. Najveću stopu nezaposlenosti te najmanju razvijenost unutar Županije ima Općina Donji Kukuruzari sa 64,71 % i parametrom pravičnoga potkriterija 0,00.

U Tablici 13. prikazane su stope nezaposlenosti i parametri pravičnoga potkriterija za općine i gradove u Sisačko-moslavačkoj županiji. Podatke u tablici ustupio je *Hrvatski zavod za mirovinsko osiguranje* i *Hrvatski zavod za zapošljavanje*. Na Slici 39. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom stope nezaposlenosti.

Tablica 13. Stopa nezaposlenosti u općinama i gradovima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

	Broj nezaposlenih	Radna snaga	Stopa nezaposlenosti [%]	Parametar pravičnoga potkriterija e_{sp6}
Gradovi:				
Glina	712	2.473	**28,79**	**1,29**
Hrvatska Kostajnica	161	692	**23,27**	**1,53**
Kutina	961	7.596	**12,65**	**2,00**
Novska	1.213	3.508	**34,58**	**1,03**
Petrinja	1.742	4.748	**36,69**	**0,95**
Popovača	684	2.614	**26,17**	**1,40**
Sisak	3.371	18.510	**18,21**	**1,75**
Općine:				
Donji Kukuruzari	165	255	**64,71**	**0,00**
Dvor	409	839	**48,75**	**0,54**
Gvozd			**–**	**–**
Hrvatska Dubica	234	375	**62,40**	**0,08**
Jasenovac	236	527	**44,78**	**0,68**
Lekenik	368	855	**43,04**	**0,89**
Lipovljani	271	918	**29,52**	**1,26**
Majur	82	232	**35,34**	**1,00**
Martinska Ves			**–**	**–**
Sunja	543	958	**56,68**	**0,27**
Topusko	246	746	**32,98**	**1,10**
Velika Ludina	147	381	**38,58**	**0,89**

Izvor: Obrada autora prema podatcima koje je ustupio *Hrvatski zavoda za mirovinsko osiguranje* i *Hrvatski zavod za zapošljavanje*

Treći su gospodarski kriterij razvijenosti proračunski prihodi po stanovniku. Najveću razvijenost u proračunskim prihodima u Sisačko-moslavačkoj županije imaju Općina Jasenovac i Grad Sisak s najvećim proračunskim prihodima po stanovniku 5.198,00 kn i 3.985,00 kn. Samim time pripadaju im parametri pravičnoga potkriterija 2,00 i 1,40. Medijalna je vrijednost u Gradu Hrvatska Kostajnica koji ima proračunske prihode 3.188,00 kn po stanovniku te parametar pravičnoga potkriterija 1,00. Najmanje proračunske prihode po stanovniku unutar Županije ima općina Dvor s 2.144,00 kn i parametrom pravičnoga potkriterija 0,00.

U Tablici 14. prikazani su proračunski prihodi po stanovniku i parametri pravičnoga potkriterija za općine i gradove u Sisačko-moslavačkoj županiji. Podatke iz tablice ustupio je *Institut za javne financije*.

Tablica 14. Proračunski prihodi po stanovniku u općinama i gradovima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

	Proračunski prihodi u 2016. godini [kn]	Procijenjeni broj stanovnika 2016. godine	Proračunski prihodi po stanovniku [kn]	Parametar pravičnoga potkriterija e_{sp7}
Gradovi:				
Glina	25.127.936	7408	**3.392,00**	**1,10**
Hrvatska Kostajnica	7.004.036	2197	**3.188,00**	**1,00**
Kutina	73.923.150	21427	**3.450,00**	**1,13**
Novska	45.341.373	12453	**3.641,00**	**1,23**
Petrinja	67.534.656	22128	**3.052,00**	**0,87**
Popovača	31.918.536	11367	**2.808,00**	**0,65**
Sisak	176.977.835	44411	**3.985,00**	**1,40**
Općine:				
Donji Kukuruzari	4.791.670	1271	**3.770,00**	**1,29**
Dvor	8.496.166	4019	**2.114,00**	**0,00**
Gvozd	5.360.791	2173	**2.467,00**	**–**
Hrvatska Dubica	4.083.516	1693	**2.412,00**	**0,28**
Jasenovac	9.117.292	1754	**5.198,00**	**2,00**
Lekenik	21.054.568	5842	**3.604,00**	**1,21**
Lipovljani	9.621.425	3245	**2.965,00**	**0,79**
Majur	3.182.391	927	**3.433,00**	**1,12**
Martinska Ves	6.543.446	3206	**2.041,00**	**–**
Sunja	11.276.250	4650	**2.425,00**	**0,29**
Topusko	7.541.760	2560	**2.946,00**	**0,77**
Velika Ludina	5.977.440	2520	**2.372,00**	**0,24**

Izvor: Obrada autora prema podatcima koje je ustupio *Institut za javne financije*

Na Slici 40. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom proračunskih prihoda po stanovniku.

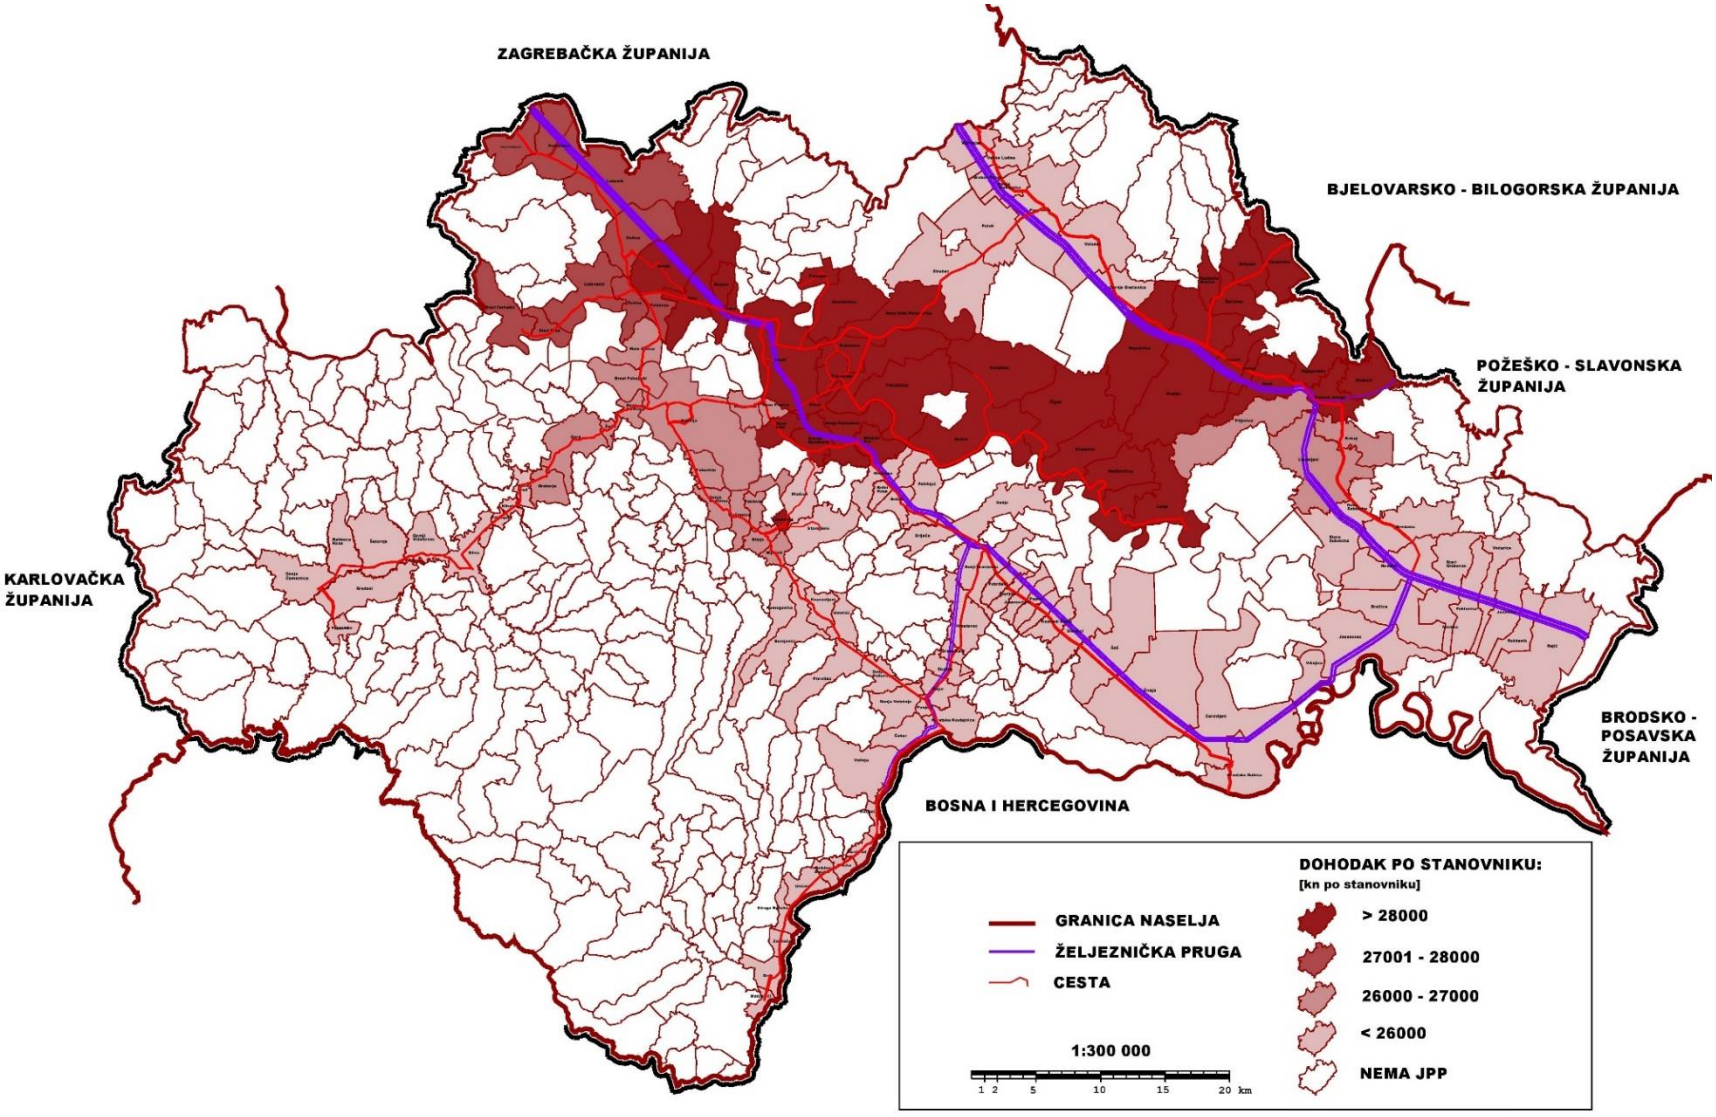

Slika 38. Analiza dohotka po stanovniku unutar naselja Sisačko-moslavačke županije

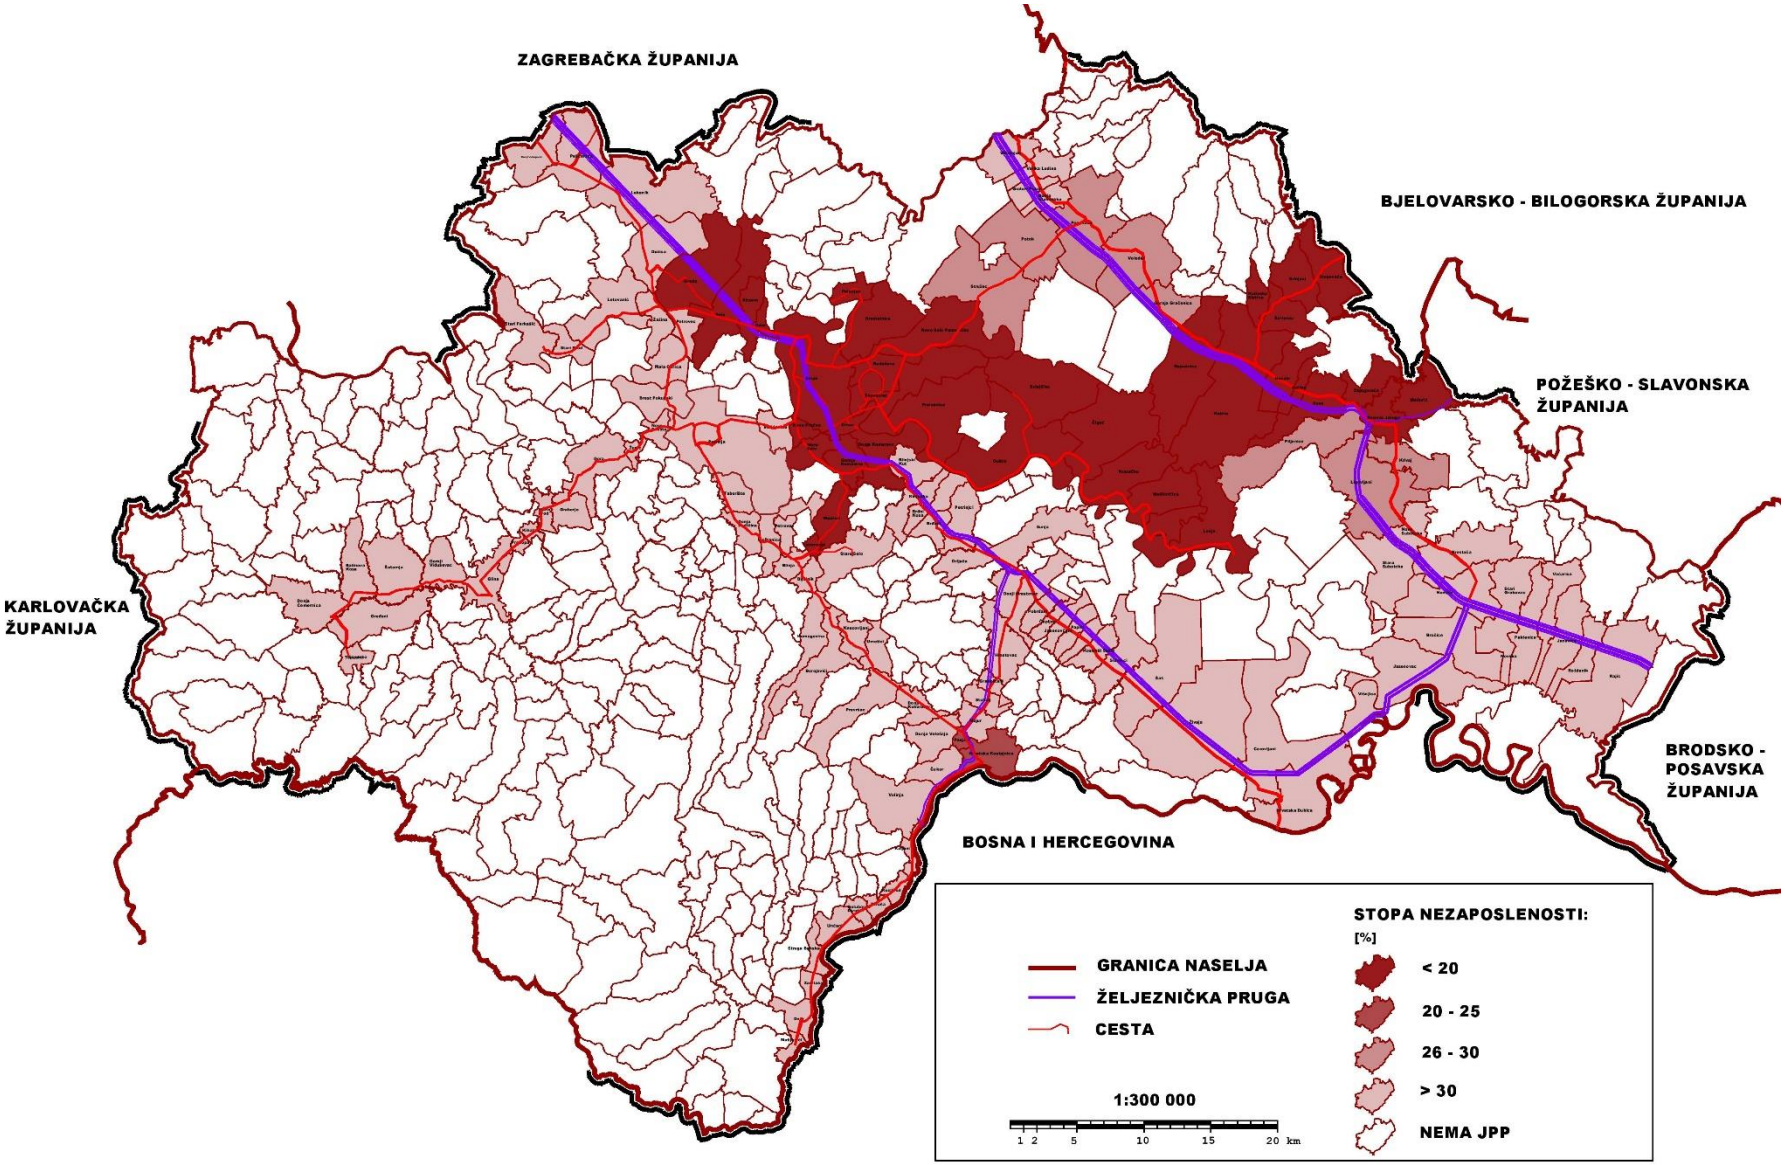

Slika 39. Analiza stope nezaposlenosti unutar naselja Sisačko-moslavačke županije

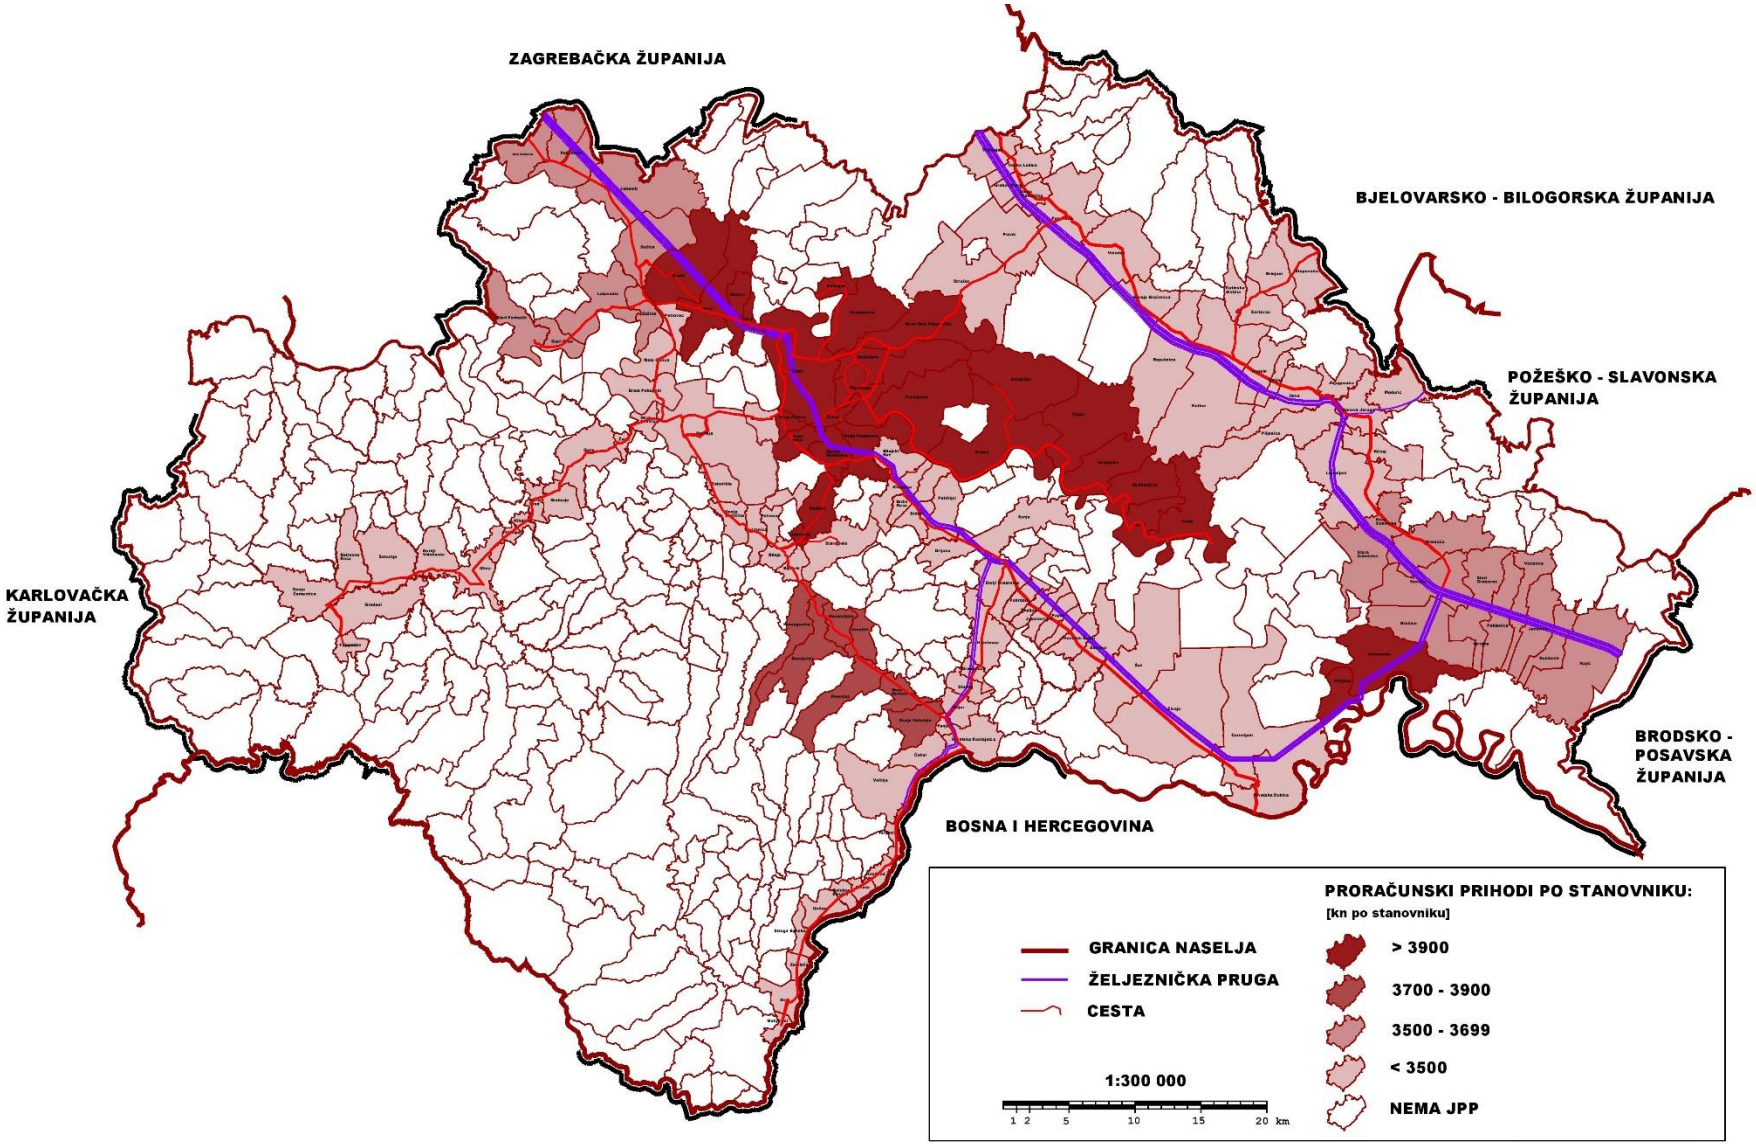

Slika 40. Analiza proračunskih prihoda po stanovniku unutar naselja Sisačko-moslavačke županije

7.3.3. Demografski kriteriji razvijenosti

Demografski kriteriji razvijenosti predstavljaju mogući smjer društveno-ekonomskoga razvoja na nekom prostoru. Analizu je moguće napraviti na razini naselja s obzirom na detaljno prikupljanje demografsko-statističkih podataka tijekom popisivanja stanovništva svakih deset godina. Pokazatelj demografskoga trenda može uvelike pridonijeti poboljšanju proizvođačko-potrošačke uloge stanovništva te razvijenosti nekoga područja ili stvaranju poteškoća.

Prvi je demografski kriterij razvijenosti gustoća stanovništva. Gustoća je stanovništva po naseljima unutar Županije analizirana i prikazana u Prilogu 6. Prema gustoći stanovništva naselje Sisak unutar Grada Siska ima najveću vrijednost, odnosno 1040,96 stanovnika po km^2, što je dvostruko veća gustoća od drugoga po redu naselja (Mošćenica 507,19 stanovnika po km^2) te nosi parametar pravičnoga potkriterija 2,00. Medijalnu vrijednost gustoće stanovništva ima naselje Stari Brod unutar Općine Lekenik i parametar pravičnoga potkriterija 1,00. Najmanju gustoću stanovništva ima naselje Pobrđani unutar Općine Sunja od 0,92 stanovnika po km^2 i pripadajući parametar pravičnoga potkriterija 0,00. Na Slici 41. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom gustoće stanovništva.

Opće kretanje stanovništva odražava sliku društveno-ekonomskoga stanja na nekom području. Razlozi su kretanja stanovništva najčešće povezani s gospodarskom razvijenošću i željom za kvalitetnijim življenjem. Definira se kao kretanje stanovništva između međupopisnoga razdoblja i predstavlja drugi demografski kriterij razvijenosti. U Prilogu 7. prikazana su sva naselja prema općem kretanju stanovništva poredana po visini izračuna parametra pravičnoga potkriterija. Naselje Petrinja unutar Grada Petrinje u posljednja dva popisa stanovništva bilježi najveći rast u broju stanovnika (1 882 stanovnika) i samim time ima najveću razvijenost te parametar pravičnoga kriterija 2,00. Medijalnu vrijednost općega kretanja stanovništva imaju naselja Grabov Potok, Husain, Jazavica i Staro Selo te je ona negativno kretanje u broju stanovnika za 31-oga stanovnika u odnosu na prethodni popis stanovništva. Najmanju razvijenost u pogledu općega kretanja stanovništva i parametar pravičnoga potkriterija 0,00 ima naselje Sisak unutar Grada Siska s padom broja stanovništva, točnije pad od 3 463 stanovnika. Na Slici 42. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom općega kretanja stanovništva.

Treći je demografski kriterij razvijenosti radni kontingent stanovništva bez kojega nema gospodarskoga razvoja jer njegova brojnost i struktura izravno utječe na razvoj gospodarstva na nekom području te na društvo u cjelini. On obuhvaća stanovništvo u dobi od 15 do 64 godine starosti.

U Prilogu 8. prikazana su sva naselja prema brojnosti radnoga kontingenta stanovništva poredana po visini izračuna parametra pravičnoga potkriterija. Naselje Sisak unutar Grada Siska ima najviše stanovnika unutar skupine radnoga kontingenta. Unutar naselja Sisak u radni kontingent svrstava se 22 710 stanovnika te naselje Sisak ima parametar pravičnoga potkriterija 2,00. Medijalnu vrijednost u radnom kontingentu stanovništva ima naselje Brinjani unutar Grada Kutine sa 182 stanovnika unutar radnoga kontingenta. Najmanju razvijenost u pogledu radnoga kontingenta stanovništva i parametar pravičnoga potkriterija 0,00 ima naselje Petkovac unutar Grada Petrinje sa svojih 11 stanovnika unutar radnoga kontingenta. Na Slici 43. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom radnoga kontingenta stanovništva.

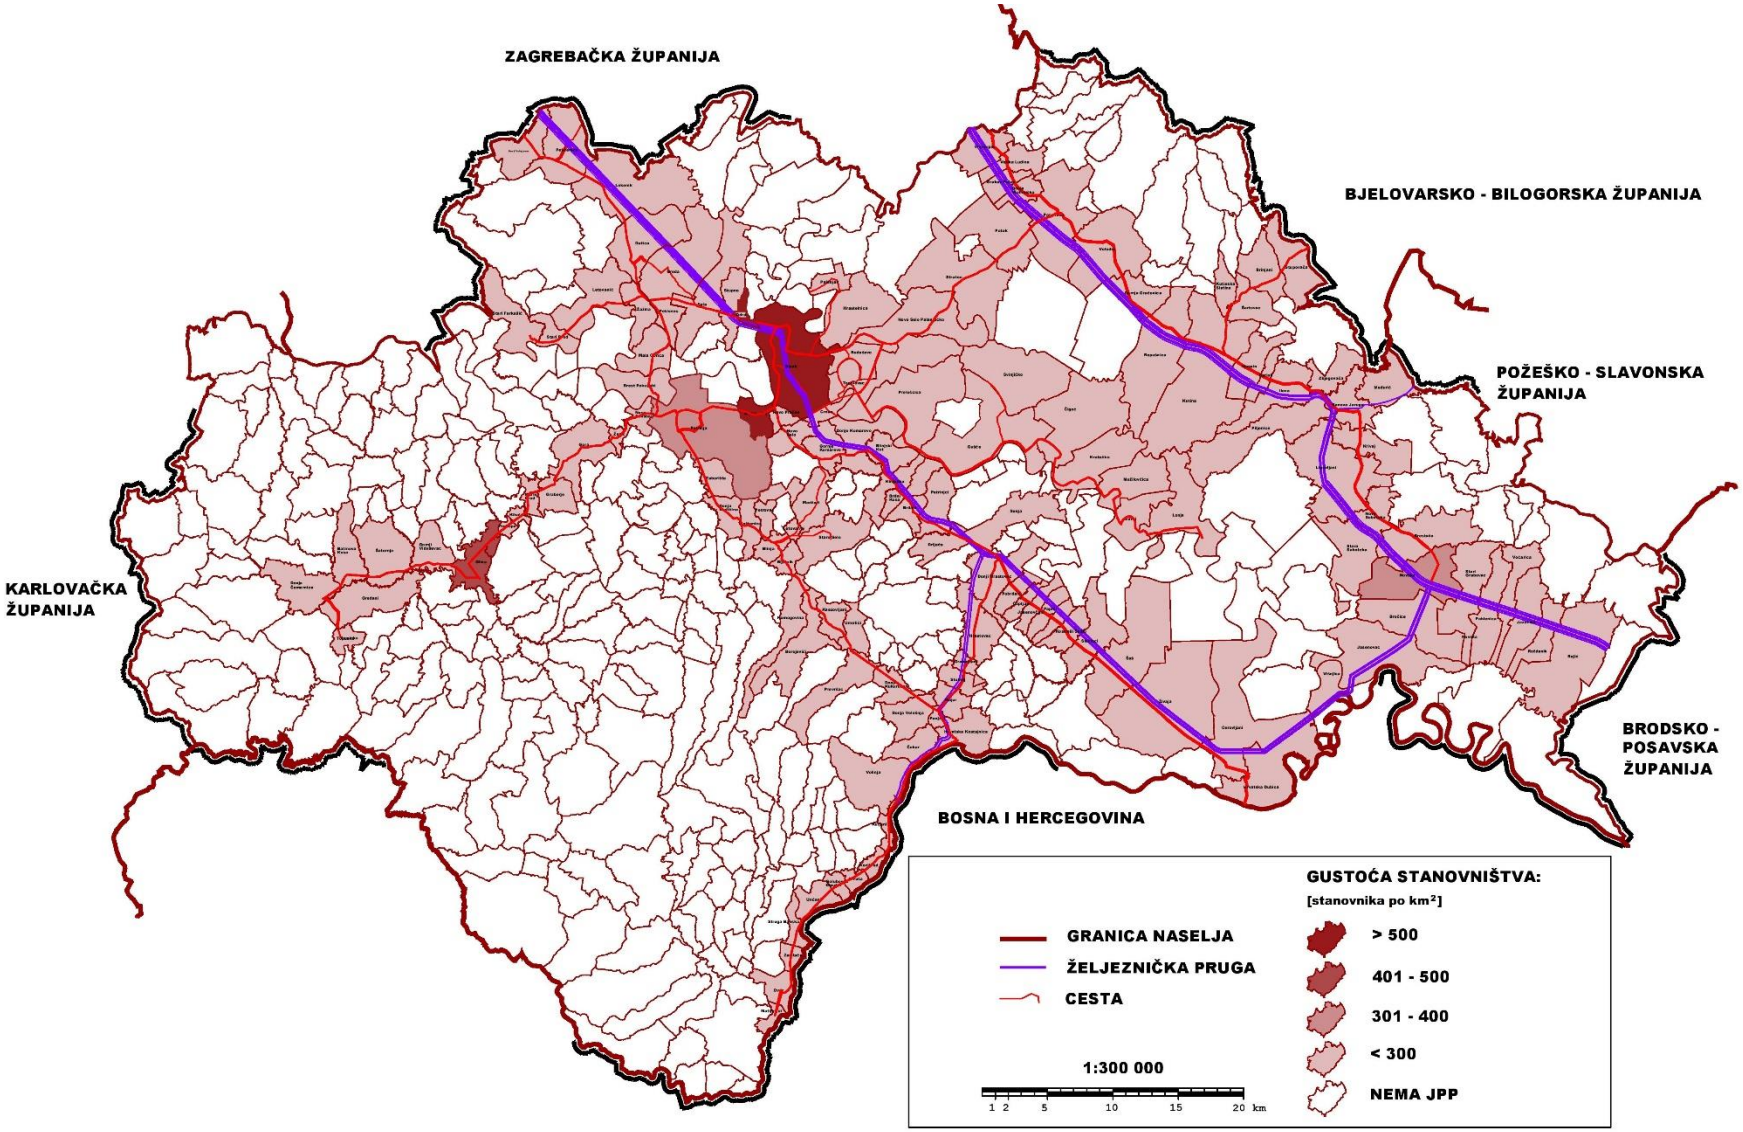

Slika 41. Analiza gustoće stanovništva unutar naselja Sisačko-moslavačke županije

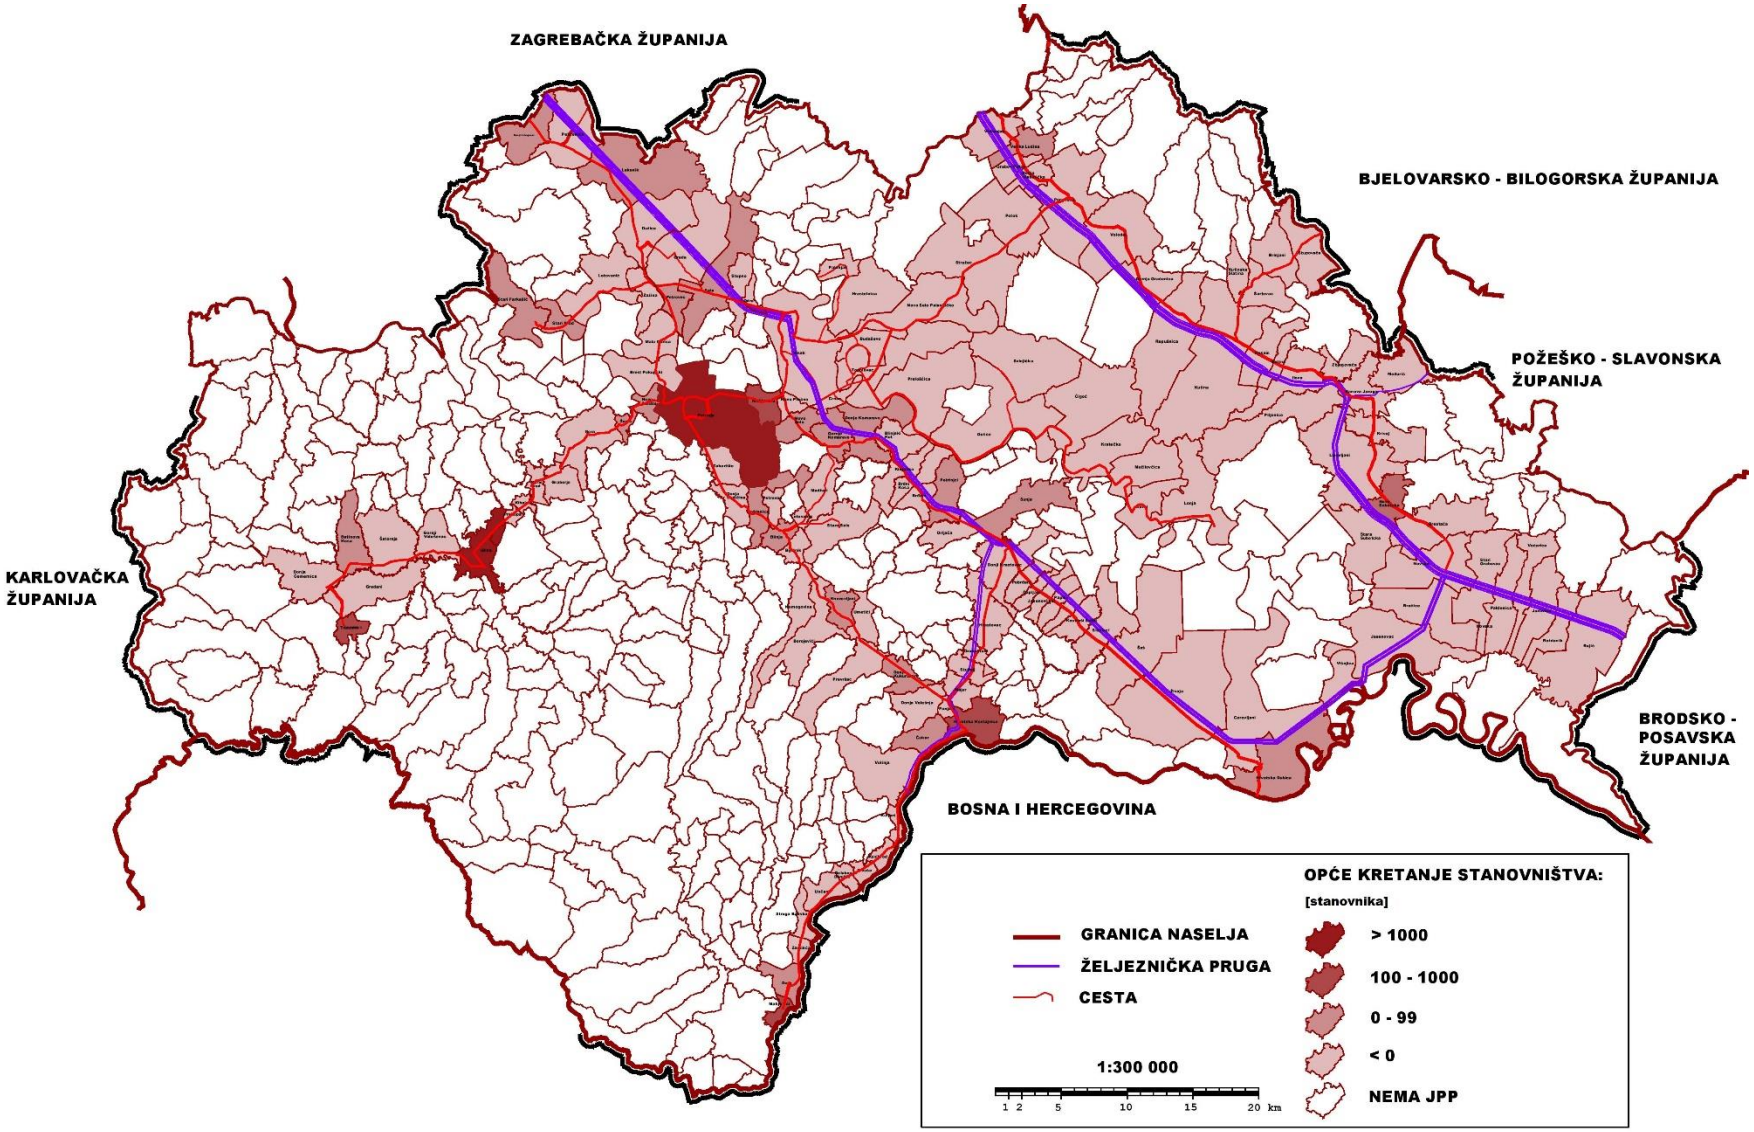

Slika 42. Analiza općega kretanja stanovništva unutar naselja Sisačko-moslavačke županije

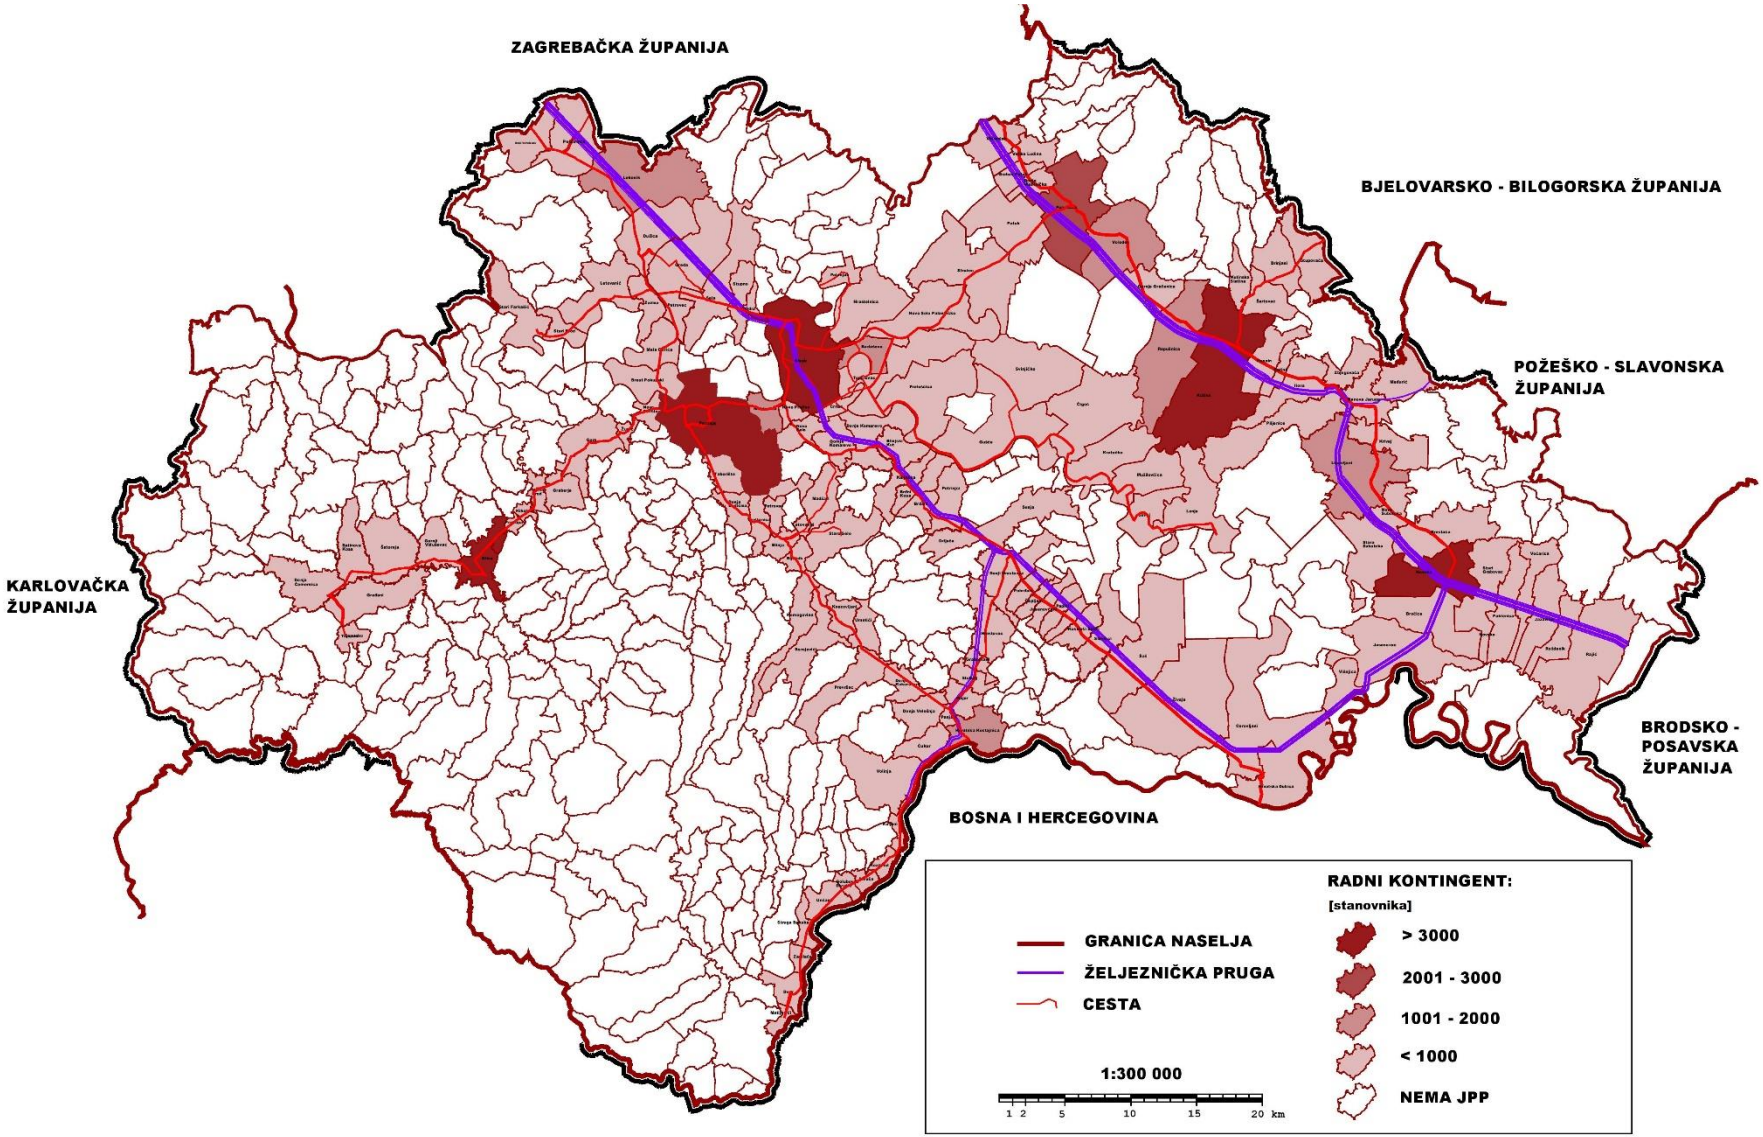

Slika 43. Analiza radnoga kontingenta stanovništva unutar naselja Sisačko-moslavačke županije

7.4. Primjena pravičnoga tarifnoga modela

Provedenom analizom pravičnih kriterija i potkriterija unutar Sisačko-moslavačke županije u mjestima u kojima se provodi javni prijevoz putnika određene su srednje, najmanje i najveće vrijednosti potkriterija na mreži te su izračunani svi parametri pravičnih potkriterija za 139 naselja. U 5. poglavlju određeni su težinski koeficijenti kriterija i potkriterija koji su potrebni kako bi se došlo do izračuna parametra pravičnih kriterija promet, gospodarstvo i demografija. Parametar je pravičnoga kriterija promet određen zbrojem umnožaka njegovih parametara pravičnih potkriterija (frekvencija polazaka, gustoća mreže, demografska gustoća i gustoća stajališta) i pripadajućih težinskih koeficijenata. Izračun parametra pravičnoga kriterija gospodarstvo označava zbroj umnožaka njegovih parametara pravičnih potkriterija (dohodak po stanovniku, stopa nezaposlenosti i proračunski prihodi po stanovniku) i pripadajućih težinskih koeficijenata. Parametar je pravičnoga kriterija demografija određen zbrojem umnožaka njegovih parametara pravičnih potkriterija (gustoća stanovništva, opće kretanje stanovništva i radni kontingent) i pripadajućih težinskih koeficijenata. Dobiveni su rezultati izračuna parametara pravičnih kriterija promet, gospodarstvo i demografija prikazani u Prilogu 9. Poredani su po naseljima prema visini koeficijenta pravičnosti izračunanoga na temelju formule 21 za izračun koeficijenta pravičnosti. Koeficijent je pravičnosti dobiven zbrojem umnožaka parametara pravičnih kriterija i pripadajućih težinskih koeficijenata.

Na Slici 44. prikazana je podjela Sisačko-moslavačke županije na naselja unutar kojih se obavlja javni prijevoz putnika s prikazom koeficijenta pravičnosti.

Izračunom je koeficijenta pravičnosti završena prva etapa testiranja i kreće druga etapa u kojoj je potrebno utvrditi cijenu prema osnovnom, odnosno općenitom matematičkom modelu za izračun cijene jednokratnoga putovanja unutar zone te uvesti koeficijent pravičnosti koji s osnovnim modelom tvori pravični tarifni model u integriranom prijevozu putnika. Nepoznanice su u modelu sljedeće: osnovna cijena, cijena po kilometru i srednja duljina linije unutar zone. Kako je osnovnu cijenu odredilo svako pojedino prijevozničko nadležno tijelo i temelji se na određivanje dijela cijene tarifne zone neovisne o duljini linija javnoga prijevoza te predstavlja fiksni trošak putovanja unutar tarifne zone, uvodi se ograničenje modela, odnosno pretpostavka da ona iznosi 0 kn. Studija slučaja Sisačko-moslavačke županije kao i ostalih županija u Republici Hrvatskoj nema integriran javni putnički prijevoz pa je osnovna cijena već uračunana u cijenu po kilometru unutar relacijskoga tarifnoga modela.

Druga je nepoznanica cijena po kilometru koju je potrebno utvrditi na temelju analize tarifnih modela prijevoznika unutar studije slučaja. Kako javni prijevoz putnika unutar Županije obavljaju tri prijevoznika od kojih su dva u autobusnom prijevozu (Auto promet Sisak i Čazmatrans – Nova) i jedan u željezničkom prijevozu (HŽ Putnički prijevoz), potrebno je uzeti u obzir tarifne sustave prijevoznika. Svi navedeni prijevoznici trenutačno koriste relacijski tarifni sustav s degresivnim cijenama. Cijena je po kilometru za tarifnu udaljenost do 5 km kod aktualnih prijevoznika sljedeća:

- HŽ Putnički prijevoz – 1,80 kn
- Auto promet Sisak – 1,80 kn
- Čazmatrans – Nova – 3,00 kn.

Za izračun je koeficijenta pravičnosti korištena srednja položajna vrijednost zbog njezine pogodnosti za vrijednosti obilježja koja znatno variraju te se u svrhu kontinuiteta primjenjuje i kod odabira srednje cijene po kilometru za sve aktualne prijevoznike. U skladu s navedenim, cijena po kilometru unutar tarifne zone iznosi 1,80 kn.

Srednja je duljina linije unutar zone posljednja preostala nepoznanica za izračun pravičnoga tarifnoga modela u integriranom prijevozu putnika. U prethodnom je poglavlju definirana kao srednja duljina putovanja unutar zone. Ako tarifna zona ima više prijevoznih linija, onda se srednja duljina linije unutar zone promatra kao medijalna vrijednost duljina prijevoznih linija promatrana prema rubovima tarifnih zona, odnosno naselja. Napravljena je analiza prijevoznih linija unutar tarifnih zona te su u Prilogu 10. navedene srednje duljine linija svake tarifne zone unutar studije slučaja.

Analiziranje je sastavnih elemenata formule za izračun pravičnoga tarifnoga modela na području studije slučaja i njihovo definiranje omogućilo izračun cijene jednokratnoga putovanja unutar zone za sve tarifne zone studije slučaja. U Prilogu 10. prikazani su rezultati izračuna cijena tarifnih zona unutar studije slučaja prema osnovnom i prema pravičnom tarifnom modelu, a na Slici 45. nalazi se prikaz cijena pravičnih tarifnih zona unutar Sisačko-moslavačke županije.

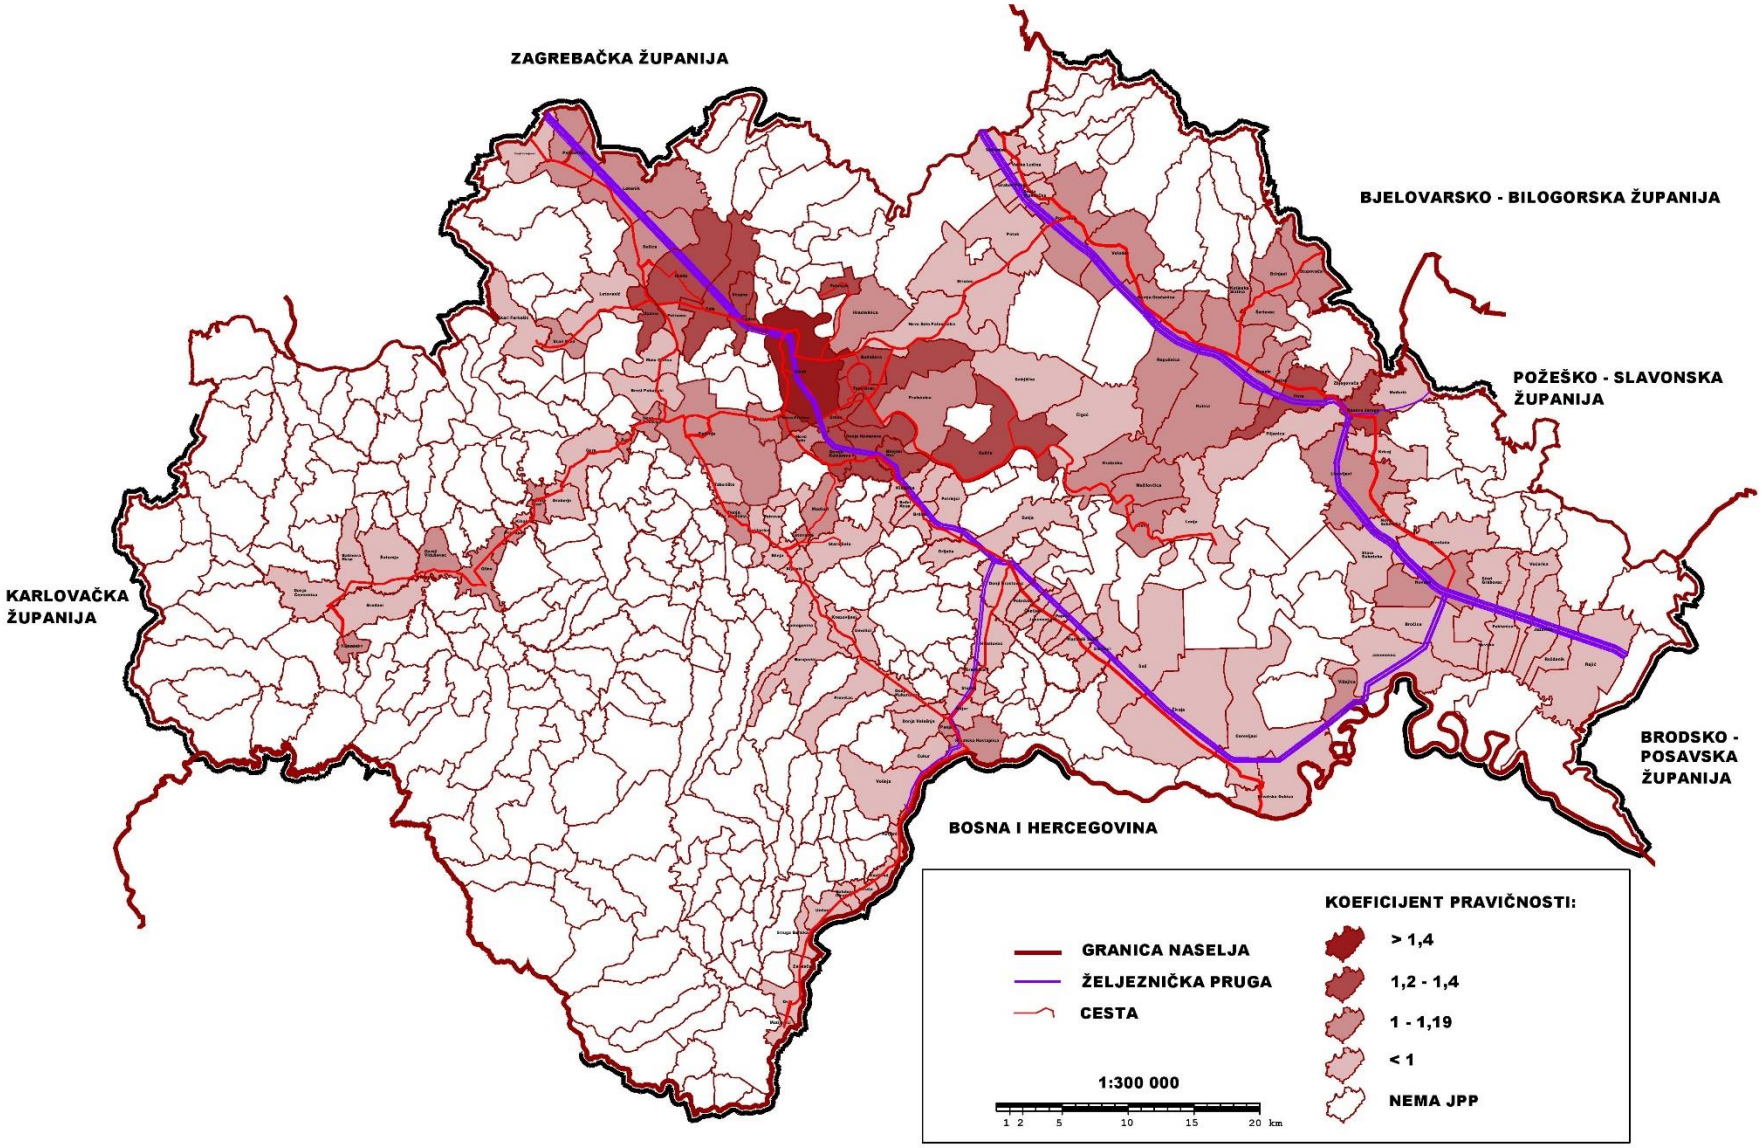

Slika 44. Analiza koeficijenta pravičnosti unutar naselja Sisačko-moslavačke županije

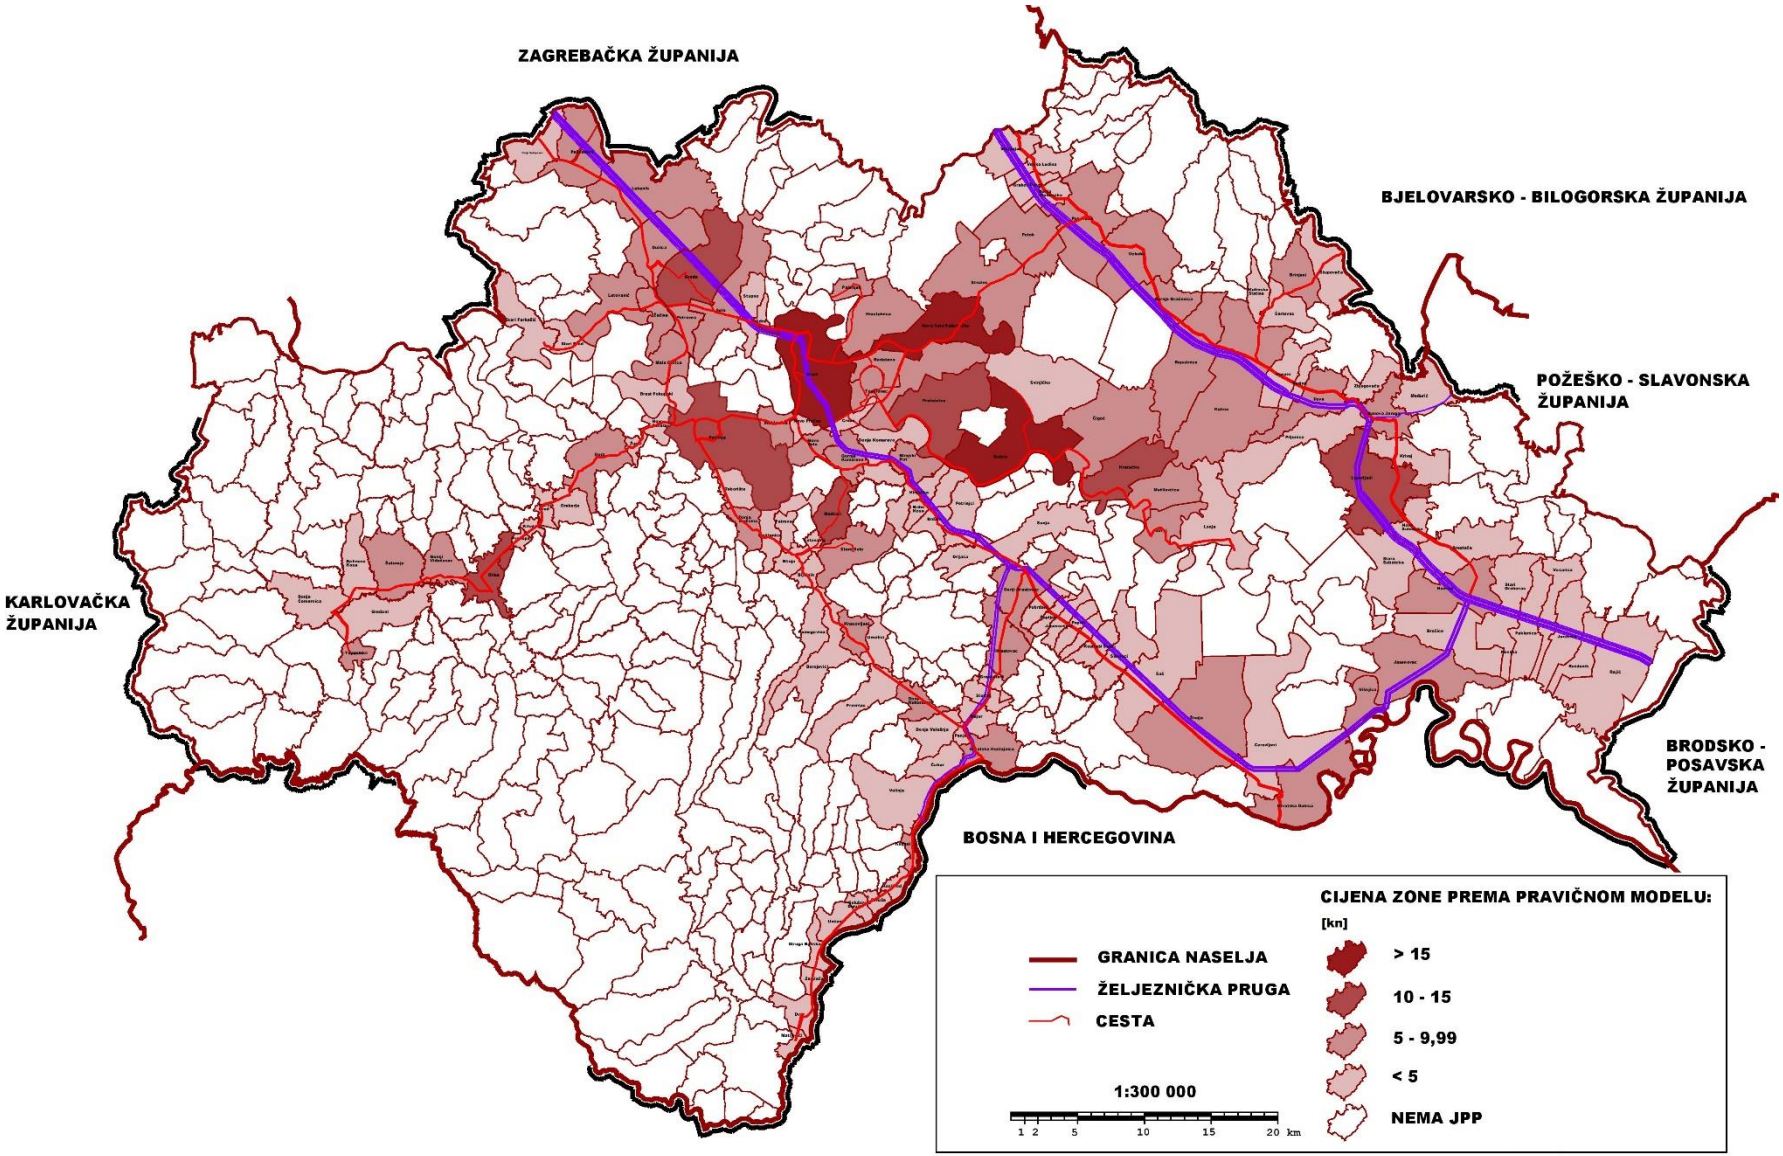

Slika 45. Analiza cijene tarifnih zona unutar Sisačko-moslavačke županije prema pravičnom tarifnom modelu

7.5. Diskusija dobivenih rezultata

Treća je i konačna etapa analiza rezultata cijena zonskih karata za jednokratno putovanje unutar zone, odnosno naselja te potvrda provedenoga znanstvenoga istraživanja s ciljem dokazivanja druge hipoteze. Rezultati su dobiveni prema osnovnom i prema pravičnom modelu te je moguće napraviti usporednu analizu.

Izračun je koeficijenta pravičnosti za sva naselja Sisačko-moslavačke županije u kojima se provodi javni prijevoz putnika omogućio cjelokupan pogled na razvijenost naselja u svrhu izrade pravičnoga tarifnoga modela za integrirani prijevoz putnika. Prema koeficijentu pravičnosti naselja koja administrativno pripadaju Gradu Sisku, koji je političko, administrativno, gospodarsko i kulturno središte Županije, dominiraju po jačini razvijenosti u odnosu na naselja iz drugih općina i gradova. Najveći koeficijent pravičnosti i najveću razvijenost očekivano ima naselje Sisak te on iznosi 1,461. Samim time donosi povećanje cijene izračunane prema osnovnom modelu za 46,1 %. Utvrđivanje dominantnosti naselja Sisak u razvijenosti prema kriterijima frekvencija polazaka, gustoća mreže, gustoća stajališta, dohodak po stanovniku, stopa nezaposlenosti, proračunski prihodi po stanovniku, gustoća stanovništva i brojnost radnoga kontingenta rezultiralo je najvećim koeficijentom pravičnosti u odnosu na ostala naselja. Kako je koeficijent pravičnosti najviše mogao dostići vrijednost 2,00, naselje Sisak ima umanjen koeficijent zbog loše razvijenosti u pogledu općega kretanja stanovništva i demografske gustoće. Trend je iseljavanja stanovništva utjecao na većinu naselja unutar Županije, no najveća je promjena broja stanovnika u naselju Sisak koje je prema gustoći stanovništva najrazvijenije, a prema broju stanovnika najveće naselje unutar Županije. Prema koeficijentu pravičnosti naselje Sisak slijede naselja koja se nalaze na prometnim pravcima u smjeru Zagreba i ostalih većih gradova unutar same Županije. Na spomenutim je prometnim pravcima došlo do velikih odstupanja u frekventnosti polazaka vozila javnoga prijevoza zbog dnevnih migracija stanovništva u svrhu odlazaka na posao i na školovanje. Također, naselje Sisak jedinstveno je unutar Županije po postojanju gradskoga prijevoza, što je s prometnoga gledišta dodatno pridonijelo boljoj razvijenosti.

Najniži su koeficijenti pravičnosti zabilježeni u šest naselja općine Sunja i u naselju Donji Cerovljani Općine Hrvatska Dubica. Karakterizira ih nepostojanje stajališta unutar naselja, već samo linije javnoga prijevoza koja prolazi kroz navedena naselja. Naselje Donji Cerovljani najmanje je razvijeno naselje s koeficijentom pravičnosti 0,260, što mu donosi

smanjenje cijene izračunane prema osnovnom modelu za 74 %. Nepostojanje stajališta, pa tako ni frekvencije polazaka po stajalištima unutar naselja, uvelike pridonosi niskoj razvijenosti te ga svrstava u tranzitna naselja u kojima vozila javnoga prijevoza samo prolaze bez stajanja. Naselje Donji Cerovljani, osim navedenoga, ima veliku stopu nezaposlenosti stanovništva, malu gustoću stanovništva i brojnost radnoga kontingenta.

Prema koeficijentu pravičnosti najveći je koeficijent uvećanja 1,461 za naselje Sisak. Uvećanje cijene osnovnoga modela za 46,1 % ne predstavlja veliko povećanja uzme li se u obzir usporedba kvalitete prijevozne usluge u odnosu na ostala naselja, a posebno naselja u ruralnim područjima gdje je i potražnja za prijevoznim uslugama puno niža. Naselja u kojima putnici ne mogu ući u sustav zbog nepostojanja stajališta većinom se nalaze na kraju tablice s koeficijentima pravičnosti i sva imaju koeficijent umanjenja cijene. Najmanje razvijena naselja Brđani Kosa (0,476), Jasenovčani (0,413), Kostreši Šaški (0,409), Čapljani (0,397), Slovinci (0,394), Pobrđani (0,312) i Donji Cerovljani (0,260) tranzitna su naselja i putnici ne mogu ući u sustav javnoga prijevoza. U navedenim naseljima izračunanu cijenu prema osnovnom modelu koeficijent pravičnosti umanjuje za oko 60 %. Prema prometnim kriterijima razvijenosti ona su na najnižoj mogućoj razvijenosti prema frekvenciji polazaka i gustoći stajališta. Umanjenje cijene smatra se pravičnim s gledišta prometne razvijenosti i s gledišta kvalitete usluge koja se pruža putnicima unutar navedenih naselja.

Cijene su jednokratnoga putovanja unutar zone za sve tarifne zone studije slučaja prikazane u Prilogu 10. Najveća je promjena cijene primjenom pravičnoga tarifnoga modela bila kod zona s najvećom srednjom duljinom linije i najvećim koeficijentima pravičnosti. Tako je tarifnoj zoni, odnosno naselju Sisak cijena porasla s 12,81 kn na 18,72 kn. Kod manje razvijenih naselja i srednja je duljina linija relativno mala pa su i cijene zona manje. Prema koeficijentu pravičnosti najmanje je razvijeno naselje Donji Cerovljani. Cijena je prema osnovnom modelu od 0,97 kn snižena u pravičnom tarifnom modelu na 0,38 kn.

Postavlja se pitanje različitosti tarifnih modela kod putovanja kroz više tarifnih zona. Prema osnovnom modelu cijena jednokratnoga putovanja u urbanoj sredini Sisačko-moslavačke županije na dionici Sisak – Petrinja (zbrajanje zona Sisak, Mošćenica i Petrinja) iznosi 28,67 kn, što je približno jednako postojećem relacijskom tarifnom sustavu (29,00 kn), dok u pravičnom tarifnom sustavu cijena jednokratnoga putovanja iznosi 38,28 kn. Zbog visoke je razvijenosti navedenih urbanih sredina došlo do povećanja cijene od 33 %. Treba uzeti u obzir kako su cijene po kilometru unutar tarifnih sustava podložne promjeni i kako ovise isključivo o prijevoznicima i prijevozničkom tijelu koje je nadležno za integrirani prijevoz

putnika nekoga područja. Osim navedenoga, kod zbrajanja tarifnih zona primjenjuje se degresivnost cijena. Tako bi sa svakom novom zonom cijena po zoni padala u određenom postotku ovisno o odluci prijevoznika. Primjer je izračuna cijena u ruralnim područjima dionica Blinjski Kut – Sunja. Na navedenoj dionici približno iste duljine kao i urbana dionica iz primjera putnik prelazi broz 7 manjih tarifnih zona (Blinjski Kut, Kinjačka, Brđani Kosa, Brđani Cesta, Petrinjci, Drljača i Sunja).

Prema osnovnom modelu cijena jednokratnoga putovanja u ruralnoj sredini Sisačko-moslavačke županije na dionici Blinjski Kut – Sunja iznosi 23,60 kn, dok u pravičnom tarifnom sustavu cijena jednokratnoga putovanja iznosi 18,88 kn. Zbog niske je razvijenosti navedenih ruralnih naselja došlo do smanjenja cijene za 25 %. Navedena dionica nije izrazito nerazvijena zbog postojanja autobusnoga i željezničkoga prometa, ali je velika razlika u frekventnosti polazaka i gospodarskih i demografskih karakteristika razvijenosti.

„A conclusion is the place

where you get tired of thinking"

Arthur Bloch

8. Zaključak

U zaključnom su poglavlju iznesena zaključna razmatranja o dobivenim rezultatima istraživanja, postavljenim znanstvenim hipotezama i ostvarenim znanstvenim doprinosima. Također, dan je i osvrt na potencijalne koristi razvijenoga modela u praksi te pogled u buduća istraživanja.

Javni prijevoz putnika karakterizira pristupačnost i raspoloživost uz jednake uvjete svima dostupne. Dodatna je pogodnost integriranoga prijevoza putnika kao koncepta vođenja javnoga prijevoza integracija svih načina prijevoza vođenih kroz određeno područje te mogućnost korištenja prijevozne usluge i presjedanja putnika s jednom prijevoznom kartom u svim dostupnim prijevoznim sredstvima. Takav koncept zahtijeva i jedinstveni tarifni sustav koji mora uskladiti želje i potrebe svih dionika u sustavu, odnosno putnika, prijevoznika i nadležnoga prijevozničkoga tijela.

Pregledom literature i analizom postojećih tarifnih sustava dolazi se do zaključka kako relacijski i zonski tarifni sustavi ne pružaju cjelovit pristup putnicima i kako prijevozna usluga nije svima pristupačna. Kako se pristupačnost odnosi na stanje u kojem financijski trošak putovanja ne predstavlja teret i nemogućnost pristupa pojedincu ili skupini ljudi, može se reći kako relacijski i zonski tarifni sustavi na koje utječu kilometri putovanja i veličina zone nisu u potpunosti pristupačni svima. Pojedinac ili skupina ljudi koji prebivaju na području s izrazito lošom uslugom javnoga prijevoza ili s malim primanjima ne mogu ostvariti prijevoznu uslugu u javnom prijevozu putnika. Tada javni prijevoz prestaje biti javni i postaje nepristupačan prijevoz, a pojedinac ili društvo postaje marginalizirano. Jednako tako raspoloživost javnoga prijevoza koja ponajprije označava učestalost, odnosno frekventnost polazaka nije ostvarena ako nema prijevozne usluge onda kada osoba ima potrebu za ostvarivanjem putovanja.

Kako bi se riješio navedeni problem marginaliziranosti pojedinih mogućih putnika, društva i prostora, nužna je promjena modela tarifnih sustava s ciljem izjednačavanja dionika u nepovoljnijem položaju i ostalih dionika, što dovodi do sprječavanja prometne marginaliziranosti prostora i društva koje migrira takvim područjima. Ovim je istraživanjem razvijen pravični tarifni model koji omogućava sprječavanje prometne marginaliziranosti davanjem dodatne naklonosti dionicima u nepovoljnijem položaju s ciljem izjednačavanja.

Kroz predmet istraživanja postavljene su i potvrđene dvije znanstvene hipoteze. Prva je hipoteza potvrdila mogućnost definiranja i vrednovanja novih pravičnih kriterija pri određivanju tarifnih zona u integriranom prijevozu putnika kroz tri etape. U prvoj su etapi uspješno identificirani mogući pravični kriteriji koji se mogu iščitati kao kriteriji prometne, gospodarske i demografske razvijenosti područja, a koji s gledišta pravičnosti imaju utjecaj na tarifni sustav u prijevozu putnika. Nakon toga su, u drugoj etapi, s pomoću modeliranja sustavne dinamike i dijagrama uzročnih petlji definirani pravični kriteriji pri određivanju tarifnih zona u integriranom prijevozu putnika. U trećoj je etapi kroz vrednovanje definiranih kriterija s pomoću metode analitičkoga hijerarhijskoga procesa potvrđena prva hipoteza u cijelosti.

Postavljena druga hipoteza potvrđena je izradom modela pravičnoga tarifnoga sustava u integriranom prijevozu putnika na temelju novodefiniranih kriterija. Model je razvijen nadogradnjom osnovnoga modela s koeficijentom pravičnosti koji omogućuje regulaciju cijene tarifne zone i promjene iz jednakosti u pravičnost. Uvođenjem koeficijenta pravičnosti razmatra se dostupnost usluge, a cijena se prilagođava s gledišta jednake prometne, gospodarske i demografske razvijenosti područja koja su obuhvaćena javnim prijevozom, odnosno naselja kao tarifne zone.

Znanstveni je doprinos istraživanja doktorskoga rada u potvrđivanju hipoteza, a očituje se u utvrđivanju novih pravičnih kriterija i njihovom vrednovanju pri određivanju tarifnih zona u integriranom prijevozu putnika te u razvoju modela pravičnoga tarifnoga sustava u integriranom prijevozu putnika na temelju novih definiranih kriterija za određivanje tarifnih zona u integriranom prijevozu putnika. Testiranje je obavljeno na konkretnoj studiji slučaja uz jasan prikaz promjene iz jednakosti u pravičnost usporednom analizom osnovnoga i pravičnoga tarifnoga modela naplate u javnom prijevozu putnika. Za područje testiranja izabrana je Sisačko-moslavačka županija zbog svojih prometnih, gospodarskih i demografskih karakteristika razvijenosti, odnosno velikih različitosti unutar naselja koja su u njezinu sastavu.

Razvijenim se modelom i njegovom primjenom u praksi osigurava pravičnost naplate javnoga prijevoza putnika davanjem dodatne naklonosti dionicima u nepovoljnijem položaju s ciljem izjednačavanja. Smanjuje se mogućnost pojave marginaliziranih prostora, društvenih skupina i pojedinaca s gledišta usluge javnoga prijevoza. Povećava se prijevozna potražnja u ruralnim te demografski i gospodarski slabije razvijenim područjima zbog prilagođavanja cijene prijevozne usluge karakteristikama razvijenosti područja. U cijelosti se postiže smisao i vizija javnoga prijevoza putnika jer isti postaje dostupan svima po pravičnim, a ne jednakim uvjetima. Jednaki su uvjeti promatrani s gledišta jednake cijene po kilometru putovanja, ali ne i prema jednakoj kvaliteti pružene prijevozne usluge ili prema jednakoj razvijenosti u gospodarskom i demografskom smislu.

Provedenim je znanstvenim istraživanjem postavljen temelj u obliku prvoga modela pravičnoga tarifnoga sustava u integriranom prijevozu putnika. Samim time ostaje mnogo mogućnosti nadogradnje i razvoja za buduća istraživanja. Jedna se od mogućnosti daljnjega istraživanja javlja u razvoju modela pravičnoga zbrajanja tarifnih zona i primjeni degresivnih cijena za putovanja kroz više tarifnih zona. Otvaranje puta pravičnosti uz zatvaranje puta jednakosti nudi puno potencijala za znanstvene istraživače, slabije razvijena područja i društvo u cjelini.

LITERATURA

[1] Šipuš, D.; Abramović, B. 2018. Tariffing in Integrated Passenger Transport Systems: A literature review. *PROMET – Traffic&Transportation*. 30/6. 745–51.

[2] Čavrak, V. 2002. *Transport economics*. Zagreb. Škola za cestovni promet. 153 p.

[3] Bored panda. www.boredpanda.com/equality-equity-band-aid-student-lesson/?utm_source=google&utm_medium=organic&utm_campaign=organic. 2019.

[4] Šťastná, M.; Vaishar, A.; Stonawská, K. 2015. Integrated Transport System of the South-Moravian Region and its impact on rural development. *Transp Res Part D Transp Environ*. 36. 53–64.

[5] Li, CB.; Chen, WD.; Jia, HF. 2013. Study on the Development Mode of Integrated Passenger Transport in City. *Appl Mech Mater*. 361–363. 2040–4.

[6] Šťastná, M.; Vaishar, A. 2017. The relationship between public transport and the progressive development of rural areas. *Land use policy*. 67. May. 107–14.

[7] Šipuš, D.; Abramović, B. 2017. The Possibility of Using Public Transport in Rural Area. *Procedia Eng*. 192. 788–93.

[8] Kopecká, P.; Švetak, J. 2013. The Integrated Public transport system. *Sci J Marit Res*. 1. 149–56.

[9] Čejka, J.; Bartuška, L.; Turinská, L. 2017. Possibilities of Using Transport Terminals in South Bohemian Region. *Open Eng*. 7/1. 55–9.

[10] Filipović, S.; Tica, S.; Živanović, P.; Milovanović, B. 2009. Comparative analysis of the basic features of the expected and perceived quality of mass passenger public transport service in Belgrade. *Transport.* 24/4. 265–73.

[11] Sumaedi, S.; Bakti, IGMY.; Rakhmawati, T.; Astrini, NJ.; Widianti, T.; Yarmen, M. 2016. Factors influencing public transport passengers' satisfaction: a new model. *Manag Environ Qual An Int J.* 27/5. 585–97.

[12] Stopka, O.; Bartuška, L.; Kampf, R. 2015. Passengers' Evaluation of the Integrated Transport Systems. *Naše more*. 62. (SI). 153–7.

[13] Reis, V.; Macario, R. 2015. Promoting integrated passenger transport solutions using a business approach. *Case Stud Transp Policy.* 3/1. 66–77.

[14] Borndorfer, R.; Pfetsch, M.; Neumann, M. 2008. Models for Fare Planning in Public Transport. *Zib-Report*. 16. July.

[15] Borndörfer, R.; Karbstein, M.; Pfetsch, M. 2012. Models for fare planning in public transport. *Discret Appl Math.*160/18. 2591–605.

[16] Huang, D.; Liu, Z.; Liu, P.; Chen, J. 2016. Optimal transit fare and service frequency of a nonlinear origin- destination based fare structure. *Transp Res Part E*. 96. 1–19.

[17] Drdla, P.; Bulíček, J. 2012. Fare collection system in integrated public passenger transport systems. VII/2. 22–33.

[18] Bouteiller, C.; Faivre d'Arcier, B. 2015. How fare simulation tools in urban public

transport can benefit from smart card data analysis? *CUPUM 2015*.

[19] Kohání, M. 2015. Tariff Zones Design in Integrated Transport Systems: a case study for the Žilina Municipality. *Mech Energy. Environ*. 91–7.

[20] Kohání, M. 2012. Exact approach to the tariff zones design problem in public transport. *Proc 30th Int Conf Math Methods Econ Exact*. 426–31.

[21] Hamacher, HW.; Schöbel, A. 2001. Design of Zone Tariff Systems in Public Transportation. *Berichte des Fraunhofer ITWM*. 21/21.

[22] Jansson, K. 1993. Optimal public transport price and servise frequency. *J Transp Econ policy.*

[23] Chowdhury, S. 2016. Users ' willingness to ride an integrated public-transport service: A literature review. *Transp Policy*. 48. 183–95.

[24] Chen, XM.; Yin, M.; Song, M.; Zhang, L.; Li, M. 2014. Social Welfare Maximization of Multimodal Transportation. *Transp Res Rec J Transp Res Board.* 2451. 36–49.

[25] Holmgren, J. 2014. Research in Transportation Economics A strategy for increased public transport usage – The effects of implementing a welfare maximizing policy. *Res Transp Econ*. 48. 221–6.

[26] Guzman, LA.; De, D.; Circella, G. 2014. Case Studies on Transport Policy Evaluation of synergies from transportation policy packages using a social welfare maximization approach: A case study for Madrid, Spain. *Case Stud Transp Policy*.

[27] Čarný, Š.; Zitrický, V.; Šipuš, D. 2020. Harmonization of Transport Charging in Slovak Republic. *LOGI – Sci J Transp Logist.* 11/1. 12.

[28] Houston, D.; Tilley, S. 2015. Fare's fair? Concessionary travel policy and social justice. *J Poverty Soc Justice*. 24/2. 187–207.

[29] Gašparović, S. 2016. Theoretical Postulates of Transport Disadvantage. *Hrvat Geogr Glas*. 78/1. 73–95.

[30] Martens, K. 2017. *Transport Justice: Designing Fair Transportation Systems*. New York. Routledge. 240 p.

[31] Nejašmić, I. 2005. *Demogeography: Population in spatial relations and processes.* Zagreb. Školska knjiga. 283 p.

[32] Perisic, A.; Wagner, V. 2015. Indeks Razvijenosti : Analiza Temeljnog Instrumenta Hrvatske Regionalne Politike. *Financ Theory Pract.* 39/2. 205–36.

[33] Nejašmić, I. 1998. *Elements of geography*. Zagreb. Educa. 396 p.

[34] Lamza-Maronić, M.; Tokić, I. 2013. Utjecaj demografskih čimbenika na društveno-ekonomski razvoj Hrvatske. *Ekonomski vjesnik.* Ekonomski fakultet u Osijeku. 12/2. 263–72.

[35] Vlada Republike Hrvatske. 2017. *Uredba o indeksu razvijenosti* [Internet]. Vol. 1. Narodne novine. Available from: http://e-journal.usd.ac.id/index.php/LLT%0Ahttp://jurnal.untan.ac.id/index.php/jpdpb/article/viewFile/11345/10753%0Ahttp://dx.doi.org/10.1016/j.sbspro.2015.04.758%0Awww.iosrjournals.org.

[36] Braičić, Z.; Lončar, J. 2011. Intra-Regional Disparities in Sisak-Moslavina County. *Geoadria*. 1. 93–118.

[37] Denona Bogović, N.; Drezgič, S.; Čegar, S. 2017. *Evaluacija postojećeg i prijedlog novog modela za izračun indeksa razvijenosti jedinica lokalne i područne samouprave u Republici Hrvatskoj* [Internet]. Vol. 1. Ekonomski fakultet Sveučilište u Rijeci. Available from: https://repositorio.ufsc.br/bitstream/handle/123456789/186602/PPAU0156-D.pdf?sequence=-1&isAllowed=y%0Ahttp://journal.stainkudus.ac.id/index.php/equilibrium/article/view/1268/1127%0Ahttp://www.scielo.br/pdf/rae/v45n1/v45n1a08%0Ahttp://dx.doi.org/10.1016/j.

[38] Blanchard, O. 2011. *Makroekonomija*. 5. izdanje. Mate d.o.o. 680 p.

[39] Denona Bogović, N.; Drezgič, S.; Čegar, S. 2017. *Evaluacija postojećeg i prijedlog novog modela za izračun indeksa razvijenosti jedinica lokalne i područne samouprave u Republici Hrvatskoj*. Vol. 1. Ekonomski fakultet Sveučilište u Rijeci.

[40] Vlada Republike Hrvatske. 2017. *Uredba o indeksu razvijenosti*. Vol. 1. Narodne novine.

[41] Abramović, B.; Šipuš, D. 2020. Quality Assessment of Regional Railway Passenger Transport. *Springer International Publishing.* 86–96.

[42] Blašković Zavada, J.; Abramović, B.; Šipuš, D. 2017. A Strategic Model of Sustainable Mobility in the City of Zagreb and Its Surrounding Area. *Int J Traffic Transp Eng.* 7/4. 430–42.

[43] *Vienna C of. Urban mobility plan Vienna.* Step 2025. Vienna. 2014.

[44] *R. White P. Public Transport: Its Planning, Management and Operation*. 6th Edition. 6th ed. New York. Routledge. 2017. 278 p.

[45] Rodrigue, J-P.; Comtois, C.; Slack, B. 2017. *The Geography of Transport Systems.* 4th ed. New York. Routledge. 440 p.

[46] Šipuš, D.; Abramović, B.; Gašparović, S. 2019. Equity fare system: Factors affecting fare structure in integrated passenger transport. *Transp Res Procedia.* 40. 1192–8.

[47] Stopka, O.; Bartuška, L.; Kampf, R. 2015. Passengers' Evaluation of the Integrated Transport Systems. *Naše more* [Internet]. 62(SI):153–7. Available from: http://www.nasemore.com/web/index.php/arhiv/2015/vo-62-special-issue/437-passengers-evaluation-of-the-integrated-transport-systems.

[48] Bertalanffy, L Von. 1968. *General System Theory: Foundations, Development, Applications.* New York. George Braziller. 289 p.

[49] Božikov, J.; Petrovečki, M.; Deželić, G. 2009. *Modeliranje i simulacija*. In: Medicinska informatika. Zagreb. Medicinska naklada. p. 9.

[50] Turina, A. 2009. Primjena metodologije sistemske dinamike u analizi stanovništva. *Migracijske i etničke teme.* 25/3. 189–211.

[51] Sterman, J. 2000. *Business Dynamics: Systems Thinking and Modeling for a Complex World*. McGraw-Hill. 1008 p.

[52] Barić, D. 2010. *Model planiranja prometno-tehnoloških projekata u funkciji razvoja*

željeznice. Fakultet prometnih znanosti. Sveučilište u Zagrebu.

[53] Barić, D.; Čurepić, D.; Radačić, Ž. 2007. Implementation of relevant methods in assessing traffic-technological projects. *Promet - Traffic - Traffico.* 19/5. 329–36.

[54] Pilko, H. 2014. *Optimization of Roundabout Design and Safety Component.* Faculty of Transport and Traffic Sciences. University of Zagreb.

[55] Noordzij, M.; Tripepi, G.; Dekker, FW.; Zoccali, C.; Tanck, MW.; Jager, KJ. 2010. Sample size calculations: Basic principles and common pitfalls. *Nephrol Dial Transplant*. 25/10. 3461–2.

[56] Israel, Glenn D. 1953. Determining Sample Size. *Can Entomol.* 85/3. 108–13.

[57] Schöbel, A. 2006. Optimization in Public Transportation. *Springer*. Boston. MA. 274 p.

[58] Hamacher, HW.; Schöbel, A. 1995. *On Fair Zone Designs in Public Transportation.* 430 (January). 9–11. Available from: http://link.springer.com/10.1007/978-3-642-57762-8

[59] Schöbel, A. 1995. *Fair Zone Design in Public Transportation Networks.* January 1995. 191–6.

[60] Harnacher, HW.; Schöbel, A. 2004. Design of zone tariff systems in public transportation. *Oper Res.* 52/6. 897–908.

[61] Ostojić, M. 2015. *Tarifa i sustavi naplate u javnom gradskom prijevozu.* University of Zagreb. Faculty of Transport and Traffic Sciences.

[62] Babel, L.; Kellerer, H. 2003. Design of tariff zones in public transportation networks: Theoretical results and heuristics. *Math Methods Oper Res.* 58/3. 359–74.

[63] Šošić, I. 2006. *Primijenjena statistika.* Školska knjiga. Zagreb. 792 p.

[64] Abramović, B.; Šipuš, D.; Jurešić, D. 2020. Organisation of Integrated Passenger Transport on the Zagreb – Velika Gorica Route. *Transp Res Procedia.* 342–7.

[65] Abramović, B.; Šipuš, D.; Šimunović, L.; Panak, M. 2017. Proposal of the Tariff Model in Integrated Passengers Public Transport. In: *Horizons of Railway Transport 2017.* Žilina: University of Žilina. 12–9.

[66] Abramović, B.; Šipuš, D. 2015. Proposal of Improvements to mobility in the City of Sisak. Železničná doprava a logistika. *Railw Transp Logist.* 11/1. 4–11.

[67] Vlada Republike Hrvatske. 2017. *Odluka o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti.* Zagreb.

[68] Sisačko-moslavačka županija. 2017. *Razvojna strategija Sisačko-moslavačke županije 2017. – 2020.* Sisak.

[69] Sisačko-moslavačka županija. 2019. *Masterplan prometnog razvoja Sisačko-moslavačke županije.* 385(0).

[70] Šipuš, D.; Abramović, B.; Černá, L.; Nedeliakova, E. 2018. Transport demand analysis in the Rural Area: The Case Study Of Sisak – Moslavina County. In: Čokorilo O, editor. Proceedings of the Fourth International Conference on Traffic and Transport Engineering. Beograd: *City Net Scientific Research Center Ltd. Belgrade*. p. 9.

[71] Abramović, B.; Šipuš, D. 2016. The Comparative Analysis of Transport Service Quality

in Regional Rail and Bus Traffic. In: *Horizons of Railway Transport*.

[72] Abramović, B.; Šipuš, D.; Ontl, L. 2020. Analysis of Exploitation Indicators in Passenger Railway Transport in Sisak-Moslavina County. *Transp Res Procedia*. 327–31.

[73] Grad Sisak. 2016. *Projekt izrade plana održive urbane mobilnosti Grada Siska (SUMP)*. Sisak.

POPIS SLIKA

Slika 1. Različitost jednakosti i pravičnosti u prometu [3] 2
Slika 2. Odnos dionika u stvaranju tarifnoga sustava [16] 12
Slika 3. Proces simulacijskoga modeliranja [49] 32
Slika 4. Dijagram uzročnih petlji razmještaja stanovništva 40
Slika 5. Dijagram uzročnih petlji kretanja stanovništva 40
Slika 6. Dijagram uzročnih petlji sastava stanovništva 42
Slika 7. Dijagram uzročnih petlji demografskih kriterija razvijenosti 43
Slika 8. Dijagram uzročnih petlji dohodovne razvijenosti 44
Slika 9. Dijagram uzročnih petlji razvijenosti proračunskih prihoda jedinice lokalne, odnosno područne (regionalne) samouprave 45
Slika 10. Dijagram uzročnih petlji razvijenosti prema zapošljivosti 46
Slika 11. Dijagram uzročnih petlji gospodarskih kriterija razvijenosti 47
Slika 12. Dijagram uzročnih petlji razvijenosti gustoće mreže JPP-a 48
Slika 13. Dijagram uzročnih petlji razvijenosti mreže JPP-a 49
Slika 14. Dijagram uzročnih petlji razvijenosti frekvencije polazaka u JPP-u 50
Slika 15. Dijagram uzročnih petlji razvijenosti demografske gustoće JPP-a 50
Slika 16. Dijagram uzročnih petlji razvijenosti gustoće stajališta JPP-a 52
Slika 17. Dijagram uzročnih petlji prometnih kriterija razvijenosti 53
Slika 18. Hijerarhijska struktura AHP metode [54] 60
Slika 19. Hijerarhijska struktura AHP modela 69
Slika 20. Rezultati vrednovanja kriterija s pripadajućim težinskim koeficijentima AHP modela 70
Slika 21. Rezultati vrednovanja prometnih kriterija, odnosno potkriterija AHP modela s pripadajućim težinskim koeficijentima 70
Slika 22. Rezultati vrednovanja gospodarskih kriterija, odnosno potkriterija AHP modela s pripadajućim težinskim koeficijentima 70
Slika 23. Rezultati vrednovanja demografskih kriterija, odnosno potkriterija AHP modela s pripadajućim težinskim koeficijentima 70
Slika 24. Analiza osjetljivosti kriterija i potkriterija na temelju pripadajućih težinskih koeficijenata AHP modela 72
Slika 25. Rezultat vrednovanja kriterija i potkriterija za definiranje cijene tarifne zone u AHP modelu 73
Slika 26. Usporedni rezultati vrednovanja kriterija i potkriterija stručnjaka iz Republike Hrvatske, stručnjaka iz inozemstva i ukupnih rezultata 74
Slika 27. Položaj Sisačko-moslavačke županije u odnosu na granične županije [69] 86

Slika 28. Podjela Sisačko-moslavačke županije na urbana i ruralna naselja [70] 89

Slika 29. Cestovna i željeznička infrastruktura na području Sisačko-moslavačke županije s prikazom urbanih i ruralnih područja 90

Slika 30. Udio korištenih načina prijevoza tijekom putovanja u Gradu Sisku [73] 90

Slika 31. Linije javnoga prijevoza putnika u autobusnom i željezničkom prijevozu unutar Sisačko-moslavačke županije 90

Slika 32. Stajališta javnoga prijevoza putnika u autobusnom i željezničkom prijevozu unutar Sisačko-moslavačke županije 93

Slika 33. Analiza JPP-a u naseljima Sisačko-moslavačke županije 94

Slika 34. Analiza frekvencije polazaka po stajalištima unutar naselja Sisačko-moslavačke županije 98

Slika 35. Analiza gustoće mreže JPP-a unutar naselja Sisačko-moslavačke županije 99

Slika 36. Analiza demografske gustoće mreže JPP-a unutar naselja Sisačko-moslavačke županije 100

Slika 37. Analiza gustoće stajališta u JPP-u unutar naselja Sisačko-moslavačke županije ... 100

Slika 38. Analiza dohotka po stanovniku unutar naselja Sisačko-moslavačke županije 106

Slika 39. Analiza stope nezaposlenosti unutar naselja Sisačko-moslavačke županije 107

Slika 40. Analiza proračunskih prihoda po stanovniku unutar naselja Sisačko-moslavačke županije 108

Slika 41. Analiza gustoće stanovništva unutar naselja Sisačko-moslavačke županije 111

Slika 42. Analiza općega kretanja stanovništva unutar naselja Sisačko-moslavačke županije 112

Slika 43. Analiza radnoga kontingenta stanovništva unutar naselja Sisačko-moslavačke županije 113

Slika 44. Analiza koeficijenta pravičnosti unutar naselja Sisačko-moslavačke županije 116

Slika 45. Analiza cijene tarifnih zona unutar Sisačko-moslavačke županije prema pravičnom tarifnom modelu 117

POPIS TABLICA

Tablica 1. Simboli, značenje, primjeri i grafikoni u dijagramima uzročnih petlji (CLD) [51]37

Tablica 2. *Saatyjeva* skala vrednovanja relativne važnosti dvaju kriterija [54] 60

Tablica 3. Prosječna vrijednost konzistencije RI [54] 62

Tablica 4. Potrebna veličina uzorka za ± 3 %, ± 5 %, ±7 %, i ±10 % stupanj preciznosti uz razinu pouzdanosti od 95 % [50] 63

Tablica 5. Postotak odgovorenih upitnika prema zemljama zaposlenja stručnjaka 66

Tablica 6. Postotak odgovorenih upitnika prema institucijama zaposlenja stručnjaka 67

Tablica 7. Postotak odgovorenih upitnika prema godinama zaposlenja stručnjaka 67

Tablica 8. Postotak odgovorenih upitnika prema stručnoj spremi stručnjaka 68

Tablica 9. Postotak odgovorenih upitnika prema ekspertizi stručnjaka 68

Tablica 10. Postotak odgovorenih upitnika prema utjecaju problematike ankete 68

Tablica 11. Prikaz pravičnih kriterija i potkriterija s njihovim težinskim koeficijentima 80

Tablica 12. Dohodak po stanovniku u općinama i gradovima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija 102

Tablica 13. Stopa nezaposlenosti u općinama i gradovima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija 104

Tablica 14. Proračunski prihodi po stanovniku u općinama i gradovima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija 105

PRILOZI

Prilog 1. Anketa za vrednovanje pravičnih kriterija (*Google Forms obrazac*)

Određivanje važnosti kriterija za definiranje cijene tarifne zone u javnom prijevozu putnika

Cilj ankete je prikupljanje znanja od eminentnih stručnjaka iz područja prometa, gospodarstva i demografije o važnosti pojedinih kriterija za određivanje cijene tarifne zone u javnom prijevozu putnika. Tarifna zona predstavlja geografski određeno područje u kojemu se obavlja jedinstvena naplata prijevozne usluge u javnom prijevozu putnika.

Prometna, gospodarska i demografska različitost tarifnih zona u javnom prijevozu putnika direktno utječe na određivanje različite cijene svake tarifne zone.

*Obavezno

Postavlja se pitanje koliko bi na cijenu pojedine tarifne zone trebala utjecati prometna razvijenost u smislu prijevozne ponude u javnom prijevozu putnika, dostupnosti i kvalitete prijevozne usluge. Isto tako u kojoj mjeri bi na cijenu tarifne zone trebali utjecati gospodarski kriteriji razvijenosti koji su ujedno i pokazatelj bogatstva područja koje obuhvaća tarifna zona, te demografski kriteriji razvijenosti koji govore o stanovništvu koje se nalazi u tarifnoj zoni.

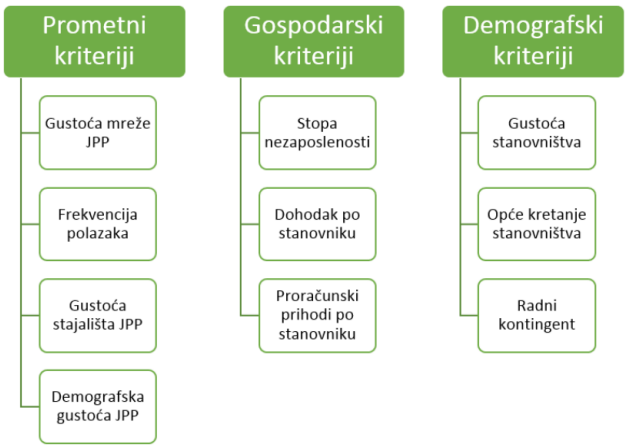

Izvor: Autor

Jednakost u odnosu na pravičnost

Postizanje pravičnosti u tarifnim sustavima javnog prijevoza putnika je moguće reguliranjem cijene prijevozne usluge temeljem navedenih pokazatelja razvijenosti. Tako dizajnirani tarifni sustavi značili bi smanjenje cijene prijevoznih usluga u tarifnim zonama koje prometno, gospodarski ili demografski zaostaju u razvoju u odnosu na ostale.

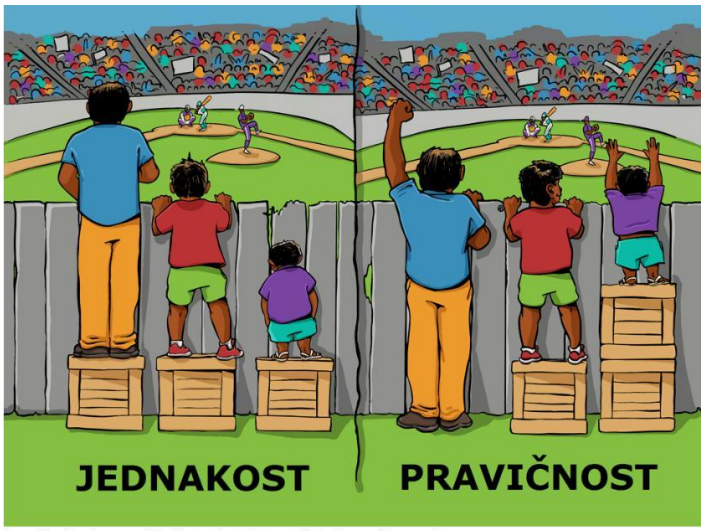

Izvor: Obradio autor prema https://interactioninstitute.org/illustrating-equality-vs-equity

Anketa će poslužiti pri definiranju pravičnih kriterija razvijenosti za određivanje tarifnih zona u integriranom prijevozu putnika u sklopu izrade doktorske disertacije pod nazivom „Razvoj pravičnoga tarifnoga modela u integriranom prijevozu putnika" doktoranda Denisa Šipuša, mag. ing. traff. pod mentorstvom izv. prof. dr. sc. Borne Abramovića sa Fakulteta prometnih znanosti Sveučilišta u Zagrebu.

Anketni upitnik je podijeljen na pet cjelina. U prvoj cjelini nalaze se uvodna pitanja. U preostalim cjelinama je potrebno rangirati određene kriterije s obzirom na njihovu redoslijednu važnost (1 – prvo po važnosti, 2 – drugo po važnosti i sl.) te potom međusobno uspoređivati dva određena kriterija gdje se primjenjuje sljedeće ocjenjivanje:
1 – Jednako važno
2 – Umjereno važno
3 – Strogo važnije
4 – Vrlo stroga, dokazana važnost
5 – Ekstremna važnost

Za potrebe izrade doktorske disertacije ocijenjeni kriteriji će se uskladiti sa teorijom Analitičkog hijerarhijskog procesa - AHP (engl. Analytic Hierarchy Process) temeljem kojeg će se simulirati važnosti kriterija putem računalnog alata Expert Choice.

Anketa je u potpunosti anonimna, a vrijeme potrebno za ispunjavanje ankete je otprilike 15 minuta.

Za eventualna pitanja možete se obratiti putem e-maila na adresu denis.sipus@fpz.hr.

Unaprijed zahvaljujem na ispunjavanju ankete,
Denis Šipuš, mag.ing.traff.

1. 1. Država zaposlenja? *

Označite samo jedan oval.

- Hrvatska
- Austrija
- Bosna i Hercegovina
- Bugarska
- Češka
- Francuska
- Grčka
- Italija
- Litva
- Mađarska
- Nizozemska
- Njemačka
- Poljska
- Rumunjska
- Slovačka
- Slovenija
- Srbija
- Švedska
- Ujedinjeno Kraljevstvo

2. 2. Gdje ste trenutno zaposleni? *

Označite samo jedan oval.

- Institut
- Obrazovna institucija (Sveučilište, Veleučilište)
- Prijevozničke tvrtka
- Tijelo državne uprave (Ministarstvo, Grad, Općina i sl.)
- Ostalo: _____

3. 3. Koliko ste dugo zaposleni na trenutnom radnom mjestu? *

Označite samo jedan oval.

- Do 10 godina
- 11 - 20 godina
- 21 - 30 godina
- Više od 30 godina

4. 4. Koja je Vaša stručna sprema?

* *Označite samo jedan oval.*

- Visoka stručna sprema (mag. ing. ili dipl. ing.)
- Magisterij znanosti (mr. sc.)
- Sveučilišni specijalist (spec.)
- Doktorat znanosti (dr. sc.)

5. 5. Na Vašem radnom mjestu najviše se bavite sljedećom problematikom: *

Označite samo jedan oval.

- Promet
- Gospodarstvo
- Demografija
- Ostalo: _____

6. 6. U kojoj mjeri Vaš trenutni posao utječe na problematiku ankete? *

1 - Uopće ne utječe, 2 - Slabo utječe, 3 - Srednje utječe , 4 - Bitno utječe, 5 - Ekstremno utječe

Označite samo jedan oval.

	1	2	3	4	5	
Uopće ne utječe						Ekstremno utječe

ODREĐIVANJE VAŽNOSTI KRITERIJA ZA DEFINIRANJE CIJENE TARIFNE ZONE

7. 7. Za definiranje cijene tarifnih zona u javnom prijevozu putnika rangirajte po redoslijedu važnosti (od 1 do 3) sljedeće kriterije: *

1 - najvažnije, 2 - srednje važno, 3 - najmanje važno

Označite samo jedan oval po retku.

	1	2	3
Prometni			
Gospodarski			
Demografski			

8. 8. Obzirom na prethodno definirane važnosti usporedite pojedinačno relativnu važnost sljedećih kriterija: *

Ako smatrate da Prvo navedeni kriterij ima veću važnost od Drugog navedenog kriterija potrebno je označiti vrijednost lijevo od 1. Ako oba kriterija imaju jednaku važnost potrebno je označiti 1. Ako Drugi navedeni kriterij ima veću važnost od Prvo navedenog kriterija potrebno je označiti vrijednost desno od 1.

Označite samo jedan oval po retku.

	5 (Ekstremna)	4 (Vrlo stroga)	3 (Stroga)	2 (Umjerena)	1 (Jednaka)	2 (Umjerena)	3 (Stroga)	4 (Vrlo stroga)	5 (Ekstremna)
Prometni - Gospodarski									
Prometni - Demografski									
Gospodarski - Demografski									

ODREĐIVANJE VAŽNOSTI UNUTAR PROMETNIH KRITERIJA ZA DEFINIRANJE CIJENE TARIFNE ZONE

JPP - Javni prijevoz putnika

Gustoća mreže JPP - odnos duljine mreže JPP i površine tarifne zone

JPP koja u jedinici vremena polaze sa stajališta

Demografska gustoća - odnos duljine mreže JPP i broja stanovnika

Frekvencija polazaka - ukupan broj vozila

Gustoća stajališta JPP - odnos broja stajališta JPP i površine tarifne zone

9. 9. Za definiranje cijene tarifnih zona u javnom prijevozu putnika rangirajte po redoslijedu važnosti (od 1 do 4) sljedeće prometne kriterije: *

1 - najvažnije, 2 - jako važno, 3 - srednje važno, 4 - najmanje važno

Označite samo jedan oval po retku.

	1	2	3	4
Gustoća mreže JPP	⬭	⬭	⬭	⬭
Frekvencija polazaka	⬭	⬭	⬭	⬭
Gustoća stajališta JPP	⬭	⬭	⬭	⬭
Demografska gustoća JPP	⬭	⬭	⬭	⬭

10. 10. Obzirom na prethodno definirane važnosti usporedite pojedinačno relativnu važnost sljedećih prometnih kriterija: *

Ako smatrate da Prvo navedeni kriterij ima veću važnost od Drugog navedenog kriterija potrebno je označiti vrijednost lijevo od 1. Ako oba kriterija imaju jednaku važnost potrebno je označiti 1. Ako Drugi navedeni kriterij ima veću važnost od Prvo navedenog kriterija potrebno je označiti vrijednost desno od 1.

Označite samo jedan oval po retku.

	5 (Ekstremna)	4 (Vrlo stroga)	3 (Stroga)	2 (Umjerena)	1 (Jednaka)	2 (Umjerena)	3 (Stroga)	4 (Vrlo stroga)	5 (Ekstremna)
Gustoća mreže - Frekvencija polazaka	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Gustoća mreže - Gustoća stajališta	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Gustoća mreže - Demografska gustoća	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Frekvencija polazaka - Gustoća stajališta	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Frekvencija polazaka - Demografska gustoća	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭
Gustoća stajališta - Demografska gustoća	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭	⬭

ODREĐIVANJE VAŽNOSTI UNUTAR GOSPODARSKIH KRITERIJA ZA DEFINIRANJE CIJENE TARIFNE ZONE

Stopa nezaposlenosti - odnos broja nezaposlenih stanovnika prema ukupnom broju evidentirane radne snage
Dohodak po stanovniku - odnos ukupnog iznosa dohodaka stanovnika i broja stanovnika Proračunski prihodi po stanovniku - odnos ostvarenih prihoda jedinica lokalne, područne samouprave i broja stanovnika

11. 11. Za definiranje cijene tarifnih zona u javnom prijevozu putnika rangirajte po redoslijedu važnosti (od 1 do 3) sljedeće gospodarske kriterije: *

1 - najvažnije, 2 - srednje važno, 3 - najmanje važno

Označite samo jedan oval po retku.

	1	2	3
Stopa nezaposlenosti	⬭	⬭	⬭
Dohodak po stanovniku	⬭	⬭	⬭
Proračunski prihodi po stanovniku	⬭	⬭	⬭

12. 12. Obzirom na prethodno definirane važnosti usporedite pojedinačno relativnu važnost sljedećih gospodarskih kriterija: *

Ako smatrate da Prvo navedeni kriterij ima veću važnost od Drugog navedenog kriterija potrebno je označiti vrijednost lijevo od 1. Ako oba kriterija imaju jednaku važnost potrebno je označiti 1. Ako Drugi navedeni kriterij ima veću važnost od Prvo navedenog kriterija potrebno je označiti vrijednost desno od 1.

Označite samo jedan oval po retku.

	5 (Ekstremna)	4 (Vrlo stroga	3 (Stroga)	2 (Umjerena)	1 (Jednaka)	2 (Umjerena)	3 (Stroga)	4 (Vrlo stroga)	5 (Ekstremna)
Stopa nezaposlenosti - Dohodak po stanovniku	◯	◯	◯	◯	◯	◯	◯	◯	◯
Stopa nezaposlenosti - Proračunski prihodi po stanovniku	◯	◯	◯	◯	◯	◯	◯	◯	◯
Dohodak po stanovniku - Proračunski prihodi po stanovniku	◯	◯	◯	◯	◯	◯	◯	◯	◯

ODREĐIVANJE VAŽNOSTI UNUTAR DEMOGRAFSKIH KRITERIJA ZA DEFINIRANJE CIJENE TARIFNE ZONE

Gustoća stanovništva - odnos broja stanovnika i površine područja
Opće kretanje stanovništva - razlika u broju stanovnika između dva međupopisna razdoblja Radni kontingent - broj stanovnika u dobi od 15 do 64 godine starosti

13. 13. Za definiranje cijene tarifnih zona u javnom prijevozu putnika rangirajte po redoslijedu važnosti (od 1 do 3) sljedeće demografske kriterije: *

1 - najvažnije, 2 - srednje važno, 3 - najmanje važno

Označite samo jedan oval po retku.

	1	2	3
Gustoća stanovništva	◯	◯	◯
Opće kretanje stanovništva	◯	◯	◯
Radni kontingent (15-64)	◯	◯	◯

14. 14. Obzirom na prethodno definirane važnosti usporedite pojedinačno relativnu važnost sljedećih demografskih kriterija: *

Ako smatrate da Prvo navedeni kriterij ima veću važnost od Drugog navedenog kriterija potrebno je označiti vrijednost lijevo od 1. Ako oba kriterija imaju jednaku važnost potrebno je označiti 1. Ako Drugi navedeni kriterij ima veću važnost od Prvo navedenog kriterija potrebno je označiti vrijednost desno od 1.

Označite samo jedan oval po retku.

	5 (Ekstremna)	4 (Vrlo stroga)	3 (Stroga)	2 (Umjerena)	1 (Jednaka)	2 (Umjerena)	3 (Stroga)	4 (Vrlo stroga)	5 (Ekstremna)
Gustoća stanovništva - Opće kretanje stanovništva	◯	◯	◯	◯	◯	◯	◯	◯	◯
Gustoća stanovništva - Radni kontingent	◯	◯	◯	◯	◯	◯	◯	◯	◯
Opće kretanje stanovništva - Radni kontingent	◯	◯	◯	◯	◯	◯	◯	◯	◯

Zahvaljujem na ispunjavanju ankete!

Za rezultate ankete slobodno se obratiti putem e-maila na adresu denis.sipus@fpz.hr.

Denis **Šipuš**, mag.ing.traff.

Google nije izradio niti podržava ovaj sadržaj.

Google Obrasci

Prilog 2. Frekvencije polazaka po stajalištu u naseljima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

Grad/Općina	Naselje	*Broj polazaka u JPP-u (autobus + vlak)*	*Broj stajališta JPP-a (autobusna + željeznička)*	**Frekvencija polazaka [broj dnevnih polazaka po stajalištu]**	**Parametar pravičnoga potkriterija e_{sp1}**
LEKENIK	Žažina	43	1	43,00	2,00
SISAK	Sisak	1.578	45	35,07	1,79
SISAK	Sela	66	2	33,00	1,74
PETRINJA	Mošćenica	61	2	30,50	1,67
SISAK	Stupno	54	2	27,00	1,58
SISAK	Odra Sisačka	50	2	25,00	1,53
PETRINJA	Petrinja	206	9	22,89	1,48
LEKENIK	Pešćenica	67	3	22,33	1,46
LEKENIK	Lekenik	84	4	21,00	1,43
LEKENIK	Donji Vukojevac	20	1	20,00	1,40
SISAK	Budaševo	76	5	15,20	1,28
POPOVAČA	Popovača	59	4	14,75	1,26
KUTINA	Repušnica	38	3	12,67	1,21
POPOVAČA	Voloder	38	3	12,67	1,21
POPOVAČA	Gornja Gračenica	62	5	12,40	1,20
GLINA	Glina	12	1	12,00	1,19
PETRINJA	Gora	12	1	12,00	1,19
PETRINJA	Graberje	12	1	12,00	1,19
GLINA	Marinbrod	24	2	12,00	1,19
PETRINJA	Novo Selište	12	1	12,00	1,19
GLINA	Prekopa	12	1	12,00	1,19
PETRINJA	Župić	12	1	12,00	1,19
SISAK	Greda	93	8	11,63	1,18
NOVSKA	Rajić	11	1	11,00	1,17
KUTINA	Kutina	76	7	10,86	1,16
SISAK	Topolovac	54	5	10,80	1,16
LEKENIK	Dužica	20	2	10,00	1,14
SISAK	Novo Selo	20	2	10,00	1,14
SISAK	Prelošćica	60	6	10,00	1,14
SISAK	Gornje Komarevo	18	2	9,00	1,12
SISAK	Gušće	36	4	9,00	1,12
SISAK	Novo Pračno	18	2	9,00	1,12
NOVSKA	Novska	17	2	8,50	1,10
TOPUSKO	Batinova Kosa	8	1	8,00	1,09
SISAK	Blinjski Kut	32	4	8,00	1,09
PETRINJA	Brest Pokupski	8	1	8,00	1,09
SISAK	Donje Komarevo	16	2	8,00	1,09
GLINA	Gornji Viduševac	16	2	8,00	1,09
SISAK	Hrastelnica	32	4	8,00	1,09
PETRINJA	Mala Gorica	8	1	8,00	1,09
SISAK	Palanjek	24	3	8,00	1,09
LEKENIK	Petrovec	8	1	8,00	1,09
GLINA	Šatornja	8	1	8,00	1,09
TOPUSKO	Topusko	8	1	8,00	1,09
VELIKA LUDINA	Velika Ludina	16	2	8,00	1,09

NOVSKA	Nova Subocka	15	2	7,50	1,08
KUTINA	Banova Jaruga	28	4	7,00	1,06
KUTINA	Brinjani	7	1	7,00	1,06
KUTINA	Kutinska Slatina	7	1	7,00	1,06
KUTINA	Stupovača	7	1	7,00	1,06
KUTINA	Šartovac	7	1	7,00	1,06
HRVATSKA KOSTAJNICA	Panjani	6	1	6,00	1,04
HRVATSKA KOSTAJNICA	Hrvatska Kostajnica	17	3	5,67	1,03
SUNJA	Brđani Cesta	11	2	5,50	1,02
KUTINA	Ilova	16	3	5,33	1,02
SISAK	Čigoć	10	2	5,00	1,01
HRVATSKA DUBICA	Gornji Cerovljani	5	1	5,00	1,01
HRVATSKA DUBICA	Hrvatska Dubica	5	1	5,00	1,01
JASENOVAC	Jasenovac	5	1	5,00	1,01
KUTINA	Međurić	5	1	5,00	1,01
SISAK	Novo Selo	15	3	5,00	1,01
SUNJA	Papići	5	1	5,00	1,01
POPOVAČA	Potok	5	1	5,00	1,01
SUNJA	Staza	5	1	5,00	1,01
POPOVAČA	Stružec	5	1	5,00	1,01
SUNJA	Šaš	5	1	5,00	1,01
JASENOVAC	Višnjica	5	1	5,00	1,01
HRVATSKA DUBICA	Živaja	5	1	5,00	1,01
SUNJA	Sunja	14	3	4,67	1,00
LIPOVLJANI	Lipovljani	18	4	4,50	0,98
SISAK	Kratečko	13	3	4,33	0,95
PETRINJA	Bijelnik	4	1	4,00	0,87
PETRINJA	Blinja	4	1	4,00	0,87
SISAK	Crnac	12	3	4,00	0,87
PETRINJA	Donja Budičina	8	2	4,00	0,87
DONJI KUKURUZARI	Donja Velešnja	4	1	4,00	0,87
DONJI KUKURUZARI	Donji Kukuruzari	4	1	4,00	0,87
DONJI KUKURUZARI	Knezovljani	4	1	4,00	0,87
DONJI KUKURUZARI	Komogovina	4	1	4,00	0,87
LEKENIK	Letovanić	12	3	4,00	0,87
PETRINJA	Moštanica	4	1	4,00	0,87
DONJI KUKURUZARI	Prevršac	4	1	4,00	0,87
LEKENIK	Stari Brod	4	1	4,00	0,87
LEKENIK	Stari Fakrašić	4	1	4,00	0,87
DONJI KUKURUZARI	Umetić	4	1	4,00	0,87
DVOR	Volinja	8	2	4,00	0,87
MAJUR	Gornji Hrastovac	7	2	3,50	0,76
MAJUR	Graboštani	7	2	3,50	0,76
MAJUR	Majur	7	2	3,50	0,76

DVOR	Divuša	3	1	3,00	0,66
DVOR	Dvor	3	1	3,00	0,66
DVOR	Golubovac	3	1	3,00	0,66
DVOR	Kozibrod	3	1	3,00	0,66
DVOR	Kuljani	6	2	3,00	0,66
SISAK	Lonja	3	1	3,00	0,66
SISAK	Mužilovčica	6	2	3,00	0,66
DVOR	Struga Banska	3	1	3,00	0,66
SISAK	Suvoj	9	3	3,00	0,66
DVOR	Unčani	3	1	3,00	0,66
DVOR	Zamlača	3	1	3,00	0,66
SUNJA	Donji Hrastovac	2	1	2,00	0,44
SUNJA	Drljača	2	1	2,00	0,44
SUNJA	Kinjačka	2	1	2,00	0,44
SISAK	Letovanci	2	1	2,00	0,44
SISAK	Madžari	10	5	2,00	0,44
SUNJA	Petrinjci	2	1	2,00	0,44
SISAK	Staro Selo	4	2	2,00	0,44
MAJUR	Stubalj	2	1	2,00	0,44
PETRINJA	Taborište	4	2	2,00	0,44
SUNJA	Vedro Polje	2	1	2,00	0,44
KUTINA	Batina	1	1	1,00	0,22
NOVSKA	Brestača	2	2	1,00	0,22
VELIKA LUDINA	Grabov Potok	1	1	1,00	0,22
KUTINA	Husain	1	1	1,00	0,22
LIPOVLJANI	Krivaj	2	2	1,00	0,22
DVOR	Matijevići	1	1	1,00	0,22
KUTINA	Zbjegovača	1	1	1,00	0,22
SUNJA	Brđani Kosa	0	0	0,00	0,00
NOVSKA	Bročice	0	0	0,00	0,00
SUNJA	Čapljani	0	0	0,00	0,00
HRVATSKA KOSTAJNICA	Čukur	0	0	0,00	0,00
TOPUSKO	Donja Čemernica	0	0	0,00	0,00
LIPOVLJANI	Donja Vlahinićka	0	0	0,00	0,00
HRVATSKA DUBICA	Donji Cerovljani	0	0	0,00	0,00
SUNJA	Jasenovčani	0	0	0,00	0,00
NOVSKA	Jazavica	0	0	0,00	0,00
GLINA	Kihalac	0	0	0,00	0,00
SUNJA	Kostreši Šaški	0	0	0,00	0,00
SISAK	Lukavec Posavski	0	2	0,00	0,00
NOVSKA	Paklenica	0	0	0,00	0,00
PETRINJA	Petkovac	0	0	0,00	0,00
LIPOVLJANI	Piljenice	0	0	0,00	0,00
SUNJA	Pobrđani	0	0	0,00	0,00
NOVSKA	Roždanik	0	0	0,00	0,00
SUNJA	Slovinci	0	0	0,00	0,00
NOVSKA	Stara Subocka	0	0	0,00	0,00
NOVSKA	Stari Grabovac	0	0	0,00	0,00
SISAK	Veliko Svinjičko	4	0	0,00	0,00
NOVSKA	Voćarica	0	0	0,00	0,00

Prilog 3. Gustoća mreže JPP-a u naseljima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

Grad/Općina	Naselje	*Duljina mreže JPP-a (autobusna + željeznička)*	*Površina naselja [km^2]*	**Gustoća mreže JPP-a [duljina mreže JPP-a po km^2 naselja]**	**Parametar pravičnoga potkriterija e_{sp2}**
SUNJA	Vedro Polje	1,53	0,44	3,48	2,00
HRVATSKA KOSTAJNICA	Panjani	2,78	1,37	2,03	1,53
DVOR	Kuljani	4,13	2,54	1,63	1,40
SISAK	Odra Sisačka	2,82	1,83	1,54	1,37
SISAK	Sisak	42,21	32,01	1,32	1,30
PETRINJA	Župić	2,34	1,79	1,31	1,30
TOPUSKO	Topusko	3,71	3,26	1,14	1,24
POPOVAČA	Gornja Gračenica	7,86	7,66	1,03	1,21
LIPOVLJANI	Donja Vlahinićka	3,90	4,13	0,94	1,18
KUTINA	Banova Jaruga	8,49	9,33	0,91	1,17
SISAK	Letovanci	1,20	1,32	0,91	1,17
DONJI KUKURUZARI	Knezovljani	4,49	5,02	0,89	1,17
SUNJA	Brđani Cesta	3,54	4,26	0,83	1,15
MAJUR	Majur	3,90	4,78	0,82	1,14
MAJUR	Gornji Hrastovac	8,90	11,09	0,80	1,14
SISAK	Gornje Komarevo	5,41	6,79	0,80	1,13
MAJUR	Graboštani	1,92	2,46	0,78	1,13
SISAK	Palanjek	3,06	3,95	0,78	1,13
SISAK	Crnac	2,28	2,95	0,78	1,13
DVOR	Kozibrod	2,07	2,72	0,76	1,12
LEKENIK	Petrovec	3,35	4,44	0,75	1,12
SISAK	Blinjski Kut	4,74	6,49	0,73	1,11
SUNJA	Petrinjci	6,40	8,85	0,72	1,11
SISAK	Budaševo	4,04	5,61	0,72	1,11
SISAK	Novo Pračno	1,70	2,39	0,71	1,11
GLINA	Kihalac	1,02	1,45	0,70	1,10
PETRINJA	Novo Selište	2,20	3,20	0,69	1,10
GLINA	Marinbrod	2,20	3,21	0,69	1,10
DVOR	Divuša	1,55	2,27	0,68	1,10
DONJI KUKURUZARI	Donji Kukuruzari	3,74	5,49	0,68	1,10
MAJUR	Stubalj	2,80	4,17	0,67	1,09
HRVATSKA KOSTAJNICA	Čukur	4,10	6,19	0,66	1,09
DVOR	Struga Banska	2,28	3,47	0,66	1,09
JASENOVAC	Višnjica	3,89	5,96	0,65	1,09
SUNJA	Donji Hrastovac	8,84	13,96	0,63	1,08
SISAK	Madžari	5,26	8,43	0,62	1,08
VELIKA LUDINA	Grabov Potok	2,37	4,06	0,58	1,07
PETRINJA	Donja Budičina	3,09	5,32	0,58	1,06
GLINA	Glina	5,40	9,33	0,58	1,06
GLINA	Prekopa	1,21	2,10	0,58	1,06
DVOR	Dvor	3,10	5,50	0,56	1,06

HRVATSKA KOSTAJNICA	Hrvatska Kostajnica	5,71	10,17	0,56	1,06
LEKENIK	Dužica	9,72	17,48	0,56	1,06
PETRINJA	Mošćenica	2,68	4,87	0,55	1,05
DVOR	Zamlača	1,38	2,51	0,55	1,05
DVOR	Unčani	2,99	5,46	0,55	1,05
SISAK	Lukavec Posavski	3,80	6,96	0,55	1,05
KUTINA	Batina	1,84	3,49	0,53	1,05
PETRINJA	Taborište	2,89	5,55	0,52	1,05
DVOR	Golubovac Divuški	1,18	2,35	0,50	1,04
KUTINA	Ilova	6,46	13,03	0,50	1,04
LEKENIK	Žažina	3,13	6,33	0,49	1,04
PETRINJA	Bijelnik	1,56	3,21	0,49	1,03
LEKENIK	Pešćenica	7,95	16,38	0,49	1,03
LEKENIK	Stari Brod	2,33	4,81	0,48	1,03
PETRINJA	Blinja	1,80	3,75	0,48	1,03
KUTINA	Husain	4,48	9,47	0,47	1,03
SISAK	Novo Selo	10,60	22,53	0,47	1,03
SISAK	Stupno	2,98	6,36	0,47	1,03
LIPOVLJANI	Lipovljani	13,36	28,98	0,46	1,03
VELIKA LUDINA	Velika Ludina	2,92	6,71	0,44	1,02
NOVSKA	Novska	8,24	19,12	0,43	1,02
SUNJA	Papići	1,38	3,21	0,43	1,02
POPOVAČA	Popovača	11,40	26,92	0,42	1,01
SUNJA	Kinjačka	3,06	7,25	0,42	1,01
SISAK	Gušće	10,02	23,92	0,42	1,01
SISAK	Novo Selo	2,28	5,51	0,41	1,01
DVOR	Matijevići	0,89	2,26	0,39	1,00
PETRINJA	Gora	5,43	13,96	0,39	1,00
SISAK	Greda	8,87	23,50	0,38	1,00
POPOVAČA	Voloder	8,57	23,02	0,37	0,98
SISAK	Suvoj	3,61	10,07	0,36	0,94
GLINA	Gornji Viduševac	2,80	7,85	0,36	0,94
PETRINJA	Mala Gorica	2,95	8,95	0,33	0,86
LEKENIK	Letovanić	5,19	16,17	0,32	0,84
LEKENIK	Lekenik	9,42	29,49	0,32	0,83
SUNJA	Brđani Kosa	1,79	5,67	0,32	0,82
NOVSKA	Brestača	5,73	18,56	0,31	0,80
SISAK	Kratečko	4,94	16,21	0,30	0,79
SISAK	Donje Komarevo	3,75	12,46	0,30	0,78
KUTINA	Kutina	14,72	49,62	0,30	0,77
PETRINJA	Graberje	1,77	6,06	0,29	0,76
SISAK	Mužilovčica	3,77	13,06	0,29	0,75
SISAK	Topolovac	6,35	22,07	0,29	0,74
KUTINA	Brinjani	2,62	9,73	0,27	0,69
SUNJA	Sunja	3,51	13,33	0,26	0,68
HRVATSKA DUBICA	Gornji Cerovljani	2,19	8,42	0,26	0,67
SUNJA	Drljača	1,59	6,31	0,25	0,64
TOPUSKO	Batinova Kosa	2,40	9,65	0,25	0,64
HRVATSKA DUBICA	Hrvatska Dubica	5,75	23,36	0,25	0,63
PETRINJA	Moštanica	1,92	7,99	0,24	0,61
SISAK	Sela	4,69	19,84	0,24	0,60

GLINA	Šatornja	3,52	14,97	0,24	0,60
KUTINA	Repušnica	6,88	29,26	0,24	0,60
SISAK	Staro Selo	2,95	12,62	0,23	0,59
SISAK	Prelošćica	5,85	25,17	0,23	0,59
KUTINA	Šartovac	1,83	7,95	0,23	0,58
SUNJA	Jasenovčani	0,95	4,15	0,23	0,58
PETRINJA	Petkovac	0,66	2,93	0,23	0,57
DVOR	Volinja	4,16	18,60	0,22	0,57
NOVSKA	Nova Subocka	1,48	6,70	0,22	0,56
DONJI KUKURUZARI	Umetić	1,16	5,26	0,22	0,56
LIPOVLJANI	Krivaj	2,34	11,03	0,21	0,53
PETRINJA	Petrinja	8,20	39,42	0,21	0,52
LEKENIK	Donji Vukojevac	2,08	10,24	0,20	0,51
SISAK	Hrastelnica	3,50	17,25	0,20	0,51
PETRINJA	Brest Pokupski	2,07	10,54	0,20	0,49
SUNJA	Kostreši Šaški	1,11	5,66	0,20	0,49
SUNJA	Čapljani	0,79	4,03	0,20	0,49
DONJI KUKURUZARI	Komogovina	1,92	10,35	0,19	0,46
NOVSKA	Bročice	3,24	18,91	0,17	0,42
POPOVAČA	Potok	3,31	19,78	0,17	0,41
KUTINA	Kutinska Slatina	0,76	4,59	0,17	0,40
DONJI KUKURUZARI	Prevršac	2,15	13,04	0,16	0,40
DONJI KUKURUZARI	Donja Velešnja	1,32	8,02	0,16	0,40
NOVSKA	Jazavica	1,98	12,62	0,16	0,38
NOVSKA	Stara Subocka	2,41	15,93	0,15	0,36
KUTINA	Zbjegovača	1,10	7,26	0,15	0,36
SUNJA	Staza	1,33	9,54	0,14	0,33
HRVATSKA DUBICA	Živaja	6,31	45,79	0,14	0,33
NOVSKA	Rođdanik	1,09	8,12	0,13	0,32
SUNJA	Slovinci	1,75	13,21	0,13	0,31
NOVSKA	Paklenica	1,65	12,66	0,13	0,31
POPOVAČA	Stružec	3,76	29,86	0,13	0,29
TOPUSKO	Donja Čemernica	1,47	12,74	0,12	0,26
SUNJA	Šaš	3,61	32,08	0,11	0,26
NOVSKA	Voćarica	1,02	9,60	0,11	0,24
JASENOVAC	Jasenovac	6,06	58,18	0,10	0,23
SISAK	Čigoć	2,84	28,01	0,10	0,23
SISAK	Veliko Svinjičko	2,44	24,88	0,10	0,22
NOVSKA	Stari Grabovac	1,62	17,42	0,09	0,20
KUTINA	Stupovača	0,98	12,10	0,08	0,17
NOVSKA	Rajić	1,69	33,88	0,05	0,08
LIPOVLJANI	Piljenice	1,04	22,82	0,05	0,07
SISAK	Lonja	0,66	19,94	0,03	0,04
HRVATSKA DUBICA	Donji Cerovljani	0,82	26,42	0,03	0,03
SUNJA	Pobrđani	0,54	23,91	0,02	0,00
LEKENIK	Stari Fakrašić	0,36	18,78	0,02	0,00
KUTINA	Međurić	0,18	10,05	0,02	0,00

Prilog 4. Demografska gustoća JPP-a u naseljima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

Grad/Općina	Naselje	*Duljina mreže JPP-a (autobusna + željeznička)*	*Broj stanovnika*	**Demografska gustoća JPP-a [duljina mreže JPP-a po stanovniku]**	**Parametar pravičnoga potkriterija e_{sp3}**
SISAK	Suvoj	3,61	41	0,088	2,00
DONJI KUKURUZARI	Knezovljani	4,49	81	0,055	1,58
DVOR	Volinja	4,16	77	0,054	1,56
SISAK	Mužilovčica	3,77	77	0,049	1,50
TOPUSKO	Batinova Kosa	2,40	50	0,048	1,49
PETRINJA	Petkovac	0,66	15	0,044	1,44
MAJUR	Gornji Hrastovac	8,90	209	0,043	1,42
DVOR	Kuljani	4,13	98	0,042	1,41
SUNJA	Donji Hrastovac	8,84	217	0,041	1,39
HRVATSKA KOSTAJNICA	Čukur	4,10	114	0,036	1,33
SUNJA	Petrinjci	6,40	183	0,035	1,32
PETRINJA	Bijelnik	1,56	47	0,033	1,30
DVOR	Kozibrod	2,07	70	0,030	1,25
SISAK	Čigoć	2,84	98	0,029	1,24
SISAK	Lukavec Posavski	3,80	132	0,029	1,24
PETRINJA	Župić	2,34	85	0,028	1,22
LEKENIK	Dužica	9,72	353	0,028	1,22
JASENOVAC	Višnjica	3,89	144	0,027	1,22
SISAK	Staro Selo	2,95	110	0,027	1,22
SUNJA	Brđani Cesta	3,54	135	0,026	1,21
SISAK	Gušće	10,02	385	0,026	1,21
SISAK	Kratečko	4,94	199	0,025	1,19
SUNJA	Papići	1,38	56	0,025	1,19
DVOR	Divuša	1,55	63	0,025	1,19
SUNJA	Pobrđani	0,54	22	0,025	1,19
GLINA	Marinbrod	2,20	93	0,024	1,18
SUNJA	Jasenovčani	0,95	41	0,023	1,17
PETRINJA	Blinja	1,80	78	0,023	1,17
VELIKA LUDINA	Grabov Potok	2,37	104	0,023	1,16
HRVATSKA KOSTAJNICA	Panjani	2,78	125	0,022	1,16
SISAK	Madžari	5,26	237	0,022	1,16
HRVATSKA DUBICA	Gornji Cerovljani	2,19	99	0,022	1,16
SISAK	Letovanci	1,20	56	0,021	1,15
SUNJA	Čapljani	0,79	37	0,021	1,14
PETRINJA	Moštanica	1,92	93	0,021	1,14
PETRINJA	Gora	5,43	264	0,021	1,14
SISAK	Novo Selo	10,60	519	0,020	1,13
HRVATSKA DUBICA	Živaja	6,31	309	0,020	1,13
GLINA	Kihalac	1,02	50	0,020	1,13
GLINA	Šatornja	3,52	176	0,020	1,13
DVOR	Struga Banska	2,28	115	0,020	1,13

DONJI KUKURUZARI	Prevršac	2,15	120	0,018	1,10
SUNJA	Brđani Kosa	1,79	103	0,017	1,09
SISAK	Blinjski Kut	4,74	277	0,017	1,09
DONJI KUKURUZARI	Umetić	1,16	73	0,016	1,08
DVOR	Unčani	2,99	189	0,016	1,07
SUNJA	Kostreši Šaški	1,11	71	0,016	1,07
DONJI KUKURUZARI	Komogovina	1,92	126	0,015	1,07
MAJUR	Stubalj	2,80	186	0,015	1,06
SUNJA	Kinjačka	3,06	213	0,014	1,06
MAJUR	Graboštani	1,92	134	0,014	1,06
LEKENIK	Stari Brod	2,33	166	0,014	1,05
DVOR	Golubovac Divuški	1,18	85	0,014	1,05
PETRINJA	Donja Budičina	3,09	236	0,013	1,04
SUNJA	Vedro Polje	1,53	119	0,013	1,04
KUTINA	Banova Jaruga	8,49	665	0,013	1,04
PETRINJA	Taborište	2,89	227	0,013	1,04
DONJI KUKURUZARI	Donji Kukuruzari	3,74	297	0,013	1,03
MAJUR	Majur	3,90	324	0,012	1,03
SUNJA	Šaš	3,61	307	0,012	1,02
SISAK	Donje Komarevo	3,75	325	0,012	1,02
SUNJA	Slovinci	1,75	152	0,012	1,02
PETRINJA	Graberje	1,77	155	0,011	1,02
LEKENIK	Letovanić	5,19	464	0,011	1,02
SISAK	Prelošćica	5,85	525	0,011	1,01
HRVATSKA DUBICA	Donji Cerovljani	0,82	76	0,011	1,01
SISAK	Gornje Komarevo	5,41	506	0,011	1,01
KUTINA	Brinjani	2,62	253	0,010	1,00
SISAK	Greda	8,87	858	0,010	1,00
LEKENIK	Petrovec	3,35	334	0,010	1,00
SISAK	Palanjek	3,06	318	0,010	1,00
DVOR	Zamlača	1,38	144	0,010	1,00
JASENOVAC	Jasenovac	6,06	653	0,009	0,93
LEKENIK	Pešćenica	7,95	883	0,009	0,90
KUTINA	Batina	1,84	205	0,009	0,90
SISAK	Veliko Svinjičko	2,44	275	0,009	0,89
LEKENIK	Žažina	3,13	355	0,009	0,88
TOPUSKO	Donja Čemernica	1,47	170	0,009	0,86
GLINA	Prekopa	1,21	143	0,008	0,85
POPOVAČA	Gornja Gračenica	7,86	954	0,008	0,82
KUTINA	Ilova	6,46	821	0,008	0,79
LIPOVLJANI	Krivaj	2,34	307	0,008	0,76
PETRINJA	Brest Pokupski	2,07	279	0,007	0,74
SISAK	Topolovac	6,35	897	0,007	0,71
LIPOVLJANI	Donja Vlahinićka	3,90	551	0,007	0,71
PETRINJA	Novo Selište	2,20	321	0,007	0,69
NOVSKA	Brestača	5,73	913	0,006	0,63
SISAK	Stupno	2,98	484	0,006	0,62
SUNJA	Staza	1,33	220	0,006	0,60
GLINA	Gornji Viduševac	2,80	468	0,006	0,60
SISAK	Lonja	0,66	111	0,006	0,59

NOVSKA	Paklenica	1,65	279	0,006	0,59
LIPOVLJANI	Lipovljani	13,36	2260	0,006	0,59
PETRINJA	Mala Gorica	2,95	510	0,006	0,58
SUNJA	Drljača	1,59	277	0,006	0,57
HRVATSKA DUBICA	Hrvatska Dubica	5,75	1040	0,006	0,55
POPOVAČA	Stružec	3,76	687	0,005	0,55
NOVSKA	Voćarica	1,02	199	0,005	0,51
DONJI KUKURUZARI	Donja Velešnja	1,32	261	0,005	0,51
NOVSKA	Jazavica	1,98	398	0,005	0,50
LEKENIK	Lekenik	9,42	1897	0,005	0,50
SISAK	Sela	4,69	963	0,005	0,49
KUTINA	Šartovac	1,83	380	0,005	0,48
NOVSKA	Stara Subocka	2,41	502	0,005	0,48
KUTINA	Husain	4,48	971	0,005	0,46
POPOVAČA	Voloder	8,57	1871	0,005	0,46
POPOVAČA	Potok	3,31	756	0,004	0,44
SISAK	Crnac	2,28	545	0,004	0,42
LEKENIK	Stari Fakrašić	0,36	86	0,004	0,42
LEKENIK	Donji Vukojevac	2,08	499	0,004	0,42
NOVSKA	Roždanik	1,09	262	0,004	0,42
NOVSKA	Stari Grabovac	1,62	393	0,004	0,41
TOPUSKO	Topusko	3,71	945	0,004	0,39
SISAK	Hrastelnica	3,50	897	0,004	0,39
VELIKA LUDINA	Velika Ludina	2,92	751	0,004	0,39
SISAK	Novo Pračno	1,70	452	0,004	0,38
KUTINA	Repušnica	6,88	1838	0,004	0,37
SISAK	Novo Selo	2,28	633	0,004	0,36
SISAK	Odra Sisačka	2,82	823	0,003	0,34
NOVSKA	Bročice	3,24	964	0,003	0,34
KUTINA	Zbjegovača	1,10	346	0,003	0,32
POPOVAČA	Popovača	11,40	4207	0,003	0,27
HRVATSKA KOSTAJNICA	Hrvatska Kostajnica	5,71	2127	0,003	0,27
LIPOVLJANI	Piljenice	1,04	417	0,002	0,25
SUNJA	Sunja	3,51	1412	0,002	0,25
SISAK	Budaševo	4,04	1664	0,002	0,24
KUTINA	Stupovača	0,98	440	0,002	0,22
DVOR	Dvor	3,10	1406	0,002	0,22
NOVSKA	Nova Subocka	1,48	713	0,002	0,21
NOVSKA	Rajić	1,69	875	0,002	0,19
DVOR	Matijevići	0,89	645	0,001	0,14
KUTINA	Kutinska Slatina	0,76	578	0,001	0,13
SISAK	Sisak	42,21	33322	0,001	0,13
NOVSKA	Novska	8,24	7028	0,001	0,12
GLINA	Glina	5,40	4608	0,001	0,12
PETRINJA	Mošćenica	2,68	2470	0,001	0,11
KUTINA	Kutina	14,72	13735	0,001	0,11
PETRINJA	Petrinja	8,20	15683	0,001	0,05
KUTINA	Međurić	0,18	485	0,000	0,00

Prilog 5. Gustoća stajališta JPP-a u naseljima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

Grad/Općina	Naselje	*Broj stajališta JPP-a (autobusna + željeznička)*	*Površina naselja [km^2]*	**Gustoća stajališta JPP-a [Broj stajališta po km^2]**	**Parametar pravičnoga potkriterija e_{sp4}**
SUNJA	Vedro Polje	1	0,44	2,27	2,00
SISAK	Sisak	45	32,01	1,41	1,59
SISAK	Odra Sisačka	2	1,83	1,09	1,44
SISAK	Crnac	3	2,95	1,02	1,41
SISAK	Budaševo	5	5,61	0,89	1,35
SISAK	Novo Pračno	2	2,39	0,84	1,32
MAJUR	Graboštani	2	2,46	0,81	1,31
DVOR	Kuljani	2	2,54	0,79	1,30
SISAK	Palanjek	3	3,95	0,76	1,28
SISAK	Letovanci	1	1,32	0,76	1,28
HRVATSKA KOSTAJNICA	Panjani	1	1,37	0,73	1,27
POPOVAČA	Gornja Gračenica	5	7,66	0,65	1,23
GLINA	Marinbrod	2	3,21	0,62	1,22
SISAK	Blinjski Kut	4	6,49	0,62	1,22
SISAK	Madžari	5	8,43	0,59	1,21
PETRINJA	Župić	1	1,79	0,56	1,19
GLINA	Prekopa	1	2,10	0,48	1,15
SUNJA	Brđani Cesta	2	4,26	0,47	1,15
DVOR	Matijevići	1	2,26	0,44	1,13
DVOR	Divuša	1	2,27	0,44	1,13
KUTINA	Banova Jaruga	4	9,33	0,43	1,13
DVOR	Golubovac	1	2,35	0,43	1,13
MAJUR	Majur	2	4,78	0,42	1,12
PETRINJA	Mošćenica	2	4,87	0,41	1,12
DVOR	Zamlača	1	2,51	0,40	1,11
PETRINJA	Donja Budičina	2	5,32	0,38	1,10
DVOR	Kozibrod	1	2,72	0,37	1,10
SISAK	Novo Selo	2	5,51	0,36	1,10
PETRINJA	Taborište	2	5,55	0,36	1,09
SISAK	Greda	8	23,50	0,34	1,09
SISAK	Stupno	2	6,36	0,31	1,07
PETRINJA	Novo Selište	1	3,20	0,31	1,07
PETRINJA	Bijelnik	1	3,21	0,31	1,07
SUNJA	Papići	1	3,21	0,31	1,07
TOPUSKO	Topusko	1	3,26	0,31	1,07
NOVSKA	Nova Subocka	2	6,70	0,30	1,07
VELIKA LUDINA	Velika Ludina	2	6,71	0,30	1,07
SISAK	Suvoj	3	10,07	0,30	1,07
HRVATSKA KOSTAJNICA	Hrvatska Kostajnica	3	10,17	0,29	1,06
SISAK	Gornje Komarevo	2	6,79	0,29	1,06
DVOR	Struga Banska	1	3,47	0,29	1,06
SISAK	Lukavec Posavski	2	6,96	0,29	1,06
KUTINA	Batina	1	3,49	0,29	1,06
PETRINJA	Blinja	1	3,75	0,27	1,05

GLINA	Gornji Viduševac	2	7,85	0,25	1,04
VELIKA LUDINA	Grabov Potok	1	4,06	0,25	1,04
MAJUR	Stubalj	1	4,17	0,24	1,04
SISAK	Prelošćica	6	25,17	0,24	1,04
SISAK	Hrastelnica	4	17,25	0,23	1,03
KUTINA	Ilova	3	13,03	0,23	1,03
PETRINJA	Petrinja	9	39,42	0,23	1,03
SISAK	Topolovac	5	22,07	0,23	1,03
LEKENIK	Petrovec	1	4,44	0,23	1,03
SUNJA	Sunja	3	13,33	0,23	1,03
KUTINA	Kutinska Slatina	1	4,59	0,22	1,03
LEKENIK	Stari Brod	1	4,81	0,21	1,02
DONJI KUKURUZARI	Knezovljani	1	5,02	0,20	1,02
DONJI KUKURUZARI	Umetić	1	5,26	0,19	1,01
LEKENIK	Letovanić	3	16,17	0,19	1,01
SISAK	Kratečko	3	16,21	0,19	1,01
LEKENIK	Pešćenica	3	16,38	0,18	1,01
DVOR	Unčani	1	5,46	0,18	1,01
DONJI KUKURUZARI	Donji Kukuruzari	1	5,49	0,18	1,01
DVOR	Dvor	1	5,50	0,18	1,01
LIPOVLJANI	Krivaj	2	11,03	0,18	1,01
MAJUR	Gornji Hrastovac	2	11,09	0,18	1,01
JASENOVAC	Višnjica	1	5,96	0,17	1,01
SISAK	Gušće	4	23,92	0,17	1,01
PETRINJA	Graberje	1	6,06	0,17	1,01
SISAK	Donje Komarevo	2	12,46	0,16	1,00
SUNJA	Drljača	1	6,31	0,16	1,00
SISAK	Staro Selo	2	12,62	0,16	1,00
LEKENIK	Žažina	1	6,33	0,16	1,00
SISAK	Mužilovčica	2	13,06	0,15	0,96
POPOVAČA	Popovača	4	26,92	0,15	0,93
KUTINA	Kutina	7	49,62	0,14	0,88
LIPOVLJANI	Lipovljani	4	28,98	0,14	0,86
SUNJA	Kinjačka	1	7,25	0,14	0,86
KUTINA	Zbjegovača	1	7,26	0,14	0,86
LEKENIK	Lekenik	4	29,49	0,14	0,85
SISAK	Novo Selo	3	22,53	0,13	0,83
POPOVAČA	Voloder	3	23,02	0,13	0,81
KUTINA	Šartovac	1	7,95	0,13	0,79
PETRINJA	Moštanica	1	7,99	0,13	0,78
DONJI KUKURUZARI	Donja Velešnja	1	8,02	0,12	0,78
HRVATSKA DUBICA	Gornji Cerovljani	1	8,42	0,12	0,74
LEKENIK	Dužica	2	17,48	0,11	0,72
SUNJA	Petrinjci	1	8,85	0,11	0,71
PETRINJA	Mala Gorica	1	8,95	0,11	0,70
NOVSKA	Brestača	2	18,56	0,11	0,67
DVOR	Volinja	2	18,60	0,11	0,67
GLINA	Glina	1	9,33	0,11	0,67
KUTINA	Husain	1	9,47	0,11	0,66

SUNJA	Staza	1	9,54	0,10	0,66
NOVSKA	Novska	2	19,12	0,10	0,65
TOPUSKO	Batinova Kosa	1	9,65	0,10	0,65
KUTINA	Brinjani	1	9,73	0,10	0,64
KUTINA	Repušnica	3	29,26	0,10	0,64
SISAK	Sela	2	19,84	0,10	0,63
KUTINA	Međurić	1	10,05	0,10	0,62
LEKENIK	Donji Vukojevac	1	10,24	0,10	0,61
DONJI KUKURUZARI	Komogovina	1	10,35	0,10	0,60
PETRINJA	Brest Pokupski	1	10,54	0,09	0,59
KUTINA	Stupovača	1	12,10	0,08	0,52
DONJI KUKURUZARI	Prevršac	1	13,04	0,08	0,48
SUNJA	Donji Hrastovac	1	13,96	0,07	0,45
PETRINJA	Gora	1	13,96	0,07	0,45
SISAK	Čigoć	2	28,01	0,07	0,45
GLINA	Šatornja	1	14,97	0,07	0,42
LEKENIK	Stari Fakrašić	1	18,78	0,05	0,33
POPOVAČA	Potok	1	19,78	0,05	0,32
SISAK	Lonja	1	19,94	0,05	0,31
HRVATSKA DUBICA	Hrvatska Dubica	1	23,36	0,04	0,27
POPOVAČA	Stružec	1	29,86	0,03	0,21
SUNJA	Šaš	1	32,08	0,03	0,19
NOVSKA	Rajić	1	33,88	0,03	0,18
HRVATSKA DUBICA	Živaja	1	45,79	0,02	0,14
JASENOVAC	Jasenovac	1	58,18	0,02	0,11
SUNJA	Brđani Kosa	0	5,67	0,00	0,00
NOVSKA	Bročice	0	18,91	0,00	0,00
SUNJA	Čapljani	0	4,03	0,00	0,00
HRVATSKA KOSTAJNICA	Čukur	0	6,19	0,00	0,00
TOPUSKO	Donja Čemernica	0	12,74	0,00	0,00
LIPOVLJANI	Donja Vlahinićka	0	4,13	0,00	0,00
HRVATSKA DUBICA	Donji Cerovljani	0	26,42	0,00	0,00
SUNJA	Jasenovčani	0	4,15	0,00	0,00
NOVSKA	Jazavica	0	12,62	0,00	0,00
GLINA	Kihalac	0	1,45	0,00	0,00
SUNJA	Kostreši Šaški	0	5,66	0,00	0,00
NOVSKA	Paklenica	0	12,66	0,00	0,00
PETRINJA	Petkovac	0	2,93	0,00	0,00
LIPOVLJANI	Piljenice	0	22,82	0,00	0,00
SUNJA	Pobrđani	0	23,91	0,00	0,00
NOVSKA	Roždanik	0	8,12	0,00	0,00
SUNJA	Slovinci	0	13,21	0,00	0,00
NOVSKA	Stara Subocka	0	15,93	0,00	0,00
NOVSKA	Stari Grabovac	0	17,42	0,00	0,00
SISAK	Veliko Svinjičko	0	24,88	0,00	0,00
NOVSKA	Voćarica	0	9,60	0,00	0,00

Prilog 6. Gustoća stanovništva u naseljima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

Grad/Općina	Naselje	*Broj stanovnika*	*Površina naselja [km^2]*	**Gustoća stanovništva [Broj stanovnika po km^2]**	**Parametar pravičnoga potkriterija e_{sp8}**
SISAK	Sisak	33.322	32,01	1040,96	2,00
PETRINJA	Mošćenica	2.470	4,87	507,19	1,47
GLINA	Glina	4.608	9,33	493,89	1,46
SISAK	Odra Sisačka	823	1,83	449,72	1,41
PETRINJA	Petrinja	15.683	39,42	397,84	1,36
NOVSKA	Novska	7.028	19,12	367,57	1,33
SISAK	Budaševo	1.664	5,61	296,71	1,26
TOPUSKO	Topusko	945	3,26	289,88	1,25
DVOR	Matijevići	645	2,26	285,40	1,25
KUTINA	Kutina	13.735	49,62	276,80	1,24
SUNJA	Vedro Polje	119	0,44	270,45	1,23
DVOR	Dvor	1.406	5,50	255,64	1,22
HRVATSKA KOSTAJNICA	Hrvatska Kostajnica	2.127	10,17	209,14	1,17
SISAK	Novo Pračno	452	2,39	189,18	1,15
SISAK	Crnac	545	2,95	185,04	1,15
POPOVAČA	Popovača	4.207	26,92	156,28	1,12
LIPOVLJANI	Donja Vlahinićka	551	4,13	133,41	1,10
KUTINA	Kutinska Slatina	578	4,59	125,93	1,09
POPOVAČA	Gornja Gračenica	954	7,66	124,54	1,09
SISAK	Novo Selo	633	5,51	114,95	1,08
VELIKA LUDINA	Velika Ludina	751	6,71	111,92	1,08
NOVSKA	Nova Subocka	713	6,70	106,42	1,07
SUNJA	Sunja	1.412	13,33	105,93	1,07
KUTINA	Husain	971	9,47	102,53	1,07
PETRINJA	Novo Selište	321	3,20	100,31	1,07
HRVATSKA KOSTAJNICA	Panjani	125	1,37	91,24	1,06
POPOVAČA	Voloder	1.871	23,02	81,28	1,05
SISAK	Palanjek	318	3,95	80,60	1,05
LIPOVLJANI	Lipovljani	2.260	28,98	77,98	1,04
SISAK	Stupno	484	6,36	76,15	1,04
LEKENIK	Petrovec	334	4,44	75,23	1,04
SISAK	Gornje Komarevo	506	6,79	74,55	1,04
KUTINA	Banova Jaruga	665	9,33	71,28	1,04
GLINA	Prekopa	143	2,10	68,10	1,03
MAJUR	Majur	324	4,78	67,78	1,03
LEKENIK	Lekenik	1.897	29,49	64,33	1,03
KUTINA	Ilova	821	13,03	63,01	1,03
KUTINA	Repušnica	1.838	29,26	62,82	1,03
GLINA	Gornji Viduševac	468	7,85	59,62	1,02
KUTINA	Batina	205	3,49	58,74	1,02
DVOR	Zamlača	144	2,51	57,37	1,02
PETRINJA	Mala Gorica	510	8,95	56,98	1,02

LEKENIK	Žažina	355	6,33	56,08	1,02
MAJUR	Graboštani	134	2,46	54,47	1,02
DONJI KUKURUZARI	Donji Kukuruzari	297	5,49	54,10	1,02
LEKENIK	Pešćenica	883	16,38	53,91	1,02
SISAK	Hrastelnica	897	17,25	52,00	1,02
NOVSKA	Bročice	964	18,91	50,98	1,02
NOVSKA	Brestača	913	18,56	49,19	1,01
LEKENIK	Donji Vukojevac	499	10,24	48,73	1,01
SISAK	Sela	963	19,84	48,55	1,01
KUTINA	Međurić	485	10,05	48,26	1,01
KUTINA	Šartovac	380	7,95	47,80	1,01
KUTINA	Zbjegovača	346	7,26	47,66	1,01
PETRINJA	Župić	85	1,79	47,49	1,01
MAJUR	Stubalj	186	4,17	44,60	1,01
HRVATSKA DUBICA	Hrvatska Dubica	1.040	23,36	44,52	1,01
PETRINJA	Donja Budičina	236	5,32	44,36	1,01
SUNJA	Drljača	277	6,31	43,90	1,01
SISAK	Blinjski Kut	277	6,49	42,69	1,01
SISAK	Letovanci	56	1,32	42,38	1,01
PETRINJA	Taborište	227	5,55	40,90	1,01
SISAK	Topolovac	897	22,07	40,64	1,01
DVOR	Kuljani	98	2,54	38,58	1,00
POPOVAČA	Potok	756	19,78	38,22	1,00
SISAK	Greda	858	23,50	36,52	1,00
KUTINA	Stupovača	440	12,10	36,36	1,00
DVOR	Golubovac Divuški	85	2,35	36,17	1,00
DVOR	Unčani	189	5,46	34,62	1,00
LEKENIK	Stari Brod	166	4,81	34,51	1,00
GLINA	Kihalac	50	1,45	34,48	1,00
DVOR	Struga Banska	115	3,47	33,14	0,96
DONJI KUKURUZARI	Donja Velešnja	261	8,02	32,54	0,94
NOVSKA	Roždanik	262	8,12	32,27	0,93
SUNJA	Brđani Cesta	135	4,26	31,69	0,92
NOVSKA	Jazavica	398	12,62	31,54	0,91
NOVSKA	Stara Subocka	502	15,93	31,51	0,91
SUNJA	Kinjačka	213	7,25	29,38	0,85
GLINA	Marinbrod	93	3,21	28,97	0,84
LEKENIK	Letovanić	464	16,17	28,70	0,83
SISAK	Madžari	237	8,43	28,12	0,81
LIPOVLJANI	Krivaj	307	11,03	27,83	0,80
DVOR	Divuša	63	2,27	27,75	0,80
PETRINJA	Brest Pokupski	279	10,54	26,47	0,76
SISAK	Donje Komarevo	325	12,46	26,07	0,75
KUTINA	Brinjani	253	9,73	26,00	0,75
NOVSKA	Rajić	875	33,88	25,83	0,74
DVOR	Kozibrod	70	2,72	25,74	0,74
VELIKA LUDINA	Grabov Potok	104	4,06	25,62	0,74
PETRINJA	Graberje	155	6,06	25,58	0,73
JASENOVAC	Višnjica	144	5,96	24,16	0,69
SUNJA	Staza	220	9,54	23,06	0,66
SISAK	Novo Selo Palanječko	519	22,53	23,03	0,66

POPOVAČA	Stružec	687	29,86	23,01	0,66
NOVSKA	Stari Grabovac	393	17,42	22,56	0,64
NOVSKA	Paklenica	279	12,66	22,04	0,63
SISAK	Prelošćica	525	25,17	20,86	0,59
PETRINJA	Blinja	78	3,75	20,80	0,59
NOVSKA	Voćarica	199	9,60	20,73	0,59
SUNJA	Petrinjci	183	8,85	20,68	0,59
LEKENIK	Dužica	353	17,48	20,19	0,57
SISAK	Lukavec Posavski	132	6,96	18,97	0,54
PETRINJA	Gora	264	13,96	18,91	0,54
MAJUR	Gornji Hrastovac	209	11,09	18,85	0,53
HRVATSKA KOSTAJNICA	Čukur	114	6,19	18,42	0,52
LIPOVLJANI	Piljenice	417	22,82	18,27	0,52
SUNJA	Brđani Kosa	103	5,67	18,17	0,51
SUNJA	Papići	56	3,21	17,45	0,49
DONJI KUKURUZARI	Knezovljani	81	5,02	16,14	0,45
SISAK	Gušće	385	23,92	16,09	0,45
SUNJA	Donji Hrastovac	217	13,96	15,54	0,44
PETRINJA	Bijelnik	47	3,21	14,64	0,41
DONJI KUKURUZARI	Umetić	73	5,26	13,88	0,39
TOPUSKO	Donja Čemernica	170	12,74	13,34	0,37
SUNJA	Kostreši Šaški	71	5,66	12,54	0,35
SISAK	Kratečko	199	16,21	12,28	0,34
DONJI KUKURUZARI	Komogovina	126	10,35	12,17	0,34
HRVATSKA DUBICA	Gornji Cerovljani	99	8,42	11,76	0,32
GLINA	Šatornja	176	14,97	11,76	0,32
PETRINJA	Moštanica	93	7,99	11,64	0,32
SUNJA	Slovinci	152	13,21	11,51	0,32
JASENOVAC	Jasenovac	653	58,18	11,22	0,31
SISAK	Veliko Svinjičko	275	24,88	11,05	0,30
SUNJA	Jasenovčani	41	4,15	9,88	0,27
SUNJA	Šaš	307	32,08	9,57	0,26
DONJI KUKURUZARI	Prevršac	120	13,04	9,20	0,25
SUNJA	Čapljani	37	4,03	9,18	0,25
SISAK	Staro Selo	110	12,62	8,71	0,23
HRVATSKA DUBICA	Živaja	309	45,79	6,75	0,17
SISAK	Mužilovčica	77	13,06	5,90	0,15
SISAK	Lonja	111	19,94	5,57	0,14
TOPUSKO	Batinova Kosa	50	9,65	5,18	0,13
PETRINJA	Petkovac	15	2,93	5,12	0,13
LEKENIK	Stari Fakrašić	86	18,78	4,58	0,11
DVOR	Volinja	77	18,60	4,14	0,10
SISAK	Suvoj	41	10,07	4,07	0,09
SISAK	Čigoć	98	28,01	3,50	0,08
HRVATSKA DUBICA	Donji Cerovljani	76	26,42	2,88	0,06
SUNJA	Pobrđani	22	23,91	0,92	0,00

Prilog 7. Opće kretanje stanovništva u naseljima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

Grad/Općina	Naselje	*Broj stanovnika – popis 2011.*	*Broj stanovnika – popis 2001.*	**Opće kretanje stanovništva**	**Parametar pravičnoga potkriterija e_{sp9}**
PETRINJA	Petrinja	15.683	13.801	1882,00	2,00
GLINA	Glina	4.608	3.116	1492,00	1,80
DVOR	Matijevići	645	421	224,00	1,13
TOPUSKO	Topusko	945	798	147,00	1,09
HRVATSKA KOSTAJNICA	Hrvatska Kostajnica	2.127	1.993	134,00	1,09
PETRINJA	Mošćenica	2.470	2.348	122,00	1,08
DVOR	Dvor	1.406	1.313	93,00	1,06
DONJI KUKURUZARI	Donji Kukuruzari	297	226	71,00	1,05
HRVATSKA DUBICA	Hrvatska Dubica	1.040	987	53,00	1,04
PETRINJA	Novo Selište	321	269	52,00	1,04
SISAK	Novo Selo	633	587	46,00	1,04
LEKENIK	Lekenik	1.897	1.857	40,00	1,04
SISAK	Gornje Komarevo	506	471	35,00	1,03
LEKENIK	Donji Vukojevac	499	468	31,00	1,03
LEKENIK	Petrovec	334	303	31,00	1,03
VELIKA LUDINA	Velika Ludina	751	724	27,00	1,03
SISAK	Donje Komarevo	325	300	25,00	1,03
NOVSKA	Nova Subocka	713	689	24,00	1,03
HRVATSKA KOSTAJNICA	Čukur	114	93	21,00	1,03
SUNJA	Sunja	1.412	1.397	15,00	1,02
TOPUSKO	Batinova Kosa	50	37	13,00	1,02
LEKENIK	Stari Brod	166	158	8,00	1,02
LEKENIK	Stari Fakrašić	86	79	7,00	1,02
PETRINJA	Blinja	78	74	4,00	1,02
PETRINJA	Moštanica	93	89	4,00	1,02
SUNJA	Vedro Polje	119	115	4,00	1,02
SISAK	Sela	963	960	3,00	1,02
PETRINJA	Župić	85	82	3,00	1,02
DONJI KUKURUZARI	Knezovljani	81	79	2,00	1,02
SUNJA	Petrinjci	183	183	0,00	1,02
SUNJA	Čapljani	37	38	–1,00	1,02
SISAK	Lukavec Posavski	132	133	–1,00	1,02
PETRINJA	Petkovac	15	17	–2,00	1,02
NOVSKA	Bročice	964	967	–3,00	1,01
SISAK	Suvoj	41	44	–3,00	1,01
PETRINJA	Taborište	227	230	–3,00	1,01
DVOR	Volinja	77	81	–4,00	1,01
SISAK	Palanjek	318	323	–5,00	1,01
DVOR	Divuša	63	69	–6,00	1,01
SISAK	Madžari	237	245	–8,00	1,01
SUNJA	Pobrđani	22	30	–8,00	1,01

SISAK	Veliko Svinjičko	275	283	–8,00	1,01
NOVSKA	Voćarica	199	207	–8,00	1,01
KUTINA	Batina	205	215	–10,00	1,01
PETRINJA	Donja Budičina	236	247	–11,00	1,01
GLINA	Kihalac	50	62	–12,00	1,01
LIPOVLJANI	Piljenice	417	429	–12,00	1,01
SISAK	Novo Pračno	452	465	–13,00	1,01
SUNJA	Brđani Kosa	103	117	–14,00	1,01
HRVATSKA DUBICA	Donji Cerovljani	76	90	–14,00	1,01
LEKENIK	Žažina	355	369	–14,00	1,01
PETRINJA	Bijelnik	47	62	–15,00	1,01
SISAK	Budaševo	1.664	1.680	–16,00	1,01
SISAK	Čigoć	98	114	–16,00	1,01
POPOVAČA	Gornja Gračenica	954	971	–17,00	1,01
SISAK	Letovanci	56	73	–17,00	1,01
NOVSKA	Paklenica	279	296	–17,00	1,01
LIPOVLJANI	Donja Vlahinićka	551	569	–18,00	1,01
GLINA	Prekopa	143	161	–18,00	1,01
DVOR	Golubovac Divuški	85	104	–19,00	1,01
KUTINA	Brinjani	253	273	–20,00	1,01
PETRINJA	Mala Gorica	510	531	–21,00	1,01
HRVATSKA KOSTAJNICA	Panjani	125	147	–22,00	1,00
SUNJA	Donji Hrastovac	217	240	–23,00	1,00
PETRINJA	Gora	264	287	–23,00	1,00
TOPUSKO	Donja Čemernica	170	199	–29,00	1,00
SISAK	Novo Selo	519	548	–29,00	1,00
NOVSKA	Roždanik	262	291	–29,00	1,00
SISAK	Mužilovčica	77	107	–30,00	1,00
VELIKA LUDINA	Grabov Potok	104	135	–31,00	1,00
KUTINA	Husain	971	1.002	–31,00	1,00
NOVSKA	Jazavica	398	429	–31,00	1,00
SISAK	Staro Selo	110	141	–31,00	1,00
PETRINJA	Graberje	155	187	–32,00	1,00
LEKENIK	Pešćenica	883	915	–32,00	1,00
KUTINA	Stupovača	440	472	–32,00	1,00
KUTINA	Zbjegovača	346	379	–33,00	1,00
GLINA	Gornji Viduševac	468	504	–36,00	1,00
MAJUR	Graboštani	134	171	–37,00	1,00
DVOR	Kuljani	98	136	–38,00	1,00
GLINA	Marinbrod	93	131	–38,00	1,00
KUTINA	Ilova	821	860	–39,00	1,00
KUTINA	Kutinska Slatina	578	617	–39,00	1,00
DONJI KUKURUZARI	Prevršac	120	159	–39,00	1,00
NOVSKA	Stari Grabovac	393	432	–39,00	1,00
DVOR	Zamlača	144	184	–40,00	1,00
LEKENIK	Dužica	353	395	–42,00	1,00
SUNJA	Jasenovčani	41	83	–42,00	1,00
HRVATSKA DUBICA	Gornji Cerovljani	99	142	–43,00	1,00
MAJUR	Stubalj	186	229	–43,00	1,00
PETRINJA	Brest Pokupski	279	325	–46,00	1,00

DVOR	Struga Banska	115	161	–46,00	1,00
MAJUR	Majur	324	372	–48,00	1,00
SISAK	Hrastelnica	897	946	–49,00	0,99
DVOR	Kozibrod	70	119	–49,00	0,99
SUNJA	Kinjačka	213	263	–50,00	0,99
DONJI KUKURUZARI	Umetić	73	124	–51,00	0,99
KUTINA	Šartovac	380	433	–53,00	0,99
SUNJA	Kostreši Šaški	71	125	–54,00	0,99
SUNJA	Slovinci	152	206	–54,00	0,99
JASENOVAC	Višnjica	144	198	–54,00	0,99
NOVSKA	Brestača	913	969	–56,00	0,99
KUTINA	Međurić	485	542	–57,00	0,99
SISAK	Kratečko	199	260	–61,00	0,99
LIPOVLJANI	Krivaj	307	368	–61,00	0,99
SUNJA	Papići	56	117	–61,00	0,99
DONJI KUKURUZARI	Komogovina	126	188	–62,00	0,99
SISAK	Lonja	111	174	–63,00	0,99
SISAK	Topolovac	897	960	–63,00	0,99
POPOVAČA	Voloder	1.871	1.934	–63,00	0,99
DVOR	Unčani	189	261	–72,00	0,99
SISAK	Stupno	484	557	–73,00	0,99
LEKENIK	Letovanić	464	539	–75,00	0,99
POPOVAČA	Potok	756	835	–79,00	0,99
KUTINA	Banova Jaruga	665	748	–83,00	0,98
SISAK	Odra Sisačka	823	906	–83,00	0,98
SUNJA	Staza	220	304	–84,00	0,98
SUNJA	Šaš	307	394	–87,00	0,98
NOVSKA	Rajić	875	969	–94,00	0,98
NOVSKA	Stara Subocka	502	597	–95,00	0,98
GLINA	Šatornja	176	272	–96,00	0,98
DONJI KUKURUZARI	Donja Velešnja	261	359	–98,00	0,98
MAJUR	Gornji Hrastovac	209	313	–104,00	0,98
POPOVAČA	Popovača	4.207	4.312	–105,00	0,98
SUNJA	Drljača	277	385	–108,00	0,98
KUTINA	Repušnica	1.838	1.946	–108,00	0,98
POPOVAČA	Stružec	687	795	–108,00	0,98
SISAK	Blinjski Kut	277	386	–109,00	0,98
SISAK	Gušće	385	498	–113,00	0,98
SUNJA	Brđani Cesta	135	249	–114,00	0,98
JASENOVAC	Jasenovac	653	780	–127,00	0,97
SISAK	Greda	858	1.010	–152,00	0,96
SISAK	Crnac	545	710	–165,00	0,96
HRVATSKA	Živaja	309	484	–175,00	0,96
SISAK	Prelošćica	525	722	–197,00	0,95
NOVSKA	Novska	7.028	7.270	–242,00	0,94
LIPOVLJANI	Lipovljani	2.260	2.777	–517,00	0,86
KUTINA	Kutina	13.735	14.814	–1079,00	0,69
SISAK	Sisak	33.322	36.785	–3463,00	0,00

Prilog 8. Radni kontingent u naseljima Sisačko-moslavačke županije s pripadajućim parametrima pravičnoga potkriterija

Grad/Općina	Naselje	**Radni kontingent (15 – 64 godine)**	**Parametar pravičnoga potkriterija e_{sp10}**
SISAK	Sisak	22.710	2,00
PETRINJA	Petrinja	10.376	1,45
KUTINA	Kutina	9.346	1,41
NOVSKA	Novska	4.752	1,20
GLINA	Glina	3.158	1,13
POPOVAČA	Popovača	2.912	1,12
PETRINJA	Mošćenica	1.690	1,07
LIPOVLJANI	Lipovljani	1.529	1,06
HRVATSKA KOSTAJNICA	Hrvatska Kostajnica	1.412	1,05
LEKENIK	Lekenik	1.256	1,05
KUTINA	Repušnica	1.247	1,05
POPOVAČA	Voloder	1.238	1,05
SISAK	Budaševo	1.107	1,04
DVOR	Dvor	917	1,03
SUNJA	Sunja	899	1,03
HRVATSKA DUBICA	Hrvatska Dubica	676	1,02
KUTINA	Husain	674	1,02
SISAK	Sela	667	1,02
POPOVAČA	Gornja Gračenica	663	1,02
NOVSKA	Bročice	620	1,02
LEKENIK	Pešćenica	614	1,02
TOPUSKO	Topusko	603	1,02
SISAK	Greda	598	1,02
SISAK	Hrastelnica	598	1,02
NOVSKA	Brestača	595	1,02
SISAK	Topolovac	591	1,02
KUTINA	Ilova	555	1,02
NOVSKA	Rajić	555	1,02
SISAK	Novo Pračno	526	1,02
NOVSKA	Nova Subocka	503	1,01
VELIKA LUDINA	Velika Ludina	502	1,01
POPOVAČA	Potok	488	1,01
KUTINA	Banova Jaruga	450	1,01
POPOVAČA	Stružec	448	1,01
DVOR	Matijevići	431	1,01
KUTINA	Kutinska Slatina	422	1,01
LIPOVLJANI	Donja Vlahinićka	410	1,01
SISAK	Madžari	401	1,01
JASENOVAC	Jasenovac	393	1,01
LEKENIK	Donji Vukojevac	350	1,01
SISAK	Mužilovčica	347	1,01
SISAK	Prelošćica	347	1,01
PETRINJA	Mala Gorica	344	1,01
KUTINA	Međurić	341	1,01
SISAK	Gornje Komarevo	338	1,01
SISAK	Stupno	330	1,01
SISAK	Crnac	324	1,01

NOVSKA	Stara Subocka	316	1,01
LEKENIK	Letovanić	306	1,01
SISAK	Odra Sisačka	303	1,01
KUTINA	Stupovača	303	1,01
LIPOVLJANI	Piljenice	281	1,00
GLINA	Gornji Viduševac	280	1,00
KUTINA	Šartovac	277	1,00
NOVSKA	Stari Grabovac	252	1,00
LEKENIK	Dužica	243	1,00
NOVSKA	Jazavica	241	1,00
KUTINA	Zbjegovača	241	1,00
SISAK	Gušće	238	1,00
LEKENIK	Žažina	238	1,00
LEKENIK	Petrovec	237	1,00
PETRINJA	Novo Selište	215	1,00
LIPOVLJANI	Krivaj	213	1,00
SISAK	Donje Komarevo	208	1,00
SISAK	Palanjek	203	1,00
PETRINJA	Brest Pokupski	198	1,00
MAJUR	Majur	197	1,00
SUNJA	Drljača	191	1,00
SISAK	Blinjski Kut	190	1,00
KUTINA	Brinjani	182	1,00
DONJI KUKURUZARI	Donji Kukuruzari	181	0,99
SUNJA	Šaš	181	0,99
NOVSKA	Paklenica	175	0,96
PETRINJA	Gora	171	0,94
NOVSKA	Roždanik	168	0,92
HRVATSKA DUBICA	Živaja	168	0,92
PETRINJA	Donja Budičina	163	0,89
DONJI KUKURUZARI	Donja Velešnja	160	0,87
PETRINJA	Taborište	160	0,87
SISAK	Novo Selo	156	0,85
SISAK	Veliko Svinjičko	155	0,84
SUNJA	Staza	153	0,83
SUNJA	Kinjačka	151	0,82
SUNJA	Donji Hrastovac	147	0,80
KUTINA	Batina	141	0,76
MAJUR	Gornji Hrastovac	141	0,76
NOVSKA	Voćarica	133	0,71
SISAK	Kratečko	121	0,64
DVOR	Unčani	119	0,63
SUNJA	Petrinjci	117	0,62
LEKENIK	Stari Brod	115	0,61
MAJUR	Stubalj	107	0,56
TOPUSKO	Donja Čemernica	105	0,55
GLINA	Šatornja	104	0,54
GLINA	Prekopa	96	0,50
MAJUR	Graboštani	94	0,49
SUNJA	Slovinci	93	0,48
PETRINJA	Graberje	89	0,46
JASENOVAC	Višnjica	89	0,46
DVOR	Zamlača	89	0,46
SISAK	Lukavec Posavski	82	0,42

SUNJA	Brđani Cesta	80	0,40
HRVATSKA KOSTAJNICA	Čukur	79	0,40
HRVATSKA KOSTAJNICA	Panjani	79	0,40
DONJI KUKURUZARI	Komogovina	77	0,39
DONJI KUKURUZARI	Prevršac	77	0,39
SISAK	Lonja	76	0,38
SUNJA	Vedro Polje	76	0,38
SISAK	Čigoć	64	0,31
SUNJA	Brđani Kosa	63	0,30
DONJI KUKURUZARI	Knezovljani	63	0,30
DVOR	Kuljani	63	0,30
HRVATSKA DUBICA	Gornji Cerovljani	61	0,29
VELIKA LUDINA	Grabov Potok	60	0,29
GLINA	Marinbrod	60	0,29
PETRINJA	Moštanica	60	0,29
DVOR	Struga Banska	60	0,29
SISAK	Staro Selo	57	0,27
PETRINJA	Župić	55	0,26
LEKENIK	Stari Fakrašić	53	0,25
HRVATSKA DUBICA	Donji Cerovljani	47	0,21
SUNJA	Kostreši Šaški	46	0,20
SISAK	Novo Selo Palanječko	45	0,20
DVOR	Golubovac Divuški	44	0,19
DONJI KUKURUZARI	Umetić	43	0,19
DVOR	Volinja	42	0,18
SISAK	Letovanci	41	0,18
PETRINJA	Blinja	40	0,17
DVOR	Kozibrod	39	0,16
DVOR	Divuša	34	0,13
TOPUSKO	Batinova Kosa	31	0,12
GLINA	Kihalac	30	0,11
SUNJA	Papići	30	0,11
SISAK	Suvoj	28	0,10
SUNJA	Jasenovčani	23	0,07
PETRINJA	Bijelnik	21	0,06
SUNJA	Čapljani	17	0,04
SUNJA	Pobrđani	12	0,01
PETRINJA	Petkovac	11	0,00

Prilog 9. Parametri pravičnih kriterija i koeficijenti pravičnosti u naseljima Sisačko-moslavačke županije

Grad/Općina	Naselje	*Parametar pravičnoga kriterija PROMET* (e_{cpT})	*Parametar pravičnoga kriterija GOSPODARSTVO* (e_{cpE})	*Parametar pravičnoga kriterija DEMOGRAFIJA* (e_{cpD})	**Koeficijent pravičnosti** (C_e)
SISAK	Sisak	1,335	1,754	1,300	1,461
SISAK	Odra Sisačka	1,270	1,754	1,161	1,400
SISAK	Stupno	1,176	1,754	1,014	1,324
SISAK	Palanjek	1,116	1,754	1,023	1,299
SISAK	Budaševo	1,064	1,754	1,117	1,297
SISAK	Blinjski Kut	1,117	1,754	0,995	1,293
SISAK	Gornje Komarevo	1,094	1,754	1,030	1,291
SISAK	Greda	1,084	1,754	0,993	1,277
SISAK	Novo Pračno	1,020	1,754	1,069	1,266
KUTINA	Banova Jaruga	1,100	1,652	1,012	1,257
SISAK	Sela	1,019	1,754	1,017	1,254
SISAK	Crnac	0,955	1,754	1,048	1,232
SISAK	Novo Selo	0,963	1,754	1,008	1,227
SISAK	Gušće	1,083	1,754	0,773	1,226
SISAK	Topolovac	0,943	1,754	1,004	1,216
LEKENIK	Žažina	1,370	1,138	1,012	1,214
SISAK	Donje Komarevo	0,973	1,754	0,910	1,209
KUTINA	Ilova	0,987	1,652	1,015	1,206
SISAK	Prelošćica	0,943	1,754	0,822	1,175
SISAK	Novo Selo	1,008	1,754	0,663	1,168
SISAK	Madžari	0,868	1,754	0,931	1,166
SISAK	Letovanci	0,905	1,754	0,800	1,153
KUTINA	Kutina	0,824	1,652	1,091	1,151
SISAK	Hrastelnica	0,793	1,754	1,010	1,150
HRVATSKA KOSTAJNICA	Panjani	1,238	1,219	0,874	1,148
SISAK	Kratečko	0,953	1,754	0,643	1,138
PETRINJA	Mošćenica	1,140	1,057	1,233	1,135
KUTINA	Brinjani	0,878	1,652	0,901	1,131
LEKENIK	Pešćenica	1,170	1,138	1,012	1,124
KUTINA	Repušnica	0,799	1,652	1,015	1,122
SISAK	Suvoj	1,032	1,754	0,417	1,122
KUTINA	Šartovac	0,781	1,652	1,004	1,111
PETRINJA	Petrinja	0,887	1,057	1,608	1,107
SISAK	Mužilovčica	0,874	1,754	0,661	1,106
POPOVAČA	Gornja Gračenica	1,145	1,092	1,044	1,105
GLINA	Glina	0,889	1,100	1,494	1,096
KUTINA	Kutinska Slatina	0,708	1,652	1,038	1,086
LEKENIK	Petrovec	1,074	1,138	1,028	1,084
PETRINJA	Župić	1,229	1,057	0,826	1,081
KUTINA	Batina	0,709	1,652	0,954	1,067
HRVATSKA	Hrvatska Kostajnica	0,914	1,219	1,113	1,057
PETRINJA	Novo Selište	1,060	1,057	1,042	1,055
LEKENIK	Lekenik	1,004	1,138	1,037	1,054
GLINA	Marinbrod	1,167	1,100	0,755	1,051

GLINA	Prekopa	1,090	1,100	0,890	1,047
LEKENIK	Dužica	1,063	1,138	0,829	1,033
POPOVAČA	Popovača	0,969	1,092	1,071	1,032
TOPUSKO	Topusko	1,013	0,975	1,139	1,029
SISAK	Lukavec Posavski	0,686	1,754	0,674	1,025
KUTINA	Husain	0,566	1,652	1,032	1,021
KUTINA	Stupovača	0,574	1,652	1,002	1,017
JASENOVAC	Višnjica	1,067	1,139	0,738	1,015
POPOVAČA	Voloder	0,952	1,092	1,027	1,014
GLINA	Gornji Viduševac	0,954	1,100	1,011	1,014
LEKENIK	Stari Brod	0,974	1,138	0,909	1,012
PETRINJA	Donja Budičina	0,994	1,057	0,980	1,011
NOVSKA	Novska	0,838	1,120	1,162	1,003
LIPOVLJANI	Lipovljani	0,909	1,144	0,983	1,001
SISAK	Čigoć	0,733	1,754	0,461	0,997
SISAK	Staro Selo	0,705	1,754	0,510	0,996
LEKENIK	Letovanić	0,909	1,138	0,928	0,987
MAJUR	Majur	0,975	0,967	1,012	0,981
LEKENIK	Donji Vukojevac	0,849	1,138	1,019	0,980
KUTINA	Međurić	0,484	1,652	1,005	0,977
PETRINJA	Gora	1,009	1,057	0,800	0,976
PETRINJA	Graberje	1,006	1,057	0,758	0,965
MAJUR	Graboštani	1,007	0,967	0,879	0,964
PETRINJA	Mala Gorica	0,873	1,057	1,013	0,964
NOVSKA	Nova Subocka	0,777	1,120	1,042	0,948
MAJUR	Gornji Hrastovac	1,022	0,967	0,746	0,941
PETRINJA	Blinja	0,998	1,057	0,636	0,934
PETRINJA	Taborište	0,820	1,057	0,975	0,932
KUTINA	Zbjegovača	0,380	1,652	1,006	0,931
PETRINJA	Bijelnik	1,024	1,057	0,531	0,921
SUNJA	Vedro Polje	1,242	0,435	0,945	0,915
PETRINJA	Brest Pokupski	0,777	1,057	0,903	0,896
VELIKA LUDINA	Velika Ludina	0,946	0,699	1,045	0,890
MAJUR	Stubalj	0,830	0,967	0,893	0,888
GLINA	Šatornja	0,846	1,100	0,608	0,873
POPOVAČA	Potok	0,628	1,092	1,000	0,862
SISAK	Lonja	0,411	1,754	0,497	0,860
TOPUSKO	Batinova Kosa	0,955	0,975	0,438	0,842
PETRINJA	Moštanica	0,828	1,057	0,556	0,839
NOVSKA	Brestača	0,530	1,120	1,008	0,829
SUNJA	Brđani Cesta	1,110	0,435	0,809	0,825
POPOVAČA	Stružec	0,596	1,092	0,858	0,815
SISAK	Veliko Svinjičko	0,214	1,754	0,685	0,815
LIPOVLJANI	Krivaj	0,528	1,144	0,918	0,815
LIPOVLJANI	Donja Vlahinićka	0,463	1,144	1,044	0,815
JASENOVAC	Jasenovac	0,627	1,139	0,715	0,811
NOVSKA	Rajić	0,530	1,120	0,894	0,803
DONJI KUKURUZARI	Donji Kukuruzari	0,987	0,348	1,025	0,791
HRVATSKA KOSTAJNICA	Čukur	0,543	1,219	0,667	0,788
DVOR	Kuljani	1,103	0,286	0,827	0,778
GLINA	Kihalac	0,513	1,100	0,781	0,763

DONJI KUKURUZARI	Knezovljani	1,102	0,348	0,613	0,748
SUNJA	Papići	1,052	0,435	0,572	0,744
SUNJA	Sunja	0,784	0,435	1,045	0,732
VELIKA LUDINA	Grabov Potok	0,756	0,699	0,716	0,729
DVOR	Unčani	0,899	0,286	0,904	0,704
DVOR	Zamlača	0,903	0,286	0,872	0,699
SUNJA	Kinjačka	0,777	0,435	0,892	0,694
DVOR	Struga Banska	0,926	0,286	0,804	0,693
DVOR	Dvor	0,755	0,286	1,119	0,689
DVOR	Golubovac Divuški	0,909	0,286	0,801	0,685
DVOR	Kozibrod	0,963	0,286	0,685	0,682
SUNJA	Petrinjci	0,825	0,435	0,746	0,682
DVOR	Divuša	0,950	0,286	0,708	0,682
LEKENIK	Stari Fakrašić	0,456	1,138	0,462	0,676
NOVSKA	Bročice	0,179	1,120	1,017	0,673
NOVSKA	Jazavica	0,195	1,120	0,965	0,668
NOVSKA	Stara Subocka	0,187	1,120	0,959	0,663
SUNJA	Donji Hrastovac	0,788	0,435	0,724	0,661
NOVSKA	Roždanik	0,163	1,120	0,953	0,651
SUNJA	Drljača	0,610	0,435	0,996	0,643
NOVSKA	Paklenica	0,189	1,120	0,844	0,638
SUNJA	Staza	0,688	0,435	0,816	0,636
HRVATSKA DUBICA	Hrvatska Dubica	0,703	0,249	1,025	0,632
DONJI KUKURUZARI	Donja Velešnja	0,659	0,348	0,938	0,624
DVOR	Matijevići	0,579	0,286	1,149	0,617
PETRINJA	Petkovac	0,409	1,057	0,405	0,616
DONJI KUKURUZARI	Umetić	0,839	0,348	0,549	0,615
NOVSKA	Stari Grabovac	0,129	1,120	0,858	0,614
HRVATSKA DUBICA	Gornji Cerovljani	0,893	0,249	0,551	0,608
NOVSKA	Voćarica	0,157	1,120	0,768	0,606
SUNJA	Šaš	0,664	0,435	0,696	0,598
DVOR	Volinja	0,869	0,286	0,439	0,584
LIPOVLJANI	Piljenice	0,063	1,144	0,811	0,581
DONJI KUKURUZARI	Komogovina	0,743	0,348	0,577	0,579
TOPUSKO	Donja Čemernica	0,224	0,975	0,636	0,559
DONJI KUKURUZARI	Prevršac	0,713	0,348	0,544	0,557
HRVATSKA DUBICA	Živaja	0,694	0,249	0,634	0,538
SUNJA	Brđani Kosa	0,425	0,435	0,635	0,476
SUNJA	Jasenovčani	0,367	0,435	0,473	0,413
SUNJA	Kostreši Šaški	0,324	0,435	0,537	0,409
SUNJA	Čapljani	0,336	0,435	0,463	0,397
SUNJA	Slovinci	0,264	0,435	0,594	0,394
SUNJA	Pobrđani	0,202	0,435	0,356	0,312
HRVATSKA DUBICA	Donji Cerovljani	0,180	0,249	0,429	0,260

Prilog 10. Cijena tarifnih zona prema osnovnom i pravičnom modelu u Sisačko-moslavačkoj županiji

Grad/Općina	Naselje	*Srednja duljina linije* (l_p)*[km]*	**Cijena prema osnovnom modelu** $(p_z^{ST}(y))$ **[kn]**	*Koeficijent pravičnosti* (C_e)	**Cijena prema pravičnom modelu** $(p_{ez}^{ST}(y))$ **[kn]**
SISAK	Novo Selo Palanječko	10,600	19,08	1,167	22,27
SISAK	Sisak	7,120	12,81	1,461	18,72
SISAK	Gušće	6,840	12,31	1,226	15,09
PETRINJA	Petrinja	6,130	11,03	1,277	14,08
SISAK	Prelošćica	5,850	10,53	1,173	12,34
LIPOVLJANI	Lipovljani	6,680	12,02	1,001	12,03
SISAK	Madžari	5,260	9,46	1,166	11,03
GLINA	Glina	5,400	9,72	1,096	10,64
SISAK	Greda	4,435	7,98	1,273	10,16
SISAK	Kratečko	4,940	8,89	1,135	10,09
KUTINA	Kutina	4,830	8,69	1,148	9,98
KUTINA	Banova Jaruga	4,245	7,64	1,256	9,59
PETRINJA	Gora	5,430	9,77	0,976	9,53
LEKENIK	Letovanić	5,190	9,34	0,984	9,18
LEKENIK	Dužica	4,859	8,74	1,033	9,03
LEKENIK	Lekenik	4,710	8,47	1,051	8,91
JASENOVAC	Jasenovac	6,060	10,90	0,810	8,83
SISAK	Topolovac	3,960	7,12	1,214	8,65
LEKENIK	Pešćenica	3,975	7,15	1,123	8,03
POPOVAČA	Popovača	4,270	7,68	1,032	7,92
POPOVAČA	Gornja Gračenica	3,930	7,07	1,105	7,81
POPOVAČA	Voloder	4,285	7,71	1,011	7,79
MAJUR	Gornji Hrastovac	4,450	8,01	0,941	7,53
SISAK	Mužilovčica	3,770	6,78	1,104	7,49
NOVSKA	Novska	4,120	7,41	1,002	7,43
SISAK	Suvoj	3,610	6,49	1,118	7,26
SISAK	Hrastelnica	3,500	6,30	1,148	7,23
SISAK	Palanjek	3,060	5,50	1,298	7,15
JASENOVAC	Višnjica	3,890	7,00	1,014	7,10
KUTINA	Ilova	3,230	5,81	1,206	7,01
SISAK	Lukavec Posavski	3,800	6,84	1,025	7,00
KUTINA	Repušnica	3,440	6,19	1,120	6,93
TOPUSKO	Topusko	3,710	6,67	1,029	6,87
LEKENIK	Žažina	3,130	5,63	1,213	6,83
LEKENIK	Petrovec	3,350	6,03	1,084	6,53
HRVATSKA DUBICA	Hrvatska Dubica	5,750	10,35	0,630	6,51
SISAK	Gornje Komarevo	2,705	4,86	1,290	6,28
HRVATSKA DUBICA	Živaja	6,310	11,35	0,537	6,09
DONJI KUKURUZARI	Knezovljani	4,490	8,08	0,748	6,04
DVOR	Kuljani	4,130	7,43	0,778	5,78
PETRINJA	Donja Budičina	3,090	5,56	1,011	5,62
SISAK	Budaševo	2,380	4,28	1,296	5,55

GLINA	Šatornja	3,520	6,33	0,871	5,51
SISAK	Blinjski Kut	2,370	4,26	1,292	5,51
POPOVAČA	Stružec	3,760	6,76	0,814	5,51
PETRINJA	Mošćenica	2,680	4,82	1,134	5,47
HRVATSKA KOSTAJNICA	Hrvatska Kostajnica	2,855	5,13	1,057	5,43
DONJI KUKURUZARI	Donji Kukuruzari	3,740	6,73	0,791	5,32
KUTINA	Brinjani	2,620	4,71	1,129	5,32
SISAK	Sela	2,345	4,22	1,252	5,28
SISAK	Staro Selo	2,950	5,31	0,993	5,27
SUNJA	Donji Hrastovac	4,420	7,95	0,660	5,25
POPOVAČA	Potok	3,310	5,95	0,861	5,12
PETRINJA	Mala Gorica	2,950	5,31	0,961	5,10
GLINA	Gornji Viduševac	2,800	5,04	1,011	5,09
SISAK	Čigoć	2,840	5,11	0,996	5,09
SISAK	Novo Selo	2,280	4,10	1,226	5,03
PETRINJA	Taborište	2,890	5,20	0,931	4,84
PETRINJA	Župić	2,340	4,21	1,081	4,55
NOVSKA	Brestača	2,865	5,15	0,826	4,25
LEKENIK	Stari Brod	2,330	4,19	1,011	4,24
PETRINJA	Novo Selište	2,200	3,96	1,055	4,17
GLINA	Marinbrod	2,200	3,96	1,050	4,16
KUTINA	Husain	2,239	4,02	1,020	4,11
SISAK	Donje Komarevo	1,875	3,37	1,206	4,07
SUNJA	Petrinjci	3,200	5,76	0,682	3,92
NOVSKA	Bročice	3,240	5,83	0,671	3,91
SUNJA	Šaš	3,610	6,49	0,597	3,87
SISAK	Novo Pračno	1,700	3,06	1,266	3,87
DVOR	Dvor	3,100	5,58	0,688	3,84
DVOR	Unčani	2,990	5,38	0,704	3,78
LEKENIK	Donji Vukojevac	2,080	3,74	0,979	3,66
KUTINA	Šartovac	1,830	3,29	1,109	3,65
TOPUSKO	Batinova Kosa	2,400	4,32	0,840	3,62
SISAK	Veliko Svinjičko	2,440	4,39	0,814	3,57
SISAK	Odra Sisačka	1,410	2,53	1,399	3,55
SISAK	Stupno	1,490	2,68	1,323	3,54
MAJUR	Majur	1,950	3,51	0,981	3,44
LIPOVLJANI	Krivaj	2,340	4,21	0,813	3,42
PETRINJA	Brest Pokupski	2,070	3,72	0,894	3,33
PETRINJA	Graberje	1,770	3,18	0,963	3,06
PETRINJA	Blinja	1,800	3,24	0,933	3,02
HRVATSKA KOSTAJNICA	Panjani	1,450	2,61	1,148	2,99
HRVATSKA KOSTAJNICA	Čukur	2,050	3,69	0,788	2,90
PETRINJA	Moštanica	1,920	3,45	0,836	2,89
NOVSKA	Stara Subocka	2,410	4,33	0,662	2,87
LIPOVLJANI	Donja Vlahinićka	1,950	3,51	0,814	2,85
DVOR	Struga Banska	2,280	4,10	0,693	2,84
SUNJA	Brđani Cesta	1,770	3,18	0,824	2,62
PETRINJA	Bijelnik	1,560	2,80	0,921	2,58
DVOR	Kozibrod	2,070	3,72	0,682	2,54
SISAK	Crnac	1,142	2,05	1,232	2,53
NOVSKA	Nova Subocka	1,480	2,66	0,946	2,51

NOVSKA	Rajić	1,690	3,04	0,802	2,44
HRVATSKA DUBICA	Gornji Cerovljani	2,190	3,94	0,606	2,38
NOVSKA	Jazavica	1,980	3,56	0,667	2,37
VELIKA LUDINA	Velika Ludina	1,460	2,62	0,889	2,33
SUNJA	Sunja	1,755	3,15	0,730	2,30
SISAK	Letovanci	1,100	1,98	1,152	2,28
GLINA	Prekopa	1,210	2,17	1,047	2,28
MAJUR	Stubalj	1,400	2,52	0,888	2,23
DVOR	Volinja	2,080	3,74	0,582	2,17
DONJI KUKURUZARI	Prevršac	2,150	3,87	0,556	2,15
DONJI KUKURUZARI	Komogovina	1,920	3,45	0,577	1,99
SUNJA	Kinjačka	1,530	2,75	0,694	1,91
DVOR	Divuša	1,550	2,79	0,682	1,90
NOVSKA	Paklenica	1,650	2,97	0,637	1,89
SUNJA	Papići	1,380	2,48	0,744	1,84
KUTINA	Zbjegovača	1,100	1,98	0,930	1,84
SUNJA	Drljača	1,590	2,86	0,641	1,83
KUTINA	Stupovača	0,980	1,76	1,017	1,79
NOVSKA	Stari Grabovac	1,620	2,91	0,613	1,78
KUTINA	Batina	0,919	1,65	1,067	1,76
DVOR	Zamlača	1,380	2,48	0,698	1,73
MAJUR	Graboštani	0,958	1,72	0,964	1,66
VELIKA LUDINA	Grabov Potok	1,185	2,13	0,728	1,55
SUNJA	Staza	1,330	2,39	0,635	1,52
KUTINA	Kutinska Slatina	0,760	1,36	1,085	1,48
DONJI KUKURUZARI	Donja Velešnja	1,320	2,37	0,622	1,47
TOPUSKO	Donja Čemernica	1,470	2,64	0,558	1,47
DVOR	Golubovac Divuški	1,180	2,12	0,685	1,45
GLINA	Kihalac	1,020	1,83	0,762	1,39
DONJI	Umetić	1,160	2,08	0,613	1,28
NOVSKA	Rođdanik	1,090	1,96	0,650	1,27
SUNJA	Vedro Polje	0,765	1,37	0,915	1,26
SUNJA	Slovinci	1,750	3,15	0,393	1,23
NOVSKA	Voćarica	1,020	1,83	0,605	1,11
LIPOVLJANI	Piljenice	1,040	1,87	0,581	1,08
SISAK	Lonja	0,660	1,18	0,860	1,02
DVOR	Matijevići	0,890	1,60	0,616	0,98
SUNJA	Kostreši Šaški	1,110	1,99	0,407	0,81
SUNJA	Brđani Kosa	0,896	1,61	0,473	0,76
PETRINJA	Petkovac	0,660	1,18	0,614	0,72
SUNJA	Jasenovčani	0,950	1,71	0,411	0,70
SUNJA	Čapljani	0,790	1,42	0,395	0,56
LEKENIK	Stari Fakrašić	0,360	0,64	0,676	0,43
HRVATSKA DUBICA	Donji Cerovljani	0,820	1,47	0,260	0,38
KUTINA	Međurić	0,180	0,32	0,979	0,31
SUNJA	Pobrđani	0,540	0,97	0,313	0,30

Životopis autora

Denis Šipuš rođen je 10. siječnja 1990. u Sisku. Srednju je Željezničku tehničku školu završio 2008. godine u Zagrebu. Školovanje nastavlja na Fakultetu prometnih znanosti Sveučilišta u Zagrebu te 2011. godine završava preddiplomski, a 2013. godine diplomski studij prometa, smjer željeznički promet.

Na Fakultetu prometnih znanosti Sveučilišta u Zagrebu zapošljava se 2015. godine u suradničko zvanje asistenta na Zavodu za željeznički promet, gdje godinu dana kasnije upisuje poslijediplomski doktorski studij. Na Fakultetu je izvođač vježba i seminarskih radova na šest kolegija unutar Zavoda. Osim nastavnih aktivnosti, aktivno se bavi znanstveno-istraživačkim radom usredotočenim na istraživanja u organiziranju željezničkoga prometa, integriranoga prijevoza putnika i tarifnih sustava. Radio je na više znanstvenih i stručnih projekata. Kao autor i suautor objavio je ukupno 27 znanstvenih radova u znanstvenim časopisima indeksiranima u CC (*Current Content*), SCI (*Social Citation Index),* SCI–E (*Science Citation Index – Expanded*) i *Scopus* bazama te zbornicima međunarodnih znanstvenih konferencija i znanstvenim knjigama.

Na Fakultetu je voditelj Laboratorija za sigurnost željezničkog prometa, voditelj stručne prakse studenata željezničkoga smjera i član Odbora za promociju Fakulteta. Član je Skupštine željezničkog strukovnog razreda Hrvatske komore inženjera tehnologije prometa i transporta i zamjenik voditelja Grupacije za integrirani prijevoz putnika Zajednice za intermodalni transport i logistiku unutar Hrvatske gospodarske komore.

Godine 2008. dobitnik je nagrade *Najbolji učenik za područje željezničkog prometa* Agencije za strukovno obrazovanje nakon što je iste godine osvojio prvo mjesto na Državnom natjecanju prometnih struka. Tijekom diplomskoga studija 2012. godine na Državnom natjecanju inženjera *IHEEP – International Highway Engineering Exchange Program* osvaja drugo mjesto.

Tijekom studija sudjelovao je na brojnim mobilnostima od kojih treba istaknuti boravak u trajanju od mjesec dana na jednom od najvećih sveučilišta u Austriji – *TU Wien*.

Popis radova autora

1. Tečec, Kristina; **Šipuš, Denis**; Abramović, Borna. 2020. Analysis of Diagnostic Systems in Integrated Passenger Transport *// Proceedings of the International Scientific Conference "Science and Traffic Development" (ZIRP 2020)* / Ivanjko, Edouard ; Stanković, Ratko (ur.). Zagreb, Hrvatska: University of Zagreb Faculty of Transport and Traffic Sciences, str. 285-291 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
2. Lukanić, Tihomir; **Šipuš, Denis**; Abramović, Borna. 2020. Croatian Transport Development Strategy: A Review on Railway Sector *// Proceedings of the International Scientific Conference "Science and Traffic Development" (ZIRP 2020)* / Ivanjko, Edouard; Stanković,Ratko(ur.).Zagreb: University of Zagreb Faculty of Transport and Traffic Sciences, str. 121-128 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso).
3. Čarný, Štefan; Zitrický, Vladislav; **Šipuš, Denis**. 2020. Harmonization of Transport Charging in Slovak Republic. *LOGI – Sci J Transp Logist.* 11(1):12.
4. Abramović, Borna; **Šipuš, Denis**. 2020. Quality Assessment of Regional Railway Passenger Transport. // Lecture Notes in Mobility / Marinov, Marin; Piip, Janene (ur.). *Cham: Springer International Publishing.* 83–96. doi:10.1007/978–3–030–19519–9_2.
5. Abramović, Borna; **Šipuš, Denis**; Jurešić, Danijel. 2020. Organisation of Integrated Passenger Transport on the Zagreb – Velika Gorica Route. // Transportation Research Procedia / Stopkova, Maria; Bartuska, Ladislav; Stopka, Ondrej (ur.). České Budějovice: *Elsevier.* 342–347. doi:10.1016/j.trpro.2020.02.033 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
6. Abramović, Borna; **Šipuš, Denis**; Ontl, Luka. 2020. Analysis of Exploitation Indicators in Passenger Railway Transport in Sisak – Moslavina County. // Transportation Research Procedia / Stopkova, Maria; Bartuska, Ladislav; Stopka, Ondrej (ur.). České Budějovice: *Elsevier.* 327–331 doi:10.1016/j.trpro.2020.02.035 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
7. Abramović, Borna; **Šipuš, Denis**. 2019. University High Education in Croatia: A Case Study of the Railway Engineering Programme. // Sustainable Rail Transport (Proceedings of RailNewcastle 2017) / Fraszczyk, Anna; Marinov, Marin (ur.). *Cham: Springer.* 101–109. doi:10.1007/978–3–319–78544–8_6 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
8. **Šipuš, Denis**; Abramović, Borna; Gašparović, Slaven. 2019. Equity fare system: Factors affecting fare structure in integrated passenger transport. // *Transportation research procedia.* 40. 1192–1198. (međunarodna recenzija, članak, znanstveni).
9. Badrov, Tomislav; Nikšić, Mladen; **Šipuš, Denis**. 2019. Hybrid–Powered and Alternative–Fueled Hauling Railway Vehicles. // Proceedings of the International Scientific Conference "Science and Traffic Development" (ZIRP 2019.) / Grgurević, Ivan; Rožić, Tomislav (ur.). Zagreb. *Faculty of Transport and Traffic Sciences University of Zagreb*. 31–37. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
10. Vojtek, Martin; Kendra, Martin; Široký, Jaromír; Magdechová, Katarína; **Šipuš, Denis**. 2019. Supply Chain Simulation in Educational Process. *LOGI – Sci J Transp Logist.* 10/1. 6.

11. Brezina, Tadej; Abramović, Borna; Shibayama, Takeru; Jelisić, Slaviša; **Šipuš, Denis**; Zlokapa, Branko. 2018. Barriers to Trans–national passenger Rail services in the Western Balkans – The quantitative background. // Proceedings of the Fourth International Conference on Traffic and Transport Engineering / Čokorilo, Olja (ur.). Beograd. *City Net Scientific Research Center Ltd. Belgrade*. 717–724. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
12. Abramović, Borna; **Šipuš, Denis**; Ribarić, Martina. 2018. Analysis of the Organisation of Railway Freight Undertaking: A Case Study of HŽ Cargo Ltd. // *MATEC Web of Conferences*. 235 (2018). 00001. 5. doi:10.1051/matecconf/201823500001 (međunarodna recenzija, članak, znanstveni).
13. **Šipuš, Denis**; Abramović, Borna. 2018. Tariffing in Integrated Passenger Transport Systems: A Literature Review. // *Promet*. 30 (2018). 6. 745–751. doi:10.7307/ptt.v30i6.2948 (međunarodna recenzija, pregledni rad, znanstveni).
14. Abramović, Borna; **Šipuš, Denis**; Leko, Marko. 2018. The Analysis of the Organisation of Railway Passenger Transport on the Liberalised Market. // Road and Rail Infrastructure V / Lakušić, Stjepan (ur.). *Zagreb: Department of Transportation Faculty of Civil Engineering University of Zagreb*. 847–854. doi:10.5592/CO/CETR A.2018.658 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
15. **Šipuš, Denis**; Abramović, Borna; Černá, Lenka; Nedeliaková, Eva. 2018. Transport demand analysis in the Rural Area: The case study of Sisak – Moslavina county. // Proceedings of the Fourth International Conference on Traffic and Transport Engineering / Čokorilo, Olja (ur.). *Beograd: City Net Scientific Research Center Ltd. Belgrade*. 643–651. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
16. Lukanić, Tihomir; **Šipuš, Denis**; Abramović, Borna. 2018. UTILISATION OF A CLOCK–FACE TIMETABLE IN RAILWAY TRANSPORT. // Proceedings of the International Scientific Conference ”Science and Traffic Development” (ZIRP 2018) / Bajor, Ivona; Vidović, Andrija (ur.). *Zagreb: Faculty of Transport and Traffic Sciences, University of Zagreb*. 173–180. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
17. Lalinska, Jana; Gašparik, Jozef; **Šipuš, Denis**. 2017. Factors Affecting the Delay of Passenger Trains. // *LOGI – Scientific Journal on Transport and Logistic*. 8/1. 74–81. doi:10.1515/logi–2017–0009 (recenziran članak, znanstveni).
18. Blašković Zavada, Jasna; Abramović, Borna; **Šipuš, Denis**. 2017. A Strategic Model of Sustainable Mobility in the city of Zagreb and its Surrounding Area. // *International Journal for Traffic and Transport Engineering (IJTTE)*. 7/4. 430–442. doi:10.7708/ijtte.2017.7(4).03 (međunarodna recenzija, članak, znanstveni).
19. Nedeliakova, Eva; Panák, Michal; **Šipuš, Denis**. 2017. Innovative Trends in Process–Oriented Quality Management within Railway Transport. // *Periodica Polytechnica Transportation Engineering*. 45/2. 84–89. doi:10.3311/PPtr.9582 (međunarodna recenzija, članak, znanstveni).
20. Panák, Michal; Nedeliakova, Eva; Abramović, Borna; **Šipuš, Denis**. 2017. Synergies of the Liberalization of the Railway Transport Market. // *MATEC Web of Conferences*. Volume 134 (18th International Scientific Conference – LOGI 2017) / Stopka, Ondrej (ur.). České Budějovice, Češka Republika, 2017. 00045, 8 doi:10.1051/matecconf/201713400045 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).

21. Abramović, Borna; **Šipuš, Denis**; Šimunović, Ljupko; Panak, Michal. 2017. Proposal of the Tariff Model in Integrated Passengers Public Transport. // *Horizons of Railway Transport 2017* / Zahumenska , Zdenka ; Abramović , Borna (ur.). Žilina: University of Žilina. 12–19. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
22. **Šipuš, Denis**; Abramović, Borna. 2017. The Possibility of Using Public Transport In Rural Area. // *Procedia Engineering*. Volume 192 (12th International Scientific Conference Of Young Scientists On Sustainable, Modern and Safe Transport – TRANSCOM 2017) / Bujňák, Ján; Guagliano, Mario (ur.). Visoke Tatre. Slovačka. 788–793. doi:10.1016/j.proeng.2017.06.136 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
23. Abramović, Borna; Nedeliakova, Eva; Panak, Michal; **Šipuš, Denis**. 2017. Synergy in Logistics Processes for Railway Transport. // *Business Logistics in Modern Management* / Dujak, Davor (ur.). Osijek: Faculty of Economics Osijek. 15–28. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
24. Abramović, Borna; Pašagić Škrinjar, Jasmina; **Šipuš, Denis**. 2016. ANALYSIS OF RAILWAY INFRASTRUCTURE CHARGES FEES ON THE LOCAL PASSENGERS LINES IN CROATIA. // *Proceedings of the Third International Conference on Traffic and Transport Engineering* / Olja Čokorilo (ur.). Beograd: City Net Scientific Research Center. 918–923. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
25. Abramović, Borna; **Šipuš, Denis**. 2016. The Comparative Analysis of Transport Service Quality in Regional Rail and Bus Traffic // *Sustainable rail transport system at national level in the frame of EU* / Zitricky, V.; Pašagić–Škrinjar, J. (ur.). Žilina: University of Žilina. 13–20. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).
26. Abramović, Borna; **Šipuš, Denis**. 2015. PROPOSAL OF IMPROVEMENTS TO MOBILITY IN THE CITY OF SISAK. // *Železničná doprava a logistika – Railway Transport and Logistics*. 11/1. 4–11. (podatak o recenziji nije dostupan, članak, znanstveni).
27. Abramović, Borna; **Šipuš, Denis**. 2015. Analysis of container transport by rail in the Republic of Croatia. // *Sustainable rail system – cooperation in the research and innovation* / Gašparik, Jozef; Zitricky, Vladislav (ur.). Žilina: University of Žilina. 11–18. (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni).