

Toni Guštin

Prostorna optimizacija funkcija u Rijeci

Diplomski rad

Zagreb

2019.

Toni Guštin

Prostorna optimizacija funkcija u Rijeci

Diplomski rad

predan na ocjenu Geografskom odsjeku

Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu

radi stjecanja akademskog zvanja

magistra geografije

Zagreb

2019.

Ovaj je diplomski rad izrađen u sklopu diplomskog sveučilišnog studija *Geografija*; smjer:
Prostorno planiranje i regionalni razvoj na Geografskom odsjeku Prirodoslovno-
matematičkog fakulteta Sveučilišta u Zagrebu, pod vodstvom prof. dr. sc. Dražena Njegača

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek

Diplomski rad

Prostorna optimizacija funkcija u Rijeci

Toni Guštin

Izvadak: Neracionalna organizacija prostora predstavlja velik problem i izazov za prostorne planere. Kako bi riješili taj problem, prostorni planeri se služe različitim skupovima metoda i tehnika među koje spada i prostorna optimizacija. Predmet rada je primijeniti metode i tehnike prostorne optimizacije u reorganizaciji funkcionalno-prostorne strukture Grada Rijeke. Cilj je predstaviti prostornu optimizaciju kao skup tehnika i metoda kojima se nastoji postići racionalna alokacija funkcionalnih zona čime se postiže veća dostupnost gradskih funkcija, to jest kvalitetnija funkcionalno-prostorna struktura, a sve to uz minimalne financijske troškove i na maksimalno ekološki prihvatljiv način. Kako bi se to postiglo formirani su model alokacije (simulira stanje funkcionalno-prostorne strukture Grada Rijeke 2050. godine nakon provedbe prostorna optimizacija), i model promjene (predviđa stanje funkcionalno-prostorne strukture Grada Rijeke 2050. godine u slučaju da ne dođe do prostorne optimizacije). Usporedba rezultata dana je u obliku dva različita scenarija pri čemu scenarij koji sadrži prostornu optimizacijom ukazuje na bolju kompaktnost i raznovrsnost funkcionalnih zona, odnosno funkcionalno-prostorne strukture nego scenarij koji ne sadrži prostornu optimizaciju. Metode korištene u radu su više-agentni sustavi, genetski algoritmi, optimizacija kolonijom mrava, analize u GIS-u, terenski rad, metoda deskripcije, metoda analogije, matematičko modeliranje, metoda scenarija, ćelijski automati, umjetne neuronske mreže, troškovna metoda procjene nekretnina, statističke i geostatističke analize te metode krajobrazne metrike.

94 stranice, 36 grafičkih priloga, 9 tablice, 59 bibliografskih referenci; izvornik na hrvatskom jeziku

Ključne riječi: prostorna optimizacija, model promjene, model alokacije, Grad Rijeka, funkcionalno-prostorna struktura, funkcionalne zone

Voditelj: prof. dr. sc. Dražen Njegač

Povjerenstvo: prof. dr. sc. Dražen Njegač
prof. dr. sc. Aleksandar Toskić
doc. dr. sc. Lana Slavuj Borčić

Tema prihvaćena: 10. 1. 2019.

Rad prihvaćen: 12. 9. 2019

Rad je pohranjen u Središnjoj geografskoj knjižnici Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Marulićev trg 19, Zagreb, Hrvatska.

University of Zagreb
Faculty of Science
Department of Geography

Master Thesis

Spatial optimization of Rijeka city functions

Toni Guštin

Abstract: Irrational spatial organization is a major problem and challenge for spatial planners. To solve this problem, spatial planners use different sets of methods and techniques, including spatial optimization. The subject of this paper is to apply methods and techniques of spatial optimization in the reorganization of the functional-spatial structure of the City of Rijeka. The aim is to present spatial optimization as a set of techniques and methods that seek to achieve rational allocation of functional zones, thereby achieving greater accessibility of urban functions, that is, a better functional-spatial structure, all with minimal financial costs and in the most environmentally friendly manner. In order to achieve this, an allocation model (simulating the state of the functional-spatial structure of the City of Rijeka in 2050 after spatial optimization), and a model of change (predicts the state of the functional-spatial structure City of Rijeka in 2050 in case there is no spatial optimization) were formed. The comparison of the results is in the form of two different scenarios, with the scenario containing spatial optimization indicating better compactness and diversity of functional zones, that is, functional-spatial structure than the scenario containing no spatial optimization. The methods used in the work are multi-agent systems, genetic algorithms, ant colony optimization, GIS analysis, fieldwork, descriptive method, analogy method, mathematical modelling, scenario method, cellular automata, artificial neural networks, real estate costing method, statistical and geostatistical analysis and methods of landscape metric.

94 pages, 36 figures, 9 tables, 59 references; original in Croatian

Keywords: spatial optimization, model of change, model of allocation, City of Rijeka, functional-spatial structure, functional zones

Supervisor: Dražen Njegač, PhD, Full Professor

Reviewers: Dražen Njegač, PhD, Full Professor
Aleksandar Toskić, PhD, Full Professor
Lana Slavuj Borčić, PhD, Assistant Professor

Thesis title accepted: 10/01/2019

Thesis accepted: 12/09/2019

Thesis deposited in Central Geographic Library, Faculty of Science, University of Zagreb, Marulićev trg 19, Zagreb, Croatia.

Sadržaj

1. UVOD	1
1.1. Predmet rada, ciljevi rada i dosadašnja istraživanja	2
1.2. Hipoteze	2
2. PROSTORNI OBUHVAT ISTRAŽIVANJA	3
3. METODOLOGIJA ISTRAŽIVANJA	4
3.1. Prostorna simulacija	4
3.1.1. Čelijski automati	5
3.1.2. Model promjene	5
3.1.1.1. Zahtjev za promjenom strukture	6
3.1.1.2. Ukupni tranzicijski potencijal	6
3.1.2.1. Potencijal susjedstva	7
3.1.2.2. Stohastičnost	9
3.1.2.3. Dostupnost cestovne mreže	10
3.1.2.4. Sukladnost	11
3.1.2.5. Urbana pravila	12
3.2. Prostorna optimizacija	13
3.2.1. Prostorna optimizacija u geografiji	14
3.2.2. Model alokacije	18
3.2.2.1. Faza odabira najpovoljnijih varijabli i njihova analiza	19
3.2.2.1.1. Prosječne cijene nekretnina	20
3.2.2.1.2. Kakvoća okoliša	22
3.2.2.1.3. Kompleksnost planiranja	25
3.2.2.1.4. Grupiranje industrije	27
3.2.2.2. Faza integracije varijabli upotrebom AHP metode i kreiranje agenata	28
3.2.2.3. Faza odabira optimalne početne lokacije za svaku vrstu agenata	35
3.2.2.4. Udaljenost agenata od optimalnih lokacija	37
3.2.2.5. Faza određivanja „barijera“	37
3.2.2.6. Faza optimizacije kolonijom mrava	38
3.2.2.7. Faza alokacije funkcionalnih zona	40
3.3. Ostale metode	41
4. PROSTORNA STRUKTURA GRADA RIJEKE	43
4.1. Morfološka struktura	43
4.2. Funkcionalno-prostorna struktura	46
4.2.1. Funkcija stanovanja	46

4.2.2. Funkcija rada	47
4.2.3. Funkcija opskrbe.....	48
4.2.4. Funkcija odmora	49
4.2.5. Funkcija obrazovanja	51
4.2.6. Funkcija prometa i komunikacije.....	52
4.3. Socijalno-prostorna struktura	53
5. PRAKTIČNI PRIMJER UPOTREBE PROSTORNE OPTIMIZACIJE – PROMJENA FUNKCIONALNO- PROSTORNE STRUKTURE GRADA RIJEKE U BUDUĆNOSTI.....	54
5.1. Scenarij 1: Prostorno širenje gradskih funkcija Grada Rijeke bez prostorne optimizacije (pesimistični scenarij).....	56
5.2. Scenarij 2: Prostorno širenje gradskih funkcija Grada Rijeke na temelju prostorne optimizacije (optimistični scenarij)	57
6. DALJNJA ISTRAŽIVANJA	59
7. ZAKLJUČAK.....	60
LITERATURA.....	61
IZVORI.....	65
PRILOZI	VII

1. UVOD

Mnogi od današnjih gradova su kombinacija reda i kaosa. Naime, iako se prostornim planiranjem nastoji uvesti red te zaštititi posebno vrijedne prostore grada i na taj način održati ravnotežu između ljudi i prostora na kojem ti ljudi žive kako bi se mogla održati harmonija i prostorni sklad, određeni postupci pojedinaca (npr. nezakonita gradnja) ili nekih interesnih skupina, koji se vode nekim svojim osobnim interesima i često ne mare za opće dobro i opću korist, narušavaju taj red stvarajući prostornu neravnotežu i nejednake odnose moći koji u konačnici dovode do kaosa u prostoru. Pritom se to ne očituje samo u fizičkoj strukturi grada već i u kompletnoj prostornoj strukturi. Tako, na primjer, lokacija objekta jedne gradske funkcije može oduzeti mjesto objektu neke druge potrebnije funkcije koja se razmješta na lokaciju objekta neke treće funkcije što utječe na to da se ta treća funkcija gubi ili se razmješta dalje u prostoru. To smanjuje dostupnost određene funkcije što može dovesti do promjena u socijalno-prostornoj strukturi. Naime, većina socijalnih skupina nastojati će povećati svoju dostupnost do određenih gradskih funkcija što može potaknuti tržišno natjecanje za onaj dio prostora koji pokazuje veću dostupnost. Pojava tržišnog natjecanja podiže vrijednost prostora pa on postaje dostupan bogatijim i utjecajnijim socijalnim skupinama, a manje dostupan ili ponekad nedostupan siromašnijim i slabije utjecajnim socijalnim skupinama. S druge strane, na dijelu prostora koji ima slabiju dostupnost, slabi zainteresiranost socijalnih skupina za prisutnošću na tom prostoru čime tom prostoru pada vrijednost pa on postaje dostupniji siromašnijim i manje utjecajnim socijalnim skupinama. Time nastaje segregirani socijalno-prostorni mozaik sa značajnim razlikama u raspodjeli moći između pojedinih socijalnih skupina. Navedeni primjer pokazuje kako je prostorna struktura grada odraz složenih prostornih odnosa koji u njemu vladaju i ukoliko se ti odnosi izbace iz ravnoteže, to može drastično promijeniti prostornu strukturu te kroz određeno vremensko razdoblje dovesti do pojave kaosa. Kako bi vratili prostorne odnose u ravnotežu, prostorni planeri koriste razne metode i tehnike, među koje spada i prostorna optimizacija. „Prostorna optimizacija bavi se maksimiziranjem ili minimiziranjem cilja vezanog za problem geografske prirode, kao što je odabir rute, modeliranje raspodjele lokacije, prostorna uzorkovanja i raspodjele korištenja zemljišta“ (Delmelle, 2010). Drugim riječima, prostorna optimizacija je niz matematičkih i računalnih postupaka koji po strogo definiranim uvjetima pronalaze najbolje moguće rješenje određenog prostornog problema (Ligmann-Zielinska, 2017) te je kao takva usko povezana s geografijom i predstavlja važno sredstvo u implementaciji geografskih istraživanja u prostorno planiranje.

1.1. Predmet rada, ciljevi rada i dosadašnja istraživanja

Predmet rada je primijeniti metode i tehnike prostorne optimizacije u reorganizaciji funkcionalno-prostorne strukture Grada Rijeke. Glavni cilj je predstaviti prostornu optimizaciju kao skup tehnika i metoda kojima se nastoji postići racionalna alokacija funkcionalnih zona čime se postiže veća dostupnost gradskih funkcija, to jest kvalitetnija funkcionalno-prostorna struktura, a sve to uz minimalne financijske troškove i na maksimalno ekološki prihvatljiv način. Također, jedan od ciljeva rada je i istražiti mogućnosti upotrebe prostorne optimizacije u urbanom i prostornom planiranju na primjeru reorganizacije funkcionalno-prostorne strukture Rijeke.

Što se tiče dosadašnjih istraživanja nisu pronađena istraživanja koja se bave ovom konkretnom temom. Najveću sličnost s ovom temom imaju radovi Ligmann-Zielinske, Churcha i Jankowskog (2005) te Zhanga, Zenga i Biana (2010) koji koriste prostornu optimizaciju u određivanju optimalne raspodjele korištenja zemljišta. U tim radovima oni koriste višekriterijsku prostornu optimizaciju. Razlog odabira višekriterijske prostorne optimizacije leži u činjenici da je taj oblik optimizacije ima manju mogućnost zarobljavanja u lokalnom minimumu što mu daje osjetnu prednost u odnosu na samostalne metode (npr. genetski algoritmi ukoliko se ne kombiniraju s drugim metodama, kao što su više-agentni sustavi, optimizacija kolonijom mrava i slično, imaju veću mogućnost greške). I u ovom radu se koristi višekriterijska prostorna optimizacija. Uz ranije navedene razloge, još jedan razlog zašto je to tako je i taj da se jedino kroz kombinaciju različitih metoda može shvatiti puna kompleksnost prostora što je često potrebno za ozbiljne geografske analize.

1.2. Hipoteze

Sukladno ranije navedenim ciljevima, u radu su postavljene slijedeće hipoteze:

- 1) Razvoj funkcionalno-prostorne strukture bez prostorne optimizacije utjecati će na povećanje centralizacije gradskih funkcija u centru grada
- 2) Provedbom prostorne optimizacije stvoriti će se heterogena funkcionalno-prostorna struktura
- 3) Nakon provođenja prostorne optimizacije, funkcionalno-prostorna struktura ima veću unutarnju koheziju (između pojedinih gradskih funkcija)

2. PROSTORNI OBUHVAT ISTRAŽIVANJA

Istraživanje je rađeno na prostoru Grada Rijeke, koji uključuje grad Rijeku i naselje Sveti Kuzam. Ta dva naselja su morfološki povezana pa su razmatrana kao jedinstvena struktura.

Također, u pojedinim dijelovima rada korišteni su podaci po mjesnim odborima (Sl.1). U Gradu Rijeci postoje 34 mjesna odbora.



Sl.1. Mjesni odbori Grada Rijeke

Izvor: izradio autor prema Izvor 14

3. METODOLOGIJA ISTRAŽIVANJA

Metodologija ovog rada je usko vezana uz matematičke modele i njihovu primjenu u geografiji i urbanom planiranju. Matematički modeli u urbanom planiranju dijele se na tri velike grupe, a to su: deskriptivni, prediktivni i planski modeli (Vresk, 1990). Deskriptivni modeli nastoje objasniti odnose u nekom zadanom vremenu, prediktivni modeli nastoje predvidjeti pojave u budućnosti na način da u razmatranje kao faktor uzimaju vrijeme, a planski (u literaturi se još upotrebljavaju nazivi evaluativni ili perspektivni) modeli služe određivanju potencijalnih alternativa u planiranju (Vresk, 1990). Za razliku od cjelovitih ili kompleksnih modela koji se razmatraju u teoriji, u praksi se većinom koriste parcijalni modeli u kojima se analizira jedan segment ili jedna pojava (Vresk, 1990).

U ovom radu, korišteni su upravo takvi parcijalni modeli. Prvi model (model promjene) analizira promjenu funkcionalnih zona bez prostorne optimizacije i temelji se na ćelijskim automatima, a drugi model (model alokacije) je hibridni model koji analizira promjenu funkcionalnih zona nakon provedbe prostorne optimizacije. U oba modela, u istraživanom području gradske funkcije su svrstane u pet glavnih funkcionalnih zona, a to su neodređena zona, ograničena zona, stambena zona, poslovna zona i industrijska zona. Na temelju raspodjele tih funkcionalnih zona u prostoru određena je funkcionalno-prostorna struktura Grada Rijeke. Neodređena zona uključuje sve objekte koji ili nemaju jednu od gradskih funkcija ili ju je teško razabrati. Ograničena (restriktivna) zona uključuje funkcije odmora, opskrbe, obrazovanja te prometa i komunikacije, a naziva se ograničena zona iz razloga što objekti te zone rijetko mijenjaju funkciju. Stambena zona obuhvaća objekte s funkcijom stanovanja. Poseban slučaj su objekti s funkcijom rada koji su ovisno o vrsti podijeljeni na poslovne i industrijske zone. Veličina svake zone određena je ukupnim zbrojem ćelija objekata koji pripadaju toj zoni, s tim da je veličina svake ćelije definirana dimenzijama 35m x 35m.

3.1. Prostorna simulacija

Prostorna simulacija (engl. *Spatial Simulation*) je jedna od najsloženijih metoda prostorne analize koja pomoću različitih prostornih podataka nastoji predvidjeti stanje u prostoru u nekom određenom trenutku u vremenu (de Sousa i da Silva, 2011). Jedan od najčešćih načina za provođenje prostorne simulacije je upotreba ćelijskih automata.

3.1.1. Čelijski automati

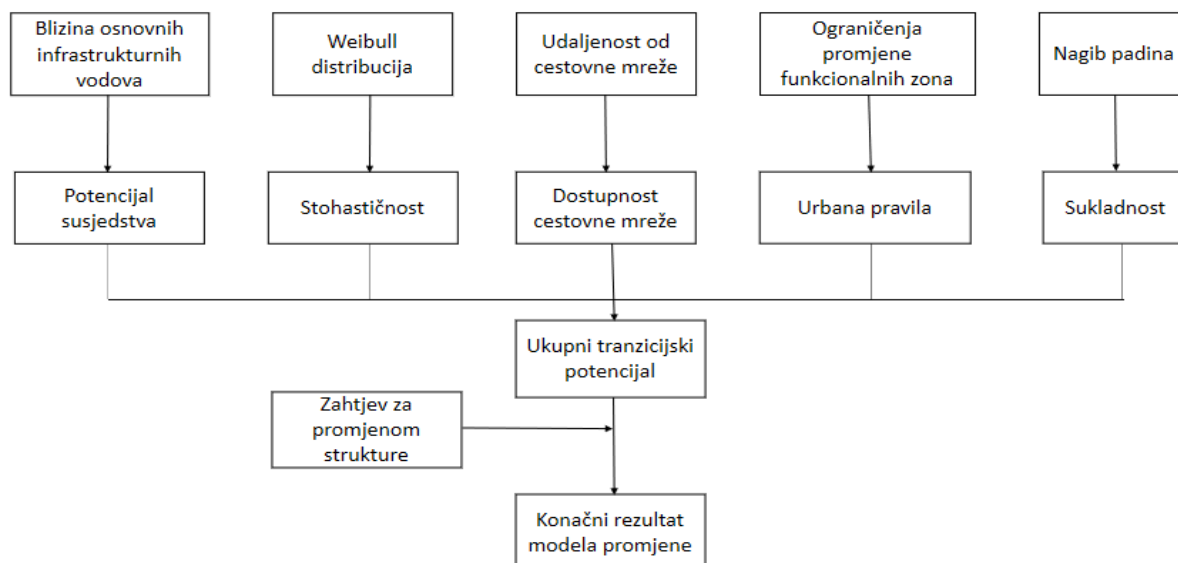
Čelijski automati (engl. *Celullar Automata* - CA) je vrsta prostorno-vremenskog dinamičkog diskretnog sustava na rasterskoj mreži koji djeluje na temelju lokalnih pravila pri čemu se svaki sustav sastoji se od četiri komponente-ćelije (pikseli u umjetnom svijetu diskretne mreže GIS-a), stanja (klasa korištenja zemljišta u klasificiranim slikama ili, konkretno u ovom radu, zone u funkcionalno-prostornoj strukturi), susjedstvo (sve ćelije koje okružuju neku središnju ćeliju (Von Neumannovo susjedstvo, Mooreovo susjedstvo, kružno susjedstvo, itd.)) i prijelazna pravila (Jogun, 2016; Tharayil, 2016 prema Sharaf i Jie, 2008).

3.1.2. Model promjene

Model promjene dobiven je metodom prostorne simulacije pomoću čelijskih automata na temelju kombinacije programskih dodataka SIMLANDerR i MOLUSCE.

SIMLANDerR ili Simulacija promjena korištenja zemljišta u R-u (engl. *Simulation of Land Use in R*) su prostorni čelijski automati za R okruženje koji zahtijevaju podatke o godišnjoj promjeni korištenja zemljišta i potencijalima prijelaza kako bi izračunala i kartografski prikazala urbana područja u nadolazećim godinama (Tharayil, 2016). S druge strane, MOLUSCE ili Moduli simulacije promjene zemljišnog pokrova (engl. *Modules for Land Use Change Simulations*) je programski dodatak za QGIS koji pruža mogućnost provedbe brze i praktične analize promjena zemljišnog pokrova (Izvor 1). Međutim, za razliku od njihove standardne primjene, u ovom radu se ti programski dodatci koriste kako bi se ustanovile određene pravilnosti dosadašnjih promjena funkcionalnih zona i na temelju tih pravilnosti predvidio izgled i raspored funkcionalnih zona u budućnosti. Drugim riječima, SIMLANDerR i MOLUSCE su korišteni u procesu izračunavanja budućih promjena funkcionalno-prostorne strukture.

Kako bi se izračunala buduća promjena funkcionalno-prostorne strukture potrebno je izračunati zahtjev za promjenom strukture i ukupni tranzicijski potencijal. Cijeli postupak dobivanja modela promjene prikazan je pomoću dijagrama toka (Sl. 2.)



Sl. 2. Dijagram toka modela promjene

Izvor: modificirao autor prema Tharayil, 2016

3.1.1.1. Zahtjev za promjenom strukture

Zahtjev za promjenom strukture označava broj ćelija koje će proći kroz postupak prenamjene funkcionalne zone, a izračunava se na način da se ukupna promjena funkcionalne strukture podijeli s brojem godina između početne (2014.) i završne (2019.) godine razmatranja. Drugim riječima, uspoređuje se koliki je broj ćelija prešao iz jedne u drugu funkcionalnu zonu u razdoblju od 2014. do 2019. godine, odnosno koliko se promjenila funkcionalno-prostorna struktura 2019. (Prilog 1.) u odnosu na funkcionalno-prostornu strukturu 2014. (Prilog 2.) godine. S druge strane, ukupni tranzicijski potencijal označava vjerojatnost da će na nekom prostoru doći do promjene funkcionalne strukture.

3.1.1.2. Ukupni tranzicijski potencijal

Veći ukupni tranzicijski potencijal neke lokacije znači da postoji veća vjerojatnost da će se na toj lokaciji doći do promjene iz jedne gradske funkcije u drugu i obrnuto. Iz niza mogućih faktora koji mogu poslužiti za izračunavanje ukupnog tranzicijskog potencijala, odabrani su slijedeći faktori:

- 1) Potencijal susjedstva (N)
- 2) Stohastičnost (α)
- 3) Dostupnost cestovne mreže (A)
- 4) Sukladnost (S)
- 5) Urbana pravila (U)

Izračunavanjem navedenih faktora sukladno zadanoj formuli

$$\text{Ukupni tranzicijski potencijal (UTP)} = N \times \alpha \times A \times S \times U$$

dobiva se vrijednost ukupnog tranzicijskog potencijala (Prilog 3.) (Tharayil, 2016).

Ta vrijednost izražena je bodovima koji odražavaju sklonost neke ćelije da promjeni vrstu svoje funkcionalne zone. Pojednostavljeno rečeno, ukupni tranzicijski potencijal označava koliko su pojedini fragmenti neke funkcionalne zone pogodni za prenamjenu u neku drugu vrstu funkcionalne zone. Najniža vrijednost je 0 i ona označava područja koja su zbog određenih ograničenja izuzeta iz analize, odnosno područja kojima je onemogućena promjena funkcionalne zone. S druge strane, najveća vrijednost je 25 i ona označava ona područja za koja je izvjesno da će u dogledno vrijeme prijeći u neku drugu vrstu funkcionalne zone. Međutim, kako bi se u potpunosti razumio princip dobivanja ukupnog tranzicijskog potencijala potrebno je detaljnije analizirati varijable na temelju kojih je on dobiven.

3.1.2.1. Potencijal susjedstva

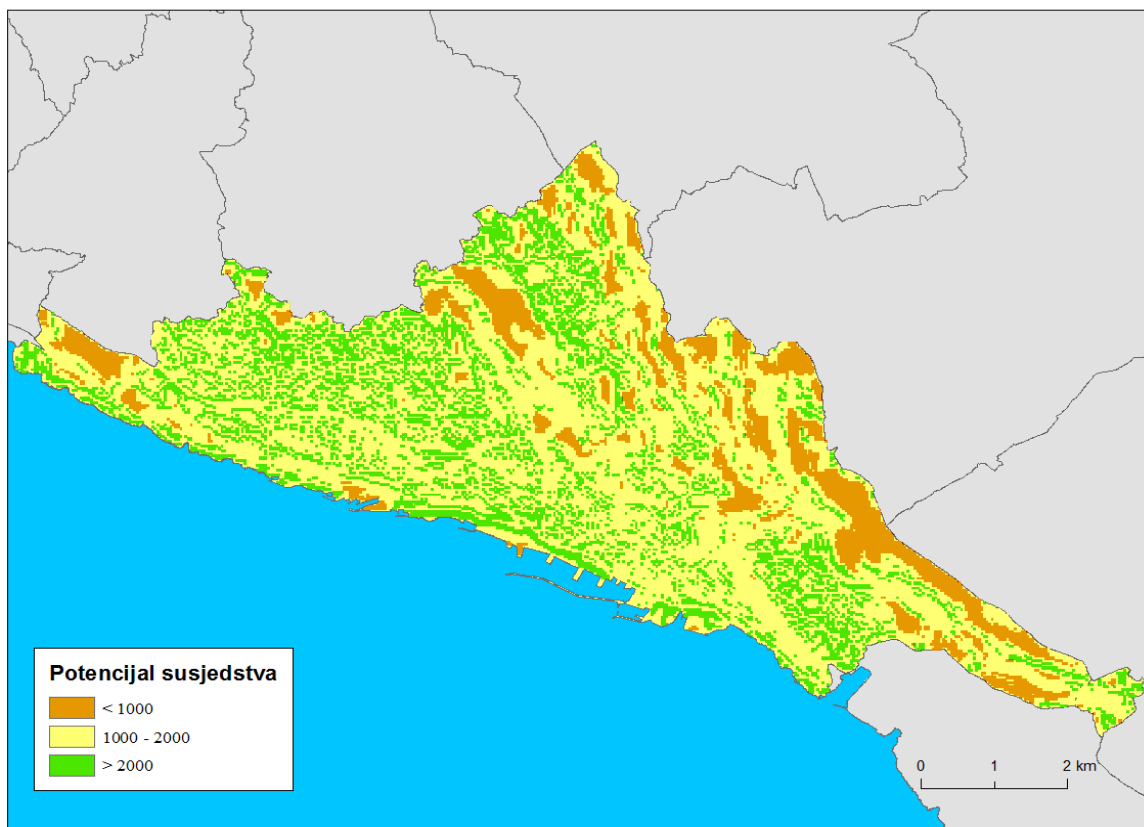
Potencijal susjedstva (N) predstavlja jezgru modela ćelijskih automata, odnosno potencijal susjedstva označava osjetljivost neke pojedinačne ćelije c na promjenu stanja u određenom vremenskom razdoblju T_n (Tharayil, 2016). U skladu s dosadašnjim istraživanjima na ovu temu (Tharayil, 2016), susjedstvo je određeno na temelju matrice prostornih težina dimenzije 5×5 (Sl. 3.), koja funkcionira na način da ukoliko se u susjedstvu središnje ćelije povećava broj onih ćelija koji predstavljaju objekte s nekom od gradskih funkcija, automatski se povećava i ukupni potencijal susjedstva središnje ćelije. Ta se matrica primjenjuje pomoću pomičućeg filtera (w).

	[,1]	[,2]	[,3]	[,4]	[,5]
[1,]	0	0	50	0	0
[2,]	0	50	50	50	0
[3,]	50	50	500	50	50
[4,]	0	50	50	50	0
[5,]	0	0	50	0	0

Sl. 3. Pomićući filter matrice prostornih težina dimenzije 5 x 5

Izvor: Hewitt, Diaz Pacheco i Moya Gomez, 2013

Primjenom pomićućeg filtera dobivena je karta potencijala susjedstva (Sl. 4.) koja upućuje na to gdje su najveće mogućnost promjene funkcionalne zone. Veće vrijednosti potencijala označavaju veću mogućnost promjene funkcionalne zone. Najveći potencijal susjedstva (više od 2000 bodova) imaju izgrađena područja. Naime, budući da na tim područjima već postoji osnovna infrastruktura (infrastrukturni vodovi vodoopskrbe, elektroopskrbe i plinoopskrbe) ta područja imaju veću vjerojatnost prijelaza u neku drugu vrstu funkcionalnih zona. S druge strane, zbog nedovoljno razvijene osnovne infrastrukturne mreže neizgrađena i slabo izgrađena područja imaju najmanji potencijal susjedstva (manje od 1000 bodova).

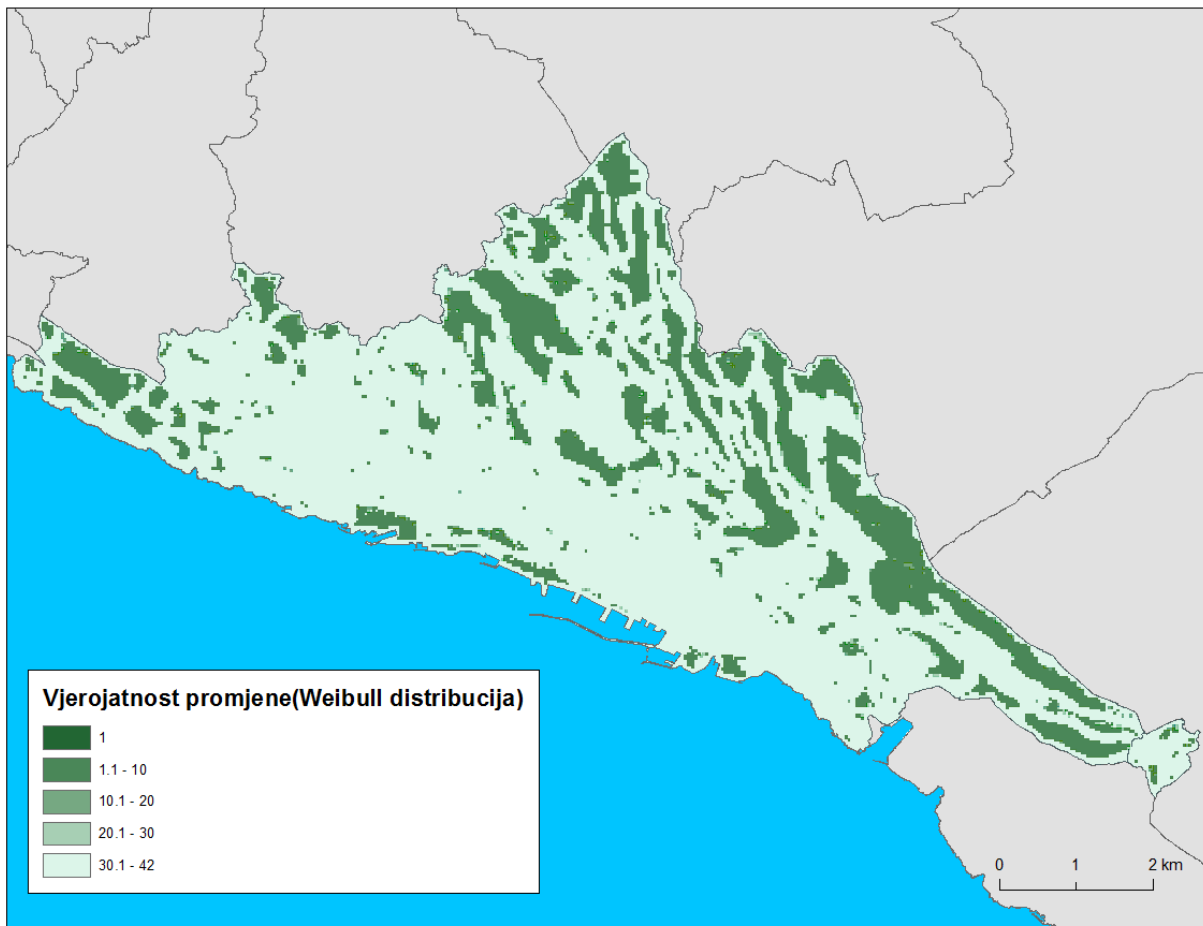


Sl. 4. Potencijal susjedstava za promjenu funkcionalno-prostorne strukture Grada Rijeke

Izvor: izradio autor prema Izvor 14

3.1.2.2. Stohastičnost

Budući da razmještaj ljudi i njihovih aktivnosti koji utječu na izgled funkcionalno-prostorne strukture nije uvijek deterministički određen, potrebno je u analizu uvesti faktor slučajnog razmještaja koji je dobiven pomoću stohastičnosti. Stohastičnost (α) je metoda dodjeljivanja visokih vrijednosti slučajnim točkama (Tharayil, 2016), a na temelju koje je moguće odrediti da li postoji pravilnost promjene ili je ona posljedica slučajnosti (Sl. 5.). Ako je vrijednost ćelije 1 postoji pravilnost, u suprotnome radi se o slučajnosti. Dobivene vrijednosti ukazuju na to da pravilnost promjene funkcionalno-prostorne strukture imaju rubni dijelovi Grada, dok u ostalim dijelovima nema pravilnosti. Drugim riječima, zbog manje gustoće i raznovrsnosti gradskih funkcija lakše je odrediti buduće promjene funkcionalno-prostorne strukture na rubovima Grada nego u njegovom središnjem dijelu.



Sl. 5. Vjerojatnost promjene funkcionalno-prostorne strukture Grada Rijeke prema Weibull distribuciji

Izvor: izradio autor prema Izvor 14

3.1.2.3. Dostupnost cestovne mreže

Dostupnost cestovne mreže (engl. *Accessibility* – A) (Sl. 6.) označava lakoću s kojom stanovnici mogu doći od svoje početne do završne točke (Tharayil, 2016). Također, (Tharayil, 2016) navodi da je dostupnost izračunava korištenjem sljedeće jednadžbe:

$$a_j = 1 + \left(\frac{D}{\delta_i}\right)^{-1}$$

u kojoj a_j predstavlja dostupnost, D udaljenost, a δ_i označava koeficijent ceste (u ostalim analizama dostupnosti δ_i označava općenito reklasificirane vrijednosti udaljenosti).

Koeficijent ceste dobiva se reklasificiranjem karte udaljenosti do cesta. To je učinjeno tako da veće vrijednosti udaljenosti do cesta dobiju manji koeficijent ceste. Kako se udaljenost od ceste povećava, dostupnost se smanjuje. Reklasifikacija je napravljena naredbom Reclassify u ArcGIS-u.



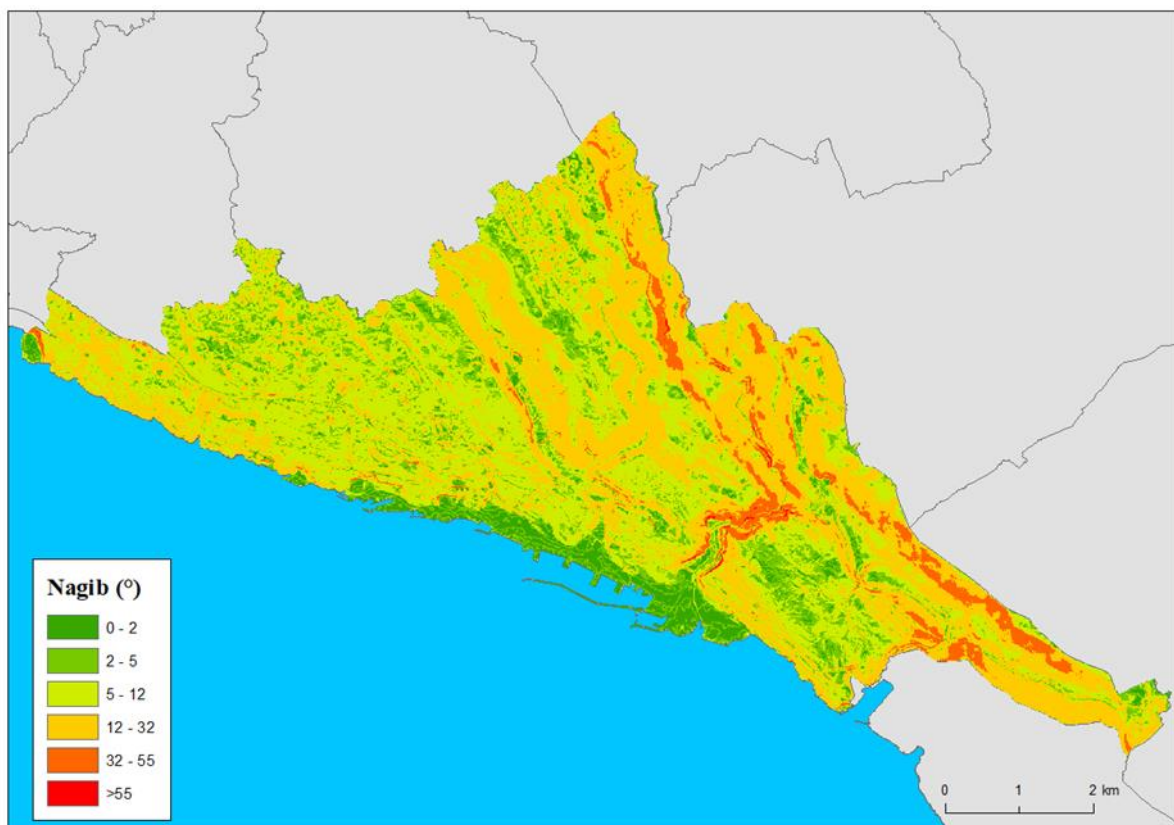
Sl. 6. Dostupnost cestovne mreže u Gradu Rijeci

Izvor: Izvor 12; Izvor 14

Dobivene vrijednosti pokazuju da bolju dostupnost cestovne mreže imaju središnji dijelovi Grada, dok se prema periferiji dostupnost smanjuje. Razlozi za to leže u činjenici da središnji dijelovi Grada imaju složeniju morfološku strukturu u kojoj se gusta cestovna mreža koristi u međusobnom povezivanju pojedinih dijelova te strukture, ali i kao sredstvo povezivanja te strukture s morfološkom strukturom ostalih dijelova Grada. S druge strane, periferija Grada ima manje složenu morfološku strukturu što generira manju gustoću cestovne mreže, a time i lošiju dostupnost.

3.1.2.4. Sukladnost

Sukladnost je varijabla koja govori koliko je neko područje pogodno za izgradnju. Tharayil (2016) navodi da se analiza sukladnosti provodi pomoću karata nagiba (Sl. 7.).



Sl.7. Kategorije nagiba padina u Gradu Rijeci

Izvor: izradio autor prema Izvor 16

Prema općoj ocjeni, urbani rast javlja se u područjima s niskim nagibom koja imaju veću pogodnost građenja nego područja s visokim nagibom. Naime, Bognar (1992) navodi da se prema građevinskoj iskoristivosti nagib padina može podijeliti na slijedeće kategorije:

- 1) 0° - 2° (padine veoma povoljne za gradnju)
- 2) 2° - 5° (padine povoljne za gradnju)
- 3) 5° - 12° (padine povoljne za gradnju ukoliko se prethodno provede odgovarajuće uređenje)
- 4) 12° - 32° (nepovoljne padine koje je moguće koristiti za gradnju samo uz značajne zahvate)
- 5) $> 32^{\circ}$ (padine nepovoljne za gradnju)

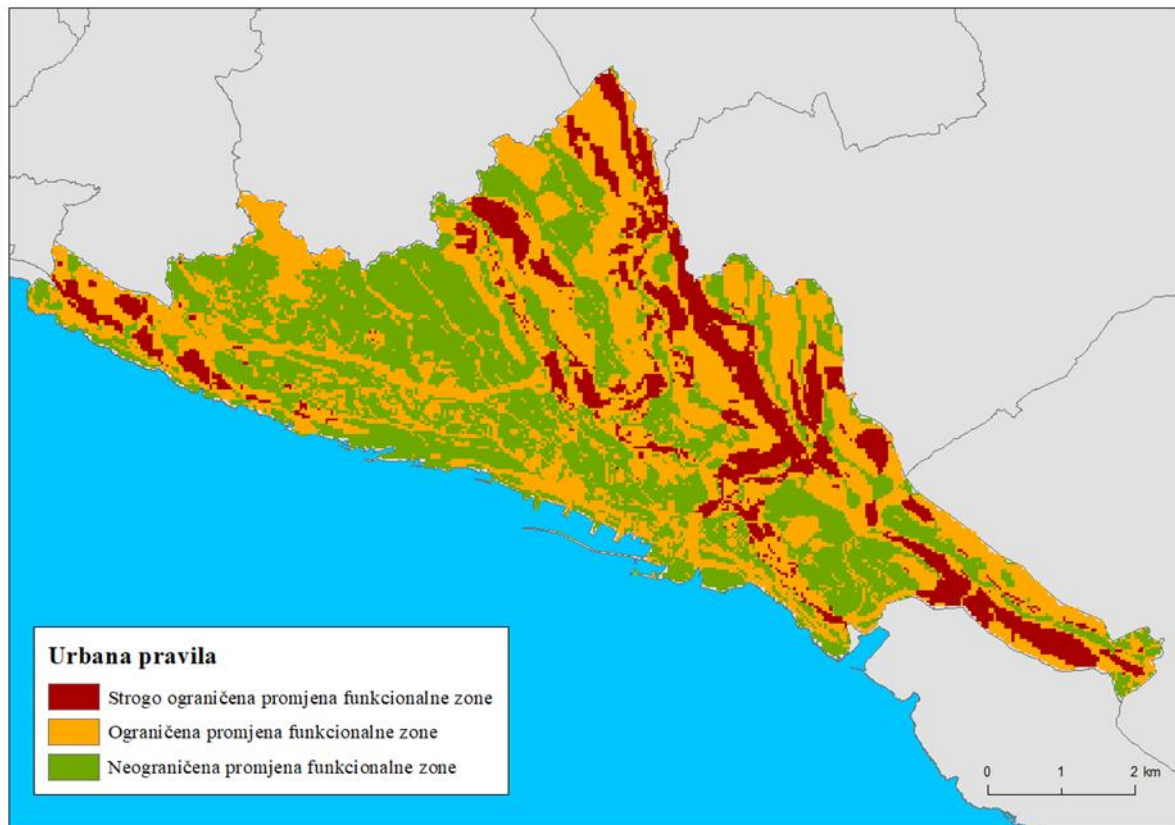
Dakle, prema Bognarovoj klasifikaciji, karta nagiba je reklasificirana tako da su područja niskog nagiba dobila su visoku vrijednost sukladnosti, odnosno prikladnosti za gradnju, a područja visokog nagiba dobila su nisku vrijednost prikladnosti za gradnju (Bognar, 1992; Tharayil, 2016). Ukratko, vrijednost 1 je dodijeljena područjima s nagibom većim od 32° , a vrijednost 5 područjima s nagibom između 0° i 2° . Dobiveni rezultati pokazuju da se prema nagibu padina najpovoljnija područja za građenje nalaze u središnjem dijelu, a nepovoljna na periferiji Grada i uz kanjon Rječine.

3.1.2.5. Urbana pravila

Urbana pravila (U) predstavljaju set posebnih zakonitosti kojima se funkcionalno-prostorna struktura nekog područja korigira na temelju posebnih odredbi koje su navedene u prostorno-planskoj dokumentaciji, što potvrđuje i sam naziv urbana pravila koji je preuzet iz Generalnog urbanističkog plana Grada Rijeke. Drugim riječima, urbana pravila predstavljaju ograničenja širenja funkcionalnih zona (Sl. 8.).

U modelu promjene, urbana pravila korištena su kao prostorna maska kojom su se iz analize izuzela ona područja koja imaju ograničenja promjene funkcionalno-prostorne strukture, to jest područja strogo ograničene i ograničene promjene funkcionalnih zona, na način da im je dodijeljena vrijednost 0. Područja strogo ograničene promjene su ona područja na kojima je Generalnim urbanističkim planom onemogućena daljnja gradnja, a jedan od razloga za to je i nepovoljna konfiguracija terena. Naime, ako se razmotri već ranije izračunate vrijednosti nagiba padina moguće je uočiti snažnu prostornu korelaciju između padina nepovoljnih za

gradnju i područja strogo ograničene promjene. S druge strane, područja ograničene promjena uključuju ona područja restriktivnih zona na kojima je zbog specifične urbane forme onemogućena promjena u neku drugu vrstu funkcionalne zone.



Sl. 8. Urbana pravila promjene funkcionalno-prostorne strukture Grada Rijeke

Izvor: izradio autor prema Izvor 2, Izvor 3, Izvor 14, Izvor 16

3.2. Prostorna optimizacija

Prostorna optimizacija u radu se primijenjuje kako bi se odredio izgled optimalne funkcionalno-prostorne strukture u budućnosti. Prostorna optimizacija je u metodološki podijeljena na dva područja, a to su prostorna optimizacija u geografiji i model alokacije. U podpoglavlju Prostorna optimizacija u geografiji razmatra se teorijska veza prostorne optimizacije i geografije, a u podpoglavlju Model alokacije detaljno se objašnjava specifični model koji je korišten za optimizaciju funkcionalno-prostorne strukture Grada Rijeke.

3.2.1. Prostorna optimizacija u geografiji

Prostorna optimizacija je već dugo važna subspecijalnost u brojnim disciplinama geografije, kao što su prometna geografija, ekonomska geografija, medicinska geografija, politička geografija i druge slične geografske discipline (Tong i Murray, 2012).

Te se discipline oslanjaju na prostornu optimizaciju kao tehniku za strukturiranje i rješavanje karakterističnih prostornih problema (Tong i Murray, 2012).

Značenje prostorne optimizacije u geografije proizlazi iz njezine praktične primjene pa zato ne iznenađuje da se temeljne geografske teorije, kao što su von Thünenov model koncentričnih krugova, Weberova minimizacija troškova kod izbora lokacije industrijskih postrojenja, te Christallerova i Loschova teorija centralnih naselja (Tong i Murray, 2012, prema: Kuby, 1989; Church 2001; Church i Murray, 2009), koriste prostornom optimizacijom u objašnjavanju i razumijevanju prostorne logike ili određivanju najpovoljnije lokacije (Tong i Murray, 2012).

Također, Tong i Murray (2012) navode da se slično kao i matematički i inženjerski optimizacijski problemi, problemi prostorne optimizacije obično sastoje od 3 vrste varijabli, a to su:

- 1) ciljevi
- 2) odluke
- 3) ograničenja

Cilj optimizacije predstavlja svrhu optimizacije i često se odnosi na smanjenje troškova ili maksimiziranje koristi, varijabla odluke odnosi se na određena rješenja koja je potrebno provesti kako bi se postigla optimalna struktura, dok, s druge strane, ograničenja predstavljaju uvjete koji moraju biti zadovoljeni kako bi dobivena rješenja bila u skladu s realnim stanjem proučavanog sustava pa se često te tri vrste varijabli kombiniraju kako bi se izrazili i riješili određeni prostorni problemi vezani uz geografiju i geografski predmet interesa (Tong i Murray, 2012). U ovom radu cilj prostorne optimizacije je reorganizirati funkcionalno-prostornu strukturu na način da ona generira minimalne financijskih troškova te da je maksimalno ekološki prihvatljiva. S druge strane, ograničenja prostorne optimizacije su određena na temelju posebnih odredbi prostorno-planske dokumentacije (Izvor 2; Izvor 3).

Dakle, prema Tong i Murray (2012), problemi prostorne optimizacije imaju praktično značenje u procesu odlučivanja o određenim prostornim posebnostima, a kako bi se ti problemi

učinkovito riješili potrebno ih je kvalitetno strukturirati oslanjajući se na stručnost samog izvođača, ali i osnovne tehničke vještine koje sama prostorna optimizacija nudi.

Najočitiji sastavni dio prostornog modela optimizacije u geografiji su vjerojatno varijable odlučivanja jer često se događa da neke odluke moraju biti donesene ovisno o kontekstu samog problema koji se nastoji riješiti te pritom trebaju obuhvatiti pitanja koliko nečega treba negdje smjestiti, kako odabrati najbolji put ili pak kako treba izgledati uzorak neke aktivnosti u prostoru (Tong i Murray, 2012). Sukladno tome, optimizacijski problemi se na određeni način specificiraju i formuliraju kako bi se na odgovarajući način predstavljali stvarnost i njezine probleme što nije nimalo lagan zadatak, posebno ako se radi o problemima i situacijama vezanim uz prostorni kontekst (Tong i Murray, 2012). Složeni prostorni odnosi često traže da se prostorni problem konstruira koristeći matematička znanja i principe na logički smislen način s time da su poput, mnogih geografskih modela, modeli za rješavanje problema prostorne optimizacije svojoj osnovi računalno intenzivni (Tong i Murray, 2012; Tong i Murray, 2012, prema: Armstrong, 2000). Kao neki od razloga zašto su prostorno optimizacijski problemi izazovni i teško rješivi su složenost prostornih odnosa i oblika, konstantne potrebe za dodatnim ograničenjima i varijablama te stalni porast količine podataka koji zahtijeva veću detaljnost i dodatno otežava veći postojeći prostorni problem (Tong i Murray, 2012). Također, tipičan interes prostorne optimizacije je da u skupu kritičnih točaka pronađe ekstreme (min i max) tražene matematičke funkcije koji su u pravom smislu riječi predstavljeni kroz apsolutni minimum ili maksimum ovisno da li je svrha rada smanjenje ili povećavanje određenog cilja, ali pritom često nije uvijek moguće naći derivaciju tražene matematičke funkcije i pridržavati se ograničenja izvedivosti (Tong i Murray, 2012), što je pridonijelo nastajanja dviju grupa metoda u rješavanju prostorno optimizacijskih problema, a to su točne i heuristične metode (Tong i Murray, 2012, prema: Scott, 1971, Miller i Shaw, 2001, Church i Murray, 2009).

Točne metode su one metode koje isprobavanjem svih mogućnosti ili iskorištavanjem problemskih svojstava omogućavaju odabir optimalnog rješenja, a temelje se na tehnikama kao što su diferencijalne jednačbe, linearno programiranje, cjelobrojno programiranje te specifične višestruko problemske metode poput Mađarskog algoritam, transportne simpleks metode, Dijkstra algoritma i slično (Tong i Murray, 2012). Uz to, važno je reći da točne metode predstavljaju osnovu prostorne optimizacije. Naime, formalno korištenje optimizacija u proučavanju geografskih pojava krenulo je s razvojem linearnog programiranja, matematičkog pristupa koji je baziran na linearnoj algebri i rješavanju sustava linearnih jednačbi pri čemu su ciljevi i ograničenja linearne funkcije, a varijable odluke imaju kontinuirane vrijednosti (Tong

i Murray, 2012). Također, osim što predstavlja osnovu prostorne optimizacije, linearno programiranje je i danas jedan od najkorištenijih pristupa u rješavanju problema prostorne optimizacije. Uz linearno programiranje, jedna od točnih metoda koja se često primjenjuje u prostornoj optimizaciji je i cjelobrojno programiranje. Cjelobrojno programiranje je točna metoda za rješavanje problema u kojima su varijable odluke ograničene na cjelobrojnim vrijednostima, a koristi se za rješavanje problema kod kojih linearno programiranje pokazuje ograničavajuće sposobnosti (Tong i Murray, 2012). Međutim, za razliku od ostalih vrsta optimizacijskih problema, prostorno optimizacijski problemi su teško rješivi upotrebom točnih metode zbog toga što je potrebno povezati geografske odnose, kao što su udaljenost, susjedstvo, povezanost, zatvorenost, raskrižja, oblik, općina i uzorak, sa željenom matematičkom strukturom što je u mnogim slučajevima teško napraviti ukoliko algoritmi razmatraju cjelokupnu populaciju, kao što je to slučaj s točnim metodama (Tong i Murray, 2012). Upravo zbog tog razloga se, u geografskim istraživanjima koja se temelje na prostornoj optimizaciji, sve češće koriste heurističke metode. Naime, za razliku od točnih metoda, heurističke metode su metode koje po potrebi u zadanom vremenu pronalaze kvalitetna rješenja (Tong i Murray, 2016). Neke od heurističkih metode koje se često koriste su:

- 1) Naivna ili slučajna strategija
- 2) Pohlepni algoritam
- 3) Simulirano žarenje
- 4) Tabu pretraživanje

Naivna strategija je pristup koji iz skupine kandidata na temelju slučajnog odabira bira određeni broj lokacija pritom ne razmatrajući prostornu strukturu pri odabiru rješenja, zbog čega se smatra vrlo neučinkovit, ali ipak, unatoč tome, numerički rezultati koji su dobiveni naivnom strategijom stvaraju dobru donju granicu u procjenjivanju kvalitete ostalih heurističkih metoda (Delmelle, 2010). Nešto bolja metoda je pohlepni algoritam. Pohlepan (ili kratkovidan) algoritam je vrsta algoritma koji odabire moguće rješenjem, a zatim ukoliko se unutar populacije nađe bolje rješenje onda se postojeće rješenje zamijeni s tim drugim, boljim rješenjem, a taj se proces nastavlja sve dok se dolazi do sve boljih i boljih rješenja što ga čini jednostavnim za upotrebu i vrlo učinkovitim ako se primjenjuje više puta (Delmelle, 2010). Za razliku od pohlepnog algoritma, simulirano žarenje je heuristička metoda koja ima sposobnost izbjegavanja zarobljavanja u lokalnom optimumu što mu omogućuje da pronađe optimalno rješenje na način da koristi stohastičko pretraživanje kojim se odabiru kvalitetna, ali i manje

kvalitetna rješenja koja se prihvaćaju s određenom vjerojatnošću (Delmelle, 2010). S druge strane, tabu pretraživanje je metoda slična simuliranom žarenju koja, za razliku od žarenja, zabranjuje zamjenu trenutnog rješenja za već prethodno razmotreno rješenje na način da to ranije razmotreno i odbijeno rješenje uvrsti u listu zabranjenih poteza čime se pri pokretanju algoritma to rješenje preskače (Delmelle, 2010). Da bi se dobila još kvalitetnija rješenja heurističke metode mogu se kombinirati pritom dajući metaheurističku metodu, a kao jedan od najpoznatijih primjera metaheurističke metode navode se evolucijski algoritmi (Delmelle, 2010). Evolucijski algoritmi „su algoritmi koji simulacijom evolucije nad populacijom rješenja, uzrokuju njeno postupno napredovanje prema boljem rješenju, a u konačnici i najboljem“ (Damjanić, 2008, 1). Posebna vrsta evolucijskih algoritama su genetski algoritmi. Genetski algoritam je metaheuristička metoda globalne optimizacije koje na osnovu tehnika iz evolucijske biologije nastoji u svakoj iteraciji odabrati najbolja rješenja pri čemu teži poboljšanju izvedivog ili neoptimalnog rješenja operacijama kojima se pojedinci kombiniraju kako bi se poboljšala obilježja populacije (Delmelle, 2010), a koristi se u rješavanju problema kao što su problemi optimizacije koji se mogu riješiti uz primjenu numeričkih metoda i/ili uz pomoć kombinatorike te problem trgovačkog putnika (Zhang, Zeng i Bien, 2010). Gotovo svi genetski algoritmi se sastoje od tri ključna dijela, a to su selekcija, rekombinacija i mutacija. Selekcija se temelji na procjeni obilježja svakog pojedinca u populaciji ili promatranom skupu i izboru najboljih pojedinaca koji se kasnije koriste u rekombinaciji i odabiru najprikladnijeg rješenja (Delmelle, 2010). Operator rekombinacije je stohastički binarni operator varijacije koji vrši izbor dijelova gena koji će se prenijeti s roditelja na potomke na način da se nasumično spajaju poželjne genetske informacije dva ili više roditelja stvarajući pritom jedan ili više potomaka koji će objediniti poželjne karakteristike svojih roditelja (Droždjek, 2015). S druge strane, operator mutacije je unarni operator kod kojeg je ulazni podatak jedan genotip, a kao izlazni podatak nastaje modificirani genotip (s tim da se često radi o manjim promjenama) (Droždjek, 2015). Drugim riječima, „mutacija je zajedničko ime za sve operatore koji iz genotipa samo jednog roditelja kreiraju samo jedno dijete, uz pomoć neke vrste nasumične promjene“ (Droždjek, 2015, 2). Pritom valja istaknuti da se kod mutacija uvijek radi o stohastičkom operatoru kod kojeg genotip potomka nastaje kao posljedica nekog niza slučajno nastalih promjena (Droždjek, 2015). Ukoliko se zna da nije svaki unarni operator mutacija već da bi on to bio on mora ostvariti uvjete kao što su nepristranost i nasumičnost, moguće je zaključiti da je to i razlog zašto se velik broj heurističkih operatora nisu mutacije u pravom smislu riječi (Droždjek, 2015).

Međutim, iako heurističke i metaheurističke metode predstavljaju napredak u odnosu na točne metode, ni one nisu bez mana. Kao ključni nedostatak navodi se to da često ne postoji način da se procijeni točnost dobivenih rezultata što posebno dolazi do izražaja kod prostornih problema koji su mnogo složeniji od ostalih problema zato što uključuju različite perspektive i interese u prostoru kao što su društveni, ekološki, ekonomski, politički, pravni i slični interesi koji se često međusobno sukobljavaju, a kao rezultat tih interesa javljaju se problemska rješenja (rijetko postoji samo jedno rješenje) koja često odražavaju kompromise između različitih ciljeva raznih aktera (Tong i Murray, 2012).

Kako bi se ti nedostaci uklonili često se koriste hibridni modeli optimizacije. Hibridni modeli su vrsta modela koji se dobivaju integracijom dvije ili više metoda kako bi se postigli najbolji mogući rezultati (Jogun, 2016). Sukladno tome, u ovom radu se također koristi hibridni model optimizacije, a taj se model naziva model alokacije funkcionalnih zona, ili kraće, model alokacije.

3.2.2. Model alokacije

Model alokacije je hibridni model prostorne optimizacije koji u sebi integrira analize u GIS-u, višekriterijsko vrednovanje, genetske algoritme, umjetne neuronske mreže, više-agentne sustave i optimizaciju kolonijom mrava. Svaka od tih metoda ima specifičnu ulogu u samom modelu. Analize u GIS koriste se za izradu i provođenje modela alokacije. Za provođenje analiza u GIS-u korišteni su programski paketi ArcGIS i QGIS. Višekriterijsko vrednovanje korišteno je kako bi se dodijelile težinske vrijednosti varijablama odluke. Te težinske vrijednosti određuju koliko je koja varijabla važna u procesu donošenja odluka. Na taj način se povezuju metode analize i sinteze varijebli odluke kako bi se dobilo što kvalitetnije rješenje. Genetski algoritmi uvode mogućnost učenja i nasljeđivanja jedinki čime se iz generacije u generaciju dobivaju sve bolje i bolje jedinke. Umjetne neuronske mreže je oblik strojnog učenja koji na temelju grupiranih uzoraka podataka metodom pokušaja i pogrešaka pronalazi poveznicu između podataka (Jogun, 2016). U kontekstu modela alokacije, umjetne neuronske mreže su korištene u programskom dodatku FLUKS programskog paketa GeoSOS za izvršavanje operatora samoučenja. „Više-agentni sustavi predstavljaju skup agenata koji međusobno djeluju u zajedničkom vanjskom okolišu“ (Jogun, 2016, 17). Važnost više-agentnih sustava u prostornoj optimizaciji je uvođenje većeg broja prostornih aktera u analizu kako bi ona dobila na što većoj točnosti. U modelu alokacije, svi agenti su određeni tipom, varijablama

odluke, parametrima odlučivanja i vrijednošću funkcije podobnosti. Tip označava vrstu agenata koji imaju svoj utjecaj na rješavanje problema optimizacije, varijable odlučivanja označavaju faktore koji služe agentima za donošenje odluka, parametri odlučivanja označavaju težinske vrijednosti koje se dodjeljuju varijablama odlučivanja kako bi se istaknula važnost pojedine varijable u procesu donošenja odluka (Zhang, Zeng i Bian, 2010), a funkcija podobnosti označava uvjete kojima se agent mora prilagoditi kako bi bio konkurentan (Droždjek, 2015; Zhang, Zeng i Bian, 2010). Optimizacijom kolonijom mrava pronalaze se područja koja je potrebno optimizirati.

Model alokacije ima nekoliko faza. Faze u modelu alokacije su:

- 1) Faza odabira najpovoljnijih varijabli i njihova analiza
- 2) Faza integracije varijabli upotrebom AHP metode i kreiranje agenata
- 3) Faza odabira optimalne početne lokacije za svaku vrstu agenata
- 4) Faza određivanja udaljenosti agenata od optimalnih lokacija
- 5) Faza određivanja „barijera“
- 6) Faza optimizacije kolonijom mrava
- 7) Faza alokacije gradskih funkcija

3.2.2.1. Faza odabira najpovoljnijih varijabli i njihova analiza

Ovisno o vrsti agenata određene su varijable odluke i specifični parametri odlučivanja (razlikuju se ovisno o vrsti agenata na koje se odnose). Drugim riječima, parametri odlučivanja služe za definiranje toga koliko je nekom agentu neka varijabla važna prilikom donošenja odluke o idealnoj lokaciji za stanovanje i/ili širenje poslovanja. Varijable odluke odabrane su na način da po svojoj prirodi objedinjuju morfološke i socijalne elemente. Razlog za to je pretpostavka da je funkcionalno- prostorna struktura neodvojivo povezana s promjenama morfoloških i socijalnih elemenata, a samim time i s morfološkom i socijalnom strukturom, ali i to da su morfološka i socijalna struktura uzročno-posljedično povezane s funkcionalnom strukturom pa promjena jedne komponente prostorne strukture utječe na promjenu kompletne strukture. Kako bi se odredile varijable odluke pojedinih agenata korištene u prostornoj optimizaciji gradskih funkcija Grada Rijeke, korištene su slijedeće varijable:

- 1) Nagib padina
- 2) Prosječna cijena nekretnina
- 3) Kakvoća okoliša
- 4) Kompleksnost planiranja
- 5) Dostupnost cestovne mreže
- 6) Grupiranje industrije

Varijable nagib padina i dostupnost cestovne mreže su već ranije objašnjene u dijelu rada vezanom uz CA modele.

3.2.2.1.1. Prosječne cijene nekretnina

Varijabla prosječne cijene nekretnina dobivena je na temelju procijene vrijednosti nekretnine upotrebom troškovne metode. Troškovna metoda je metoda koja se u procjeni cijena nekretnina temelji na izračunavanju troškova gradnje, opremanja i/ili održavanja neke nekretnine (Horvat, 2007).

Prema Horvatu (2007), troškovna metoda u izračunu upotrebljava slijedeće parametre:

- 1) Cijena izgradnje
- 2) Cijena zemljišta
- 3) Starost zgrada

Cijena izgradnje određena na temelju Pokazatelja troškova gradnje (Izvor 4.). Drugim riječima, cijena izgradnje dobivena je ovisno o tome o kojem se objektu radi, kolika je njegova površina i koja je njegova namjena.


S druge strane, cijena zemljišta je određena na temelju Cjenika građevinskog zemljišta Grada Rijeke (Izvor 5). Naime, budući da se nastojala procijeniti vrijednost izgrađenih nekretnina, u razmatranje je uzeta samo vrijednost građevinskog zemljišta jer je jedino na njemu predviđena izgradnja. Cijena izgradnje i cijena zemljišta se zbrajaju i od te cijene se oduzimaju predviđeni troškovi održavanja zbog starosti zgrada. Starost zgrada određena je na temelju tipologije

gradnje prema razdoblju gradnje i energetskim potrebama. Tipologija gradnje prema razdoblju gradnje i energetskim potrebama (Vršek, 2012) razlikuje slijedeće grupacije zgrada:

- 1) zgrade građene prije 1940. godine
- 2) zgrade građene u razdoblju od 1940. do 1970. godine
- 3) zgrade građene u razdoblju od 1970. do 1987. godine
- 4) zgrade građene u razdoblju od 1987. do 2006. godine
- 5) zgrade građene nakon 2006. godine

Prva i druga grupacija zgrada čine zgrade građene prije 1940. i zgrade građene u razdoblju od 1940. do 1970. godine čija su osnovna obilježja veliki intenzitet gradnje tradicionalnim tehnikama i materijalima te nepostojanje toplinske zaštite (Vršek, 2012). Treću grupaciju zgrada čine zgrade građene u razdoblju od 1970. do 1987. godine čija su osnovna obilježja vitke skeletne konstrukcije, poprečni betonski nosivi zidovi te zidne ispune s izrazito slabim toplinskim karakteristikama (Vršek, 2012). Četvrtu grupaciju zgrada čine zgrade građene u razdoblju od 1987. do 2006. godine čija su osnovna obilježja gradnja s dostupnim materijalima i toplinska izolacija upotrebom kamene vune i polistirena (Vršek, 2012). Petu grupaciju čine zgrade građene nakon 2006. godine čija su osnovna obilježja je energetska održivost. Iz tih vrijednosti dobivena je prosječna cijena nekretnina (Sl.9.).

Prosječne vrijednosti cijena nekretnina su reklasificirane na način da su područjima s jeftinijim nekretninama dodijeljene više vrijednosti, a onima s skupljim niže vrijednosti. Tako, na primjer, nekretninama koje su procijenjene na vrijednost manju od 4000 kn/m² je dodijeljena vrijednost 5, a onim nekretninama koje su procijenjene na više od 7000 kn/m² je dodijeljena vrijednost 1. Iz dobivenih rezultata vidljivo je da su najviše cijene nekretnina uz obalu te da udaljšavanje od obale cijena nekretnina pada. Snižavanje cijena od obale prema unutrašnjosti moguće je objasniti padom atraktivnosti geografske lokacije (područje uz more je puno atraktivnije potencijalnim kupcima pa je i njegova cijena veća od cijene područja u unutrašnjosti Grada) te smanjenjem dostupnosti gradskih funkcija (obalni dio Grada ima veću dostupnost gradskih funkcija, čime se smanjuje vrijeme putovanja od mjesta stanovanja do mjesta rada, obrazovanja, odmora i slično pa su zbog toga potencijalni kupci spremni izdvojiti više novca što u konačnici rezultira većom cijenom od one u unutrašnjosti).



Sl. 9. Prosječna cijena nekretnina u Gradu Rijeci

Izvor: Izradio autor prema: Horvat (2007)

3.2.2.1.2. Kakvoća okoliša

Kakvoća okoliša je kompleksna varijabla koja je sastavljena od sljedećih pokazatelja:

- 1) kakvoća zraka
- 2) kakvoća vode,
- 3) prosječna jačina buke
- 4) udaljenost od odlagališta otpada.

Budući da su ti pokazatelji valorizirani višekriterijskim vrednovanjem isto kao i varijable odluke u modelu alokacije, može se reći da je postupak dobivanja varijable kakvoća okoliša zapravo mini verzija prve i druge faze modela alokacije.

Kakvoća zraka klasificirana je na temelju indeksa kvalitete zraka (Prilog 4.), ali budući da u Gradu Rijeci nema vrlo visokog i visokog stupnja onečišćenja, bilo je potrebno napraviti određene korekcije u toj klasifikaciji kako bi se ona mogla primijeniti na analizirano područje. Tako je u ovom slučaju raspon vrijednosti podijeljen u 5 skupina (Prilog 5.). Prvu skupinu čini područja Grada Rijeke na kojima su vrijednosti indeksa manje od 10, u drugoj skupini vrijednosti indeksa se kreću od 10 do 20, u trećoj skupini od 20 do 30, u četvrtoj od 30 do 40, a petu skupinu čine područja s vrijednosti indeksa većom od 40. Vrijednosti su izračunate iz podataka dobivenih na temelju rezultata izmjerenih vrijednost na postajama kvalitete zraka upotrebom metode običnog kriginga (naredba Kriging) u programskom paketu ArcGIS. Dobiveni rezultati izmijenjenog indeksa kvalitete zraka pokazuju da je najveća kvaliteta zraka u sjevernom dijelu, a najmanja u južnom dijelu Grada. Razlog za takvu raspodjelu kakvoće (kvalitete) zraka leži u činjenici da se neki najvećih pojedinačni izvora onečišćujućih tvari nalaze na području južnog dijela Grada ili u njegovoj blizini. Naime, u dokumentu *Nacrt programa zaštite zraka, ozonskog sloja, ublažavanja klimatskih promjena i prilagodbe klimatskim promjenama Grada Rijeke za razdoblje 2018. - 2022.* (Izvor 6) kao glavni onečišćivači navode se 3.Maj brodogradilište, Brodogradilište Viktor Lenac, pogoni tvrtke Energo, Klinički bolnički centar (KBC) Rijeka, Prehrambeno Industrijski Kombinat d.d. Rijeka, INA Rafinerija nafte Rijeka, Termoelektrana Rijeka, MGK-PACK i slični objekti.

Drugi važan kriterij je kakvoća pitke vode. Iako je generalno gledano kakvoća pitke vode u Rijeci zadovoljavajuća, ipak postoje određene razlike u kakvoći između pojedinih dijelova Rijeke. Kakvoća vode dobivena je izračunavanjem prosječnog broja negativno ocijenjenih parametara po uzorku na način da veći prosječan broj parametara po uzorku označava manju kakvoću vode, i obrnuto. Te su vrijednosti dobivene uzorkovanjem izvora pitke vode na širem riječkom području (Prilog 6.) pri čemu se analizom prosječne vrijednosti broja negativno ocijenjenih parametara po uzorku (Prilog 7.) pokazalo da najveća kakvoća vode ima Sveti Kuzam, a najmanju Sušak. Dobivene vrijednosti su reklasificirane na način da su područjima s većom kakvoćom vode dodijeljene veće vrijednosti, a područjima s manje kakvoćom vode manje vrijednosti. Neki od razloga postojanja razlike u kakvoći pitke vode mogu se vezati uz kvalitetu pročišćavanja otpadnih voda, ali budući da su razlike jako male može se zaključiti da je pročišćavanje otpadnih voda na zadovoljavajućoj razini. Također, u kvaliteta pročišćavanja će se dodatno poboljšati realizacijom projekta rekonstrukcije i nadogradnje postojećeg sustava odvodnje te izgradnjom uređaja za pročišćavanje otpadnih voda (UPOV) sa II stupnjem pročišćavanja (biološka obrada) u sklopu kojega se planira izgraditi oko 200 km sustava

odvodnje, dodatnih kišnih preljeva te retencijskih bazena na postojećem mješovitom sustavu odvodnje (Izvor 6).

Uz vodu i zrak, važan faktor kakvoće okoliša je i prosječna jačina buke, koja može upućivati na to u kolikoj mjeri buka onečišćuje okoliš. Fuzijom rastera jačine buke po danu i noći dobivena je jedinstvena karta jačine buke (Prilog 8), koja pokazuje da je onečišćenje bukom najjače uz glavne prometne pravce, dok je na ostatku prostora razina onečišćenja bukom relativno niska.

S druge strane, udaljenost od odlagališta otpada je dobivena na temelju euklidske udaljenosti lokacija odlagališta otpada i ilegalnih deponija (Prilog 9.). Rezultati pokazuju da se odlagališta nalaze na prihvatljivoj udaljenosti od naseljenog područja Grada i daleko od izvora pitke vode.

Nakon analize, navedeni pokazatelji su valorizirani uz pomoć AHP metode. Analitički hijerarhijski proces (engl. *The Analytic Hierarchy Process - AHP*) je metoda višekriterijske analize koja omogućuje donošenje odluka na temelju prethodno određenih prioriteta razmatrajući pritom u jednakoj mjeri i kvalitativne i kvantitativne aspekte odlučivanja (Kegalj, 2015, prema: Nieto-Morote i Ruz-Vila, 2011, Saaty, 1977, 1980).

Drugim riječima, AHP u sebi integrira kvalitativne i kvantitativne elemente za strukturiranje problema odlučivanja kako bi se dobili rezultati koji najbolje odgovaraju definiranim ciljevima, a zbog toga što ima svojstva redundancije AHP metoda je, za razliku od drugih sličnih metoda, manje je osjetljiva na greške koje nastaju kao posljedica pogrešne procjene procijenitelja, te kroz simulaciju odnosa između težinskih vrijednosti elemenata i prioriteta alternativa omogućava kvalitetnu analizu osjetljivosti dobivenih rezultata čime se provjerava njihova stabilnost (Kegalj, 2015).

Na primjeru kakvoće okoliša u Gradu Rijeci, najveće težinske vrijednost su dodijeljene varijabli kakvoća zraka, a najmanje varijabli buka (Tab.1.).

Tab.1. Višekriterijsko vrednovanje kakvoće okoliša u Gradu Rijeci primjenom AHP metode

	Kakvoća zraka	Kakvoća vode	Razina buke	Udaljenost od odlagališta otpada
Kakvoća zraka	1	2	5	4
Kakvoća vode	0,5	1	3	5
Razina buke	0,2	0,33	1	0,33
Udaljenost od odlagališta otpada	0,25	0,2	3	1

Na temelju dobivenih težišnih vrijednosti dobivena je varijabla kakvoće okoliša koja je reklasificirana na način da su više vrijednosti dodijeljene područjima s većom kakvoćom okoliša, a niske obrnuto. Najveću kakvoću okoliša ima sjeverni dio, a najmanju jugozapadni dio Grada. Razlozi takve distribucije kakvoće okoliša vezani su uz razlike u distribuciji vrijednosti analiziranih pokazatelja.

3.2.2.1.3. Kompleksnost planiranja

Kompleksnost planiranja je varijabla koja pokazuje složenost određenog prostora za planiranje i izgradnju. Ta složenost proizlazi iz razine izgrađenost prostora te demografskog pritiska na taj isti prostor. Kompleksnost izgrađenosti je dobivena na temelju tipologije. U izradi tipologije kompleksnosti planiranja korištene su slijedeći pokazatelji:

- a) udaljenost od centra grada
- b) udaljenost od izgrađenog područja

Udaljenost od centra grada (Prilog 10.) je uzet u obzir kao pokazatelj iz razloga što se je na temelju analize funkcionalne strukture, samostalnog terenskog rada i analize plana grada ustanovilo da je najveća gustoća gradskih funkcija u centru grada čime raste atraktivnost prostora što dovodi do povećane potražnje za smještanjem u tom istom prostoru pa taj prostor postaje složeniji za planiranje. Udaljavanjem od centra, smanjuje se potražnja za prostorom čime se smanjuje i složenost planiranja. S druge strane, udaljenost od izgrađenog područja je pokazatelj dostupnosti infrastrukture koja omogućuje stanovništu zadovoljavanje temeljnih potreba (potreba za vodom, hranom, strujom i slično).

Izračunavanje udaljenosti od izgrađenog područja sastoji se od dvije faze:


- 1) Određivanje je li neko područje izgrađeno ili ne
- 2) Određivanje udaljenosti od najbližeg izgrađenog područja

Prva faza (određivanje je li neko područje izgrađeno ili ne) provedena je na temelju podataka dobivenih iz Open Street Map-a. Na osnovi tih podataka izrađena je karta izgrađenosti (Prilog 11.), koja pokazuje da je najviše izgrađenog područja u središnjem dijelu Grada, dok su krajnju istočni dijelovi Grada slabo izgrađeni. Druga faza (određivanje udaljenosti od najbližeg

izgrađenog područja) provedena je na isti način kao i udaljenost od centra grada, dakle upotrebom euklidske udaljenosti (Prilog 12.).

Navedeni pokazatelji su reklasificirani i zbrojeni, a kao rezultat tog zbroja dobivena su četiri tipa kompleksnosti planiranja (Sl. 10.). Prvi tip (Izgrađena područja blizu centra) uključuje izgrađene prostore relativno blizu centra Grada kojima je reklasifikacijom dodijeljena najniža vrijednost (1) zbog toga što ima veliku kompleksnost planiranja. Ta visoka razina kompleksnosti planiranja u središnjem dijelu Grada proizlazi iz historijskogeografskih uvjeta u kojima se to područje razvijalo. Naime, povijest naseljenosti tog područja seže još iz rimskog razdoblja kada se na prostoru zapadno od Rječine (današnji Stari grad) razvilo naselje Trsatika, na čijim je ruševinama izgrađena današnja Rijeke (Dolušić, 2017). Različiti su razlozi zašto se upravo na tom području razvila urbana jezgra Grada, a s geografskog aspekta, kao najčešći razlog tog razvoja, spominje se povoljan prometno-geografski položaj tog dijela Grada.

S druge strane, četvrtom tipu (neizgrađena područja dalje od centra) reklasifikacijom je dodijeljena najviša vrijednost (4) zbog toga što ima malu kompleksnost planiranja koja se javlja kao posljedica slabije stambene izgradnje.




Sl. 10. Tipologija kompleksnosti planiranja u Gradu Rijeci

Izvor: Izvor 12

3.2.2.1.4. Grupiranje industrije

Grupiranje industrije je varijabla koja pokazuje intenzitet klasterizacije industrije na području Grada. Razina aglomeracije je dobivena pomoću ArcGIS upotrebom naredbe Usmjerena udaljenost (naredba Directional Distance) (Sl. 11). Ta naredba izračunava standardnu devijaciju svake točke od prostorne aritmetičke sredine i na temelju nje kreira elipsu distribucije koja obuhvaća točke s najpovoljnijom vrijednošću standardne devijacije. Sukladno tome, vrlo visoka razina aglomeracije industrije sadržava točke s najnižom vrijednošću prve standardne devijacije te predstavlja područje s najvećom koncentracijom industrije. Visoka i srednja razina aglomeracije označavaju točke s najnižom vrijednošću druge i treće standardne devijacije (s izuzetkom onih točaka koje već pripadaju prethodnoj razini) te predstavlja područje s nešto nižom koncentracijom industrije. Niska razina aglomeracije označava područje na kojem gotovo pa nema prisutne koncentracije industrije. Dobivene rezultate moguće je objasniti vremenom nastanka riječke industrije. Naime, veći dio riječke industrije je nastao nakon Drugog svjetskog rata kada je glavni lokacijski faktor za smještaj industrije bili niski transportni troškovi pa su se sukladno tome industrijski pogoni u Gradu Rijeci smještali u blizinu morske luke i željezničke pruge gdje su i dan danas smješteni.



Sl. 11. Grupiranje (razina aglomeracije) industrije u Gradu Rijeci

Izvor: Izvor 12; Izvor 14

3.2.2.2. Faza integracije varijabli upotrebom AHP metode i kreiranje agenata

U ovoj fazi modela alokacije ključnu ulogu ima već spomenuta AHP metoda. Iako, kao samostalna metoda, AHP ima određene nedostatke, dosadašnja istraživanja (Kegalj, 2015; Ligmann-Zielinska, Church i Jankowski, 2005; Zhang, Zeng i Bian, 2010) su pokazala da ukoliko se AHP kombinira s drugim metodama, a naročito s metodama matematičkog programiranja, ona daje vrlo kvalitetne i zadovoljavajuće rezultate. Budući da se prostorna optimizacija u svojoj osnovi temelji na matematičkom programiranju, jasno je da AHP metoda može biti vrlo korisna i u rješavanju određenih zadataka unutar modela alokacije. Glavna uloga AHP-a u modelu alokacije je vrednovanje prethodno navedenih i analiziranih varijabli. S obzirom da su varijable korištene u modelu alokacije slične varijablama korištenima u modelu M-MAGA autora (Zhang, Zeng i Bian, 2010), pri određivanju vrijednosti određenih parametara u modelu alokacije korišteni su isti parametri odlučivanja kao i u modelu M-MAGA, to jest za određivanje parametara odlučivanja korištena je metoda analogije. Sukladno navedenom, određeni su parametri odlučivanja pa je tako provedbom AHP metode dobiveno je 7 tipova agenata koji su na višoj hijerarhijskoj razini podijeljeni u 3 vrste agenata (Tab. 2.).

Tab. 2. Varijable i parametri odlučivanja prema tipovima agenata

Varijable odlučivanja	Parametri odlučivanja po tipovima agenata						
	Stambeni agenti			Industrijski agenti		Poslovni agenti	
	Bogati	Srednje bogati	Siromašni	Ekološki prihvatljivi	Ekološki neprihvatljivi	Krupni	Sitni
Nagib padina	0,113	0,082	0,051	0,124	0,112	0,112	0,135
Prosječna cijena nekretnina	0,149	0,209	0,343	0,225	0,251	0,201	0,261
Kakvoća okoliša	0,315	0,243	0,114	-	-	0,087	0,054
Kompleksnost planiranja	0,180	0,194	0,157	0,129	0,154	0,133	0,096
Dostupnost cestovne mreže	0,243	0,272	0,335	0,286	0,270	0,244	0,299
Grupiranje industrije	-	-	-	0,236	0,213	0,223	0,155

Izvor: modificirao autor prema Zhang, Zeng i Bian, 2010

Te 3 vrste agenata su stambeni agenti, industrijski agenti i poslovni agenti. Stambeni agenti su po tipu podijeljeni na bogate, srednje bogate i siromašne stambene agente, industrijski agenti podijeljeni su na dvije vrste: ekološki prihvatljive industrijske agente ili eko-industrijske agente i stare „prljave“ industrijske agente ili ekološki neprihvatljive agente, a poslovni agenti podijeljeni su na krupne i sitne poslovne agente. Krupni poslovni agenti uključuju velika i srednje velika poduzeća, trgovačke centre, robne kuće, banke i slične prostorne aktere. S druge strane, sitni poslovni agenti uključuju mala poduzeća, lokalne trgovine, obiteljske obrte i slične prostorne aktere. Funkciju podobnosti određena je na temelju ukupnog zbroja vrijednosti

varijabli. Dodjeljivanjem težinskih koeficijenata varijablama i zbrajanjem tih varijabli dobivena je početna pozicija svake vrste aktera. Nakon određivanja početnog položaja za svaku tip kreirano je sedam rastera, po jedan za svaku tip. Budući je pojedinu lokaciju (ćeliju) zauzima više tipova agenata što u stvarnosti nije moguće, zato što u jednoj ćeliji mora biti točno jedna vrijednost, bilo je potrebno objediniti rastere. Kako bi to bilo moguće, u modelu su korišteni određeni operatori genetskih algoritama. Primjenom samo genetskih algoritama dobivanje kvalitetnog rješenja često nije moguće zbog glavnog nedostatka genetskih algoritama, a to je mogućnost zarobljavanja u lokalnom optimumu, to jest česta nemogućnost pronalaženja rješenja koje će biti Pareto optimalno rješenja za cijelu populaciju. Pareto optimalno rješenje je ono rješenja koje postiže vrijednosti Pareto efikasnosti. „Pareto efikasnost podrazumijeva stanje u kojem ne postoji nikakav način da se promjenom proizvodnje ili potrošnje poveća zadovoljstvo jedne osobe, a da to ne ide na štetu druge“ (Izvor 7). U ovom slučaju, Pareto optimalno rješenje bi bili oni agenti koji u svom genetskom kodu imaju obilježja najboljih jedinki (aktera) u populaciji (svi akteri na nekom prostoru) te time predstavljaju najbolje moguće rješenje. Kod genetskih algoritama se može javiti situacija da se bira najbolja jedinka u nekom susjedstvu, ali u usporedbi s cijelom populacijom, ta jedinka ne predstavlja najbolje rješenja, odnosno u drugim susjedstvima je bilo potencijalnih rješenja koja su bila bolja od dobivenog rješenja, ali su u konačnici odbačena zbog toga što je u njihovom susjedstvu postojalo bolje rješenje. Drugim riječima, genetski algoritmi mogu odabrati rješenja koja su prihvatljiva na razini susjedstva, ali ne i na razini cijelog prostora. Upravo taj nedostatak je i razlog zašto se genetski algoritmi često kombiniraju s multi-agentnim sustavima. Naime, multi-agentni sustavi dovode agente u konstantnu interakciju i promjenu položaja čime se postiže veća fleksibilnost genetskih algoritama što u konačnici rezultira Pareto optimalnim rješenjem. U ovom konkretnom slučaju, operatori genetskih algoritama se dodjeljuju populaciji agenata čime agenti dobivaju određena svojstva kako bi bili u stanju odabrati Pareto optimalno rješenje. Operatori genetskih algoritama koji su korišteni u ovoj fazi su evaluacija, selekcija, rekombinacija (križanje) i mutacija. Operator evaluacija mjeri kvalitetu svake jedinke na način da izračunava njezinu pogodnost pomoću funkcije pogodnosti (funkcija dobrote, funkcija sposobnosti, funkcija cilja, engl. fitness function) s tim da veća pogodnost agenta znači i veću vjerojatnost da će taj agent preživjeti i sudjelovati u procesu rekombinacije (Damjanić, 2008), a s druge strane za agente s manjom pogodnošću vrijedi obrnuto. U modelu alokacije evaluacija je napravljena u ArcGIS-u pomoću programske funkcije Slice. Tom su programskom funkcijom vrijednosti dobivene AHP metodom podjednako podijeljene u tri grupe od kojih svaka predstavlja određenu vrstu strategije koju agent zauzima u odnosu na druge agente s

kojim se on "bori" kako bi postigao svoj cilj, odnosno kako bi došao do maksimuma funkcije podobnosti, to jest svoje optimalne lokacije. Sukladno tome, za vrstu agenta korištene su tri vrste strategije, a to su:

- 1) Dominantna
- 2) Slabo dominirana
- 3) Strogo dominirana

Dominantna (nadređena) strategija je vrsta strategije koja, neovisno o izboru strategije drugih agenata, agentu koji ju koristi pruža veće ili jednake mogućnosti za preživljavanje u odnosu na sve ostale agente (Čalija Matijević i Radišić, 2013). Slabo dominirana (slabo podređena) strategija je vrsta strategije koja, neovisno o izboru strategije drugih agenata, agentu koji ju koristi pruža manje ili jednake mogućnosti za preživljavanje u odnosu na sve ostale agente (Čalija Matijević i Radišić, 2013). S druge strane, strogo dominirana (striktno podređena) strategija ima slična obilježja kao i slabo dominirana s tom razlikom da strogo dominirana strategija agentu koji ju koristi pruža strogo manje ili jednake mogućnosti za preživljavanje u odnosu na sve ostale agente (Čalija Matijević i Radišić, 2013). Osim tih strategija, moguće je koristiti i strogo dominantnu (striktno nadređenu) strategiju. Međutim, budući da ta strategija agentima koji ju koriste pruža strogo veće ili jednake mogućnosti za preživljavanje u odnosu na sve ostale agente (Čalija Matijević i Radišić, 2013), ona nije zadana već se do nje nastojalo doći kroz interakcije agenata i miješanje njihovih obilježja. Drugim riječima, strogo dominantnu strategiju usvajaju samo oni agenti čija su obilježja preživjela do krajnje točke evolucije. Ukratko, što je strategija dominantnija to je njezina vrijednost funkcije podobnosti veća čime se povećava vjerojatnost preživljavanja agenata koji koriste tu strategiju. Kako bi se znalo koju strategiju određeni agent koristi, tip agenta je reklasificiran na način da se uz broj koji označava tip agenta dodaje vrijednost 0 (ukoliko se radi o dominantnoj strategiji), 1 (ukoliko se radi o slabo dominiranoj strategiji) ili 2 (ukoliko se radi o strogo dominiranoj strategiji).

Nakon određivanja vrijednosti funkcije podobnosti rasteri su preklapljeni pomoću programske naredbe Combine. Iz dobivenih kombinacija rastera potrebno je bilo odabrati one vrijednosti koje imaju najveću vjerojatnošću za preživljavanje. To je učinjeno pomoću operatora selekcije. Operator selekcije ima ulogu očuvanja i prenošenja pozitivno ocijenjenih svojstava iz aktualne populacije u svaku slijedeću populaciju sve dok jedinke koje imaju negativno ocijenjene značajke ne izumru (Damjanić, 2008). Budući da Combine uzima sve moguće kombinacije

agenata različitih tipova i vrsta strategija ostavljena je mogućnost preživljavanja i onim agentima koji nemaju dominantnu strategiju. Time se zadržava raznolikost populacije i sprječava zarobljavanje u lokalnom optimumu.

Među najpoznatijim selekcijskim mehanizmima, prema Damjanić (2008), ističu se:

- 1) jednostavna selekcija
- 2) turnirska selekcija
- 3) eliminacijska selekcija
- 4) elitizam

Jednostavna selekcija (selekcija roditelja ruletom, engl. *roulette wheel parent selection*) je selekcijski mehanizam koji u svakoj generaciji agenata iz stare populacije stvara u potpunosti novu populaciju (Damjanić, 2008), što u ovoj fazi znači da se originalni agenti iz početnih rastera koji imaju povoljnija obilježja kloniraju, odnosno kopiraju, da bi se zatim originalni agenti odbacili i da bi se umjesto njih u zajedničkom rasteru koristili njihovi klonovi čime je agentima s dominantnom strategijom ostavljena veća vjerojatnost preživljavanja. Poteškoće koje mogu nastati ovim selekcijskim mehanizmom su tehničke i praktične prirode. Problemi tehničke prirode odnose se na moguću pojavu duplikata (dva klon istog agenta) te na potencijalne probleme vezane u loše definiranu funkciju podobnosti. Po pitanju pojave duplikata, Damjanić (2008) navodi da kod jednostavne selekcije ne postoji način provjere koji bi potvrdio ili opovrgnuo da li je neki agent već ranije korišten u selekciji što utječe na to da može doći do pojave velikog broja duplikata čime se, zbog smanjenja genetske raznolikosti, usporava i otežava kompletan proces provedbe algoritma. Problem duplikata u ovom radu je riješen na način da su pomoću operacije Combine svi agenti svrstani u grupe, odnosno kombinacije po zajedničkom lokacijskom svojstvu. Zajedničko lokacijsko svojstvo je prostorno svojstvo kreirano u ovom modelu, a označava da se svi agenti koji na različitim rasterima dijele istu lokaciju vertikalno povezuju stvarajući grupu koja ima određenu kombinaciju tipova agenata. Nakon kreiranja početnih grupa na temelju zajedničkog lokacijskog svojstva, sve grupe koje imaju istu kombinaciju tipova agenata se udružuju u jednu jedinstvenu grupu, a na temelju tih jedinstvenih grupa se vrši jednostavna selekcija čime se smanjuje broj klonova, a time i broj potencijalnih duplikata. Budući da se u ovoj fazi rada radi s malim brojem rastera i njihovih mogućih kombinacija, navedeni postupak daje zadovoljavajuće rezultate. U slučaju velikog broja rastera i njihovih mogućih kombinacija javlja se potreba za uvođenjem posebnog

svojstva prema kojemu je rezultat interakcije dva agenta uvijek isti neovisno o redosljedu kojim su oni selektirani ($A : B = B : A$) pa se kao takav zapisuje samo jednom. S druge strane, problem loše definirane funkcije podobnosti može za posljedicu imati to da svi agenti imaju jednaku vjerojatnosti preživljavanja. Taj je problem već ranije riješen pomoću operatora evaluacije.

Problemi praktične prirode odnose se na to da iako su jednostavnom selekcijom stvoreni uvjeti po kojima veću vjerojatnost preživljavanja imaju agenti s dominantnom strategijom pri čemu nije isključena mogućnost za preživljavanje i onih agenata koji koriste dominirantnu strategiju. U većini ostalih analiza to ne predstavlja problem već poželjno svojstvo jednostavne selekcije jer se njime potiče raznovrsnost. Međutim, budući da je cilj rada u ovoj fazi dobiti što više agenata koji koriste dominantnu strategiju, jednostavna selekcija je poboljšana kombiniranjem s eliminacijskom selekcijom i elitizmom.

Eliminacijska selekcija (engl. *steady-state selection*) predstavlja unaprijeđenje jednostavne selekcije s tom razlikom da jednostavna strategija izabire i prenosi dobre kromosome (agente) u slijedeću populaciju, a eliminacijska selekcija djeluje suprotno, to jest izabire i uklanja loše kromosome (agente) iz populacije da bi se upotrebom genetskih operatora od preostalih agenata populacija ponovno razvila do svoje uobičajene veličine (Damjanić, 2008). Vjerojatnost eliminacije agenata ovisi o vrijednosti funkcije kazne (funkcija suprotna funkciji podobnosti) koju taj agent posjeduje. Točnije, funkcija kazne je zamišljena na način da agenti s dominantnom strategijom imaju niske vrijednosti funkcije kazne što im pruža veću vjerojatnost za preživljavanje. Iako je vjerojatnost eliminacije najboljeg agenta vrlo niska (često jednaka nuli) što često garantira da taj agent neće biti uklonjen iz populacije, stohastičnost čitavog procesa može povisiti tu vjerojatnost i na taj način dovesti u pitanje opstojnost tog agenta što za posljedicu ima nazadovanje populacije kroz nekoliko generacijskih ciklusa (Damjanić, 2008). Kako bi se to riješilo u analizu se ubacuje mehanizam koji štiti najbolje agente od eliminacije i koji omogućuje genetskim algoritmima asimptotsko napredovanje prema globalnom optimumu kroz nekoliko generacija, a taj selekcijski mehanizam je poznat kao elitizam (Damjanić, 2008). Elitizam je proveden na način da su se početne varijable ponovno zbrojile, ali ovog puta bez težišnih vrijednosti kako bi se mogla dobiti ukupna vrijednost funkcije podobnosti. Ukupna vrijednost funkcije podobnosti je potom reklasificirana kako bi se dobila elitistička strategija. Elitistička strategija, u ovom slučaju, predstavlja ukupno najdominantniju strategiju, odnosno, drugim riječima, globalni maksimum funkcije podobnosti. Području s elitističkom strategijom dodijeljena je vrijednost 0, a slabijim strategijama

vrijednosti 1 čime je kreiran novi raster, raster elitističke strategije. Uz to, ponovno je naredbom Combine izvršeno kombiniranje početnih rastera s tom razlikom da je sad tim početnim rasterima pridružen i raster elitističke strategije. Agenti koji se nalaze u području s elitističkom strategijom ostaju za slijedeću generaciju, dok ostali agenti izumiru. Nakon toga ponovno se izvršavaju mehanizmi jednostavne i eliminacijske strategije. Ponovnim izvršavanjem tih selekcijskih mehanizama iz ove faze eliminirana je većina agenata s dominiranim strategijama.

Drugi dio ove faze uključuje rekombinaciju (ukoliko se radi o rekombinaciji samo 2 različita tipa agenata govorimo o križanju) selektiranih agenata. Naime, ako su selekcijom odabrani agenti koji imaju istu vrstu strategije onda se oni međusobno miješaju, a kao posljedica tog miješanja nastaje novi agent koji ima nova, poboljšana obilježja. U teoriji dva su karakteristična oblika rekombinacije, odnosno križanja, a to su križanje s m točkom prekida i uniformno križanje. U slučaju jednostavnih genetskih algoritama, osnovne jedinice na kojima se vrši rekombinacija nazivaju se kromosomi i oni predstavljaju niz binarnih znamenki, a svaka binarna znamenka označava dio genetskog materijala (gen) (Damjanić, 2008). Ukoliko se rekombiniraju 2 kromosoma, mjesto između dva gena na kojima se kromosomi razrežu, zamijene i ponovno spoje kako bi se dobile dvije kompaktne cjeline naziva se m točka prekida, a metoda križanja s tom točkom naziva se križanje s m točkom prekida (Damjanić, 2008). Druga metoda rekombinacije dvaju binarnih kromosoma naziva se uniformno križanje i ta metoda funkcionira na način da se za svaki gen roditelja određuje njegovu vjerojatnost prenošenja u slijedeću generaciju (Damjanić, 2008). Međutim, ako je gen ima složeniju strukturu mijenjenja se i sama metoda uniformnog križanje (Damjanić, 2008).

U modelu alokacije, za razliku od operatora selekcije koji proučava svakog agenta, rekombinacija ne proučava agenta kao cjelinu već ga više zanimaju njegova specifična obilježja. Kao obilježja koja se pri razmatranju uzimaju u obzir su parametar odlučivanja i vrijednosti funkcije podobnosti, dok su ostala obilježja kvalitativna pa ne ulaze u razmatranje. Budući da je funkcija podobnosti u velikoj mjeri ovisna o parametru odlučivanja i da se mijenja s promjenom tog parametra, može se zaključiti da je upravo parametar odlučivanja ključno obilježje koje se razmatra u procesu nasljeđivanja. Vrijednosti parametra odlučivanja novog agenta dobivene na temelju vjerojatnosti nasljeđivanja gena, odnosno obilježja iz prethodne generacije, određene su pomoću Monte Carlo simulacije.

Monte Carlo simulacija je metoda koja se primijenjuje u proučavanje toga na koji se način ponaša model ukoliko mu za ulazne vrijednost odredimo nasumično generirane brojeve (Izvor 8).

Pojednostavljeno rečeno, Monte Carlo simulacija kao ulazne parametre u obzir uzima neku slučajnu vrijednost te vrijednost aritmetičke sredine i standardne devijacije parametara odlučivanja agenata iz prethodne generacije, odnosno parametara odlučivanja agenata koji se rekombiniraju, kako bi kreirala novu vrijednost parametara odlučivanja koja se dodjeljuje novim agentima. Ti novi parametri dobiveni Monte Carlo simulacijom predstavljaju nove težišne vrijednosti kojima se množe varijable odlučivanja čime i ti novi agenti ulaze u ovu fazu modela alokacije te prolaze kroz isti proces kao i njihova roditeljska generacija. Budući da se promjenom parametara odlučivanja promjenila i funkcija podobnosti, kod pojedinih agenata došlo je do naglih promjena u vrsti strategije, odnosno drugim riječima, došlo je do mutacije. Operator mutacije funkcionira na način da svakom obilježju agenta određuje vjerojatnost promjene, odnosno takozvani parametar mutacije (p_m). U ovom radu, kako bi se odredio parametar mutacije, i to ne samo za slijedeće generacije već i za sve njihove potencijalne iteracije, korištena je metoda Markovljevog lanca Monte Carlo simulacije (engl. *Markov Chain Monte Carlo-MCMC*). Markovljev lanac je diskretni slučajni proces gdje vjerojatnost pojave budućih stanja sustava ne ovisi o prethodnim koracima već isključivo o sadašnjem stanju sustava ili o neposredno prethodnom stanju (Jogun, 2016, prema: Guan i dr., 2008, Yang i dr., 2012; Izvor 9). Sukladno tome, Markovljev lanac Monte Carlo simulacije kombinira vjerojatnost promjene parametra odlučivanja koja je dobivena Markovljevim lancima i slučajne promjene na temelju obilježja prethodnih generacija koje su dobivene Monte Carlo simulacijama. Za treniranje Markovljevih lanaca Monte Carlo simulacije i predviđanje potencijalnih mutacija važnu ulogu može imati turnirska selekcija koja slučajnim redoslijedom izvlači jedinke (agente) iz populacije i međusobno uspoređujući njihov parametar mutacije bira one s najvećim parametrom kako bi poslužili u predviđanju kretanja mutacije u budućnosti. Izračunate vjerojatnosti mutacije predstavljaju važne informacije za ovu, ali i za slijedeću fazu modela alokacije. Razlog za to leži u činjenici da ukoliko se želi pronaći optimalna lokacija potrebno je u populaciji imati najbolje, ali i najstabilnije agente što se postiže uklanjanjem mutiranih agenata, odnosno mutanata iz ukupne populacije. Najstabilnija evolucijska strategija po kojoj u populaciji opstaju oni agenti koji kroz generacije uspiju sačuvati čistu strategiju, odnosno, drugim riječima, oni agenti koji ne mijenjaju svoju strategiju pod utjecajem operatora mutacije naziva se evolucijski stabilna strategija. Drugim riječima, evolucijski stabilna strategija je ona vrsta strategije bez mutanata koja dostiže krajnju točku evolucije (Ileković, 2017). Nakon dostizanja krajnje točke evolucije u populaciji ostaju samo oni agenti koji imaju najbolju vrijednost funkcije podobnosti, odnosno najoptimalniju lokaciju agenata. Postizanjem evolucijski stabilne strategije početne generacije agenata završava ovo faza modela alokacije.

3.2.2.3. Faza odabira optimalne početne lokacije za svaku vrstu agenata

Kako bi se odabrala svoju optimalnu početnu lokaciju, svaka vrsta agenata nastoji doći do područja koje za tu vrstu najpogodnije, odnosno, u matematičkom smislu, svaki agent nastoji doći do onog područja (ćelije) koje ima maksimum funkcije podobnosti.

Da bi ostvario svoja nastojanja, svaki agent mora proći kroz niz promjena u kojima će se iz ukupnog broja agenata izgenerirati oni agenti koji imaju najbolja obilježja u populaciji. Te promjene provedene su pomoću standardnih operatora genetskih algoritama, kao što su evaluacija, selekcija, rekombinacija i mutacija, koji su već korišteni i objašnjeni u prethodnoj fazi, ali i pomoću dodatnih operatora kao što su susjedno natjecanje, izumiranje i samoučenje koji su kreirani kombiniranjem tih standardnih operatora. Ti će operatori biti objašnjeni redosljedom kojim se pojavljuju u modelu. Tijek ove faze modela prikazan je dijagramom toka (Prilog 13.).

Sukladno dijagramu toka, prvi korak je iz početnih agenata odabrati one najbolje, odnosno pronaći one agente koji imaju najpogodnija obilježja za prijenos na slijedeće generacije i odrediti vrijednosti njihove funkcije podobnosti. Budući da je svaka generacija u modelu ima neku vrijednost t koja označava koja je to generacija po redu, vrijednost t za početnu generaciju iznosi 0 jer to upućuje da je to prva prava generacija koja je nastala iz početnih parametara odlučivanja. Kako se parametri odlučivanja sve više mijenjaju (kao posljedica rekombinacije dvaju ili više različitih tipova agenata s istom vrstom strategije), nastaju novije i novije generacije, a time raste i vrijednost t . S druge strane, kako bi se lakše interpretirala, funkciji podobnosti je dodijeljena oznaka $f(t)$. U drugom koraku proveden je operator migracije. Operator migracije funkcionira po principu da kreira raster slučajnih vrijednosti i izvršava reklasifikaciju nad njime, zatim se upotrebom eliminacijske selekcije iz populacije tog rastera uklanjaju ćelije koje su zauzete od strane drugih agenata i one koje imaju nisku vrijednost funkcije podobnosti, a preostale ćelije koje su preživjele eliminacijsku selekciju pridružuju se ranije odabranim agentima. Tim migrantima (agenti koji su dobiveni operatorom mutacije) je izračunata funkcija podobnosti te je određena evolucijska strategija ovisno o tome koji je tip agenta. Upotrebom operatora migracije čuva se raznolikost populacije i olakšava daljnje računanje. Slijedeći korak odnosi se na uvođenje još jednog novog operatora, operatora susjednog natjecanja. Operator susjednog natjecanja ima cilj potaknuti natjecateljsko ponašanje agenata. Natjecateljsko ponašanje agenata uključuje unutarnju konkurenciju i vanjsku konkurenciju unutar susjedstva na način da između agenata istog tipa dolazi do unutarnje

konkurencije, dok kod agenata različitih tipova dolazi do vanjske konkurencije (Zhang, Zeng i Bian, 2010). Drugim riječima, pojedine vrste agenata se prvo suočavaju s tipovima agenata iste vrste, a zatim se pobjednici tih sučeljavanja natječu s agentima drugih vrsta. Kako bi se natjecateljsko ponašanje agenata najbolje realiziralo korišteni su filteri za izražavanje najčešće (Majority) i najrjeđe (Minority) vrijednosti susjedstva koji su dobiveni pomoću naredbe Focal Statistics u ArcGIS-u. Filter najčešće vrijednosti služi za izračunavanje one vrijednosti ćelije koja se najviše puta pojavljuje u susjedstvu, dok s druge strane, filter najrjeđe vrijednosti ima suprotni efekt, to jest on služi za izračunavanje onih vrijednosti ćelija koje su najmanje zastupljene u susjedstvu. Ti se filteri koriste kako bi se dobila 2 rastera. Prvi raster (dobiven filterom najčešće vrijednosti) čine oni tipovi agenata koji se najčešće pojavljuju unutar susjedstva. Nakon provedbe navedenih filtera dobiveni agenti su rekombinirani naredbom Combine kako bi se ponovno kreirao jedinstveni raster koji sadrži agente s poboljšanim vrijednostima funkcije podobnosti. Poslije provedbe susjednog natjecanja i ponovnog izračunavanja funkcije podobnosti preostalih agenata, u slijedećim koracima provedene su operacije rekombinacije i mutacije. Provedbom mutacije promjenila su se obilježja, a time i sama strategija agenata što je dovelo do povećanja raznovrsnosti te smanjenja broja agenata s izvornom (čistom) strategijom. Kako bi došlo do evolucijski stabilne strategije, selekcijom se agenti razdvajaju na dvije skupine, mutante i ne-mutante. Skupina mutanata usmjerava se prema operatoru izumiranja, a skupina ne-mutanata se usmjerava prema operatoru samoučenja. Operator izumiranja iz populacije uklanja skupinu mutanata kako bi se postigla stabilnost populacije. S druge strane, budući da u njoj nema mutanata i kao takva predstavlja idealnu populaciju, na skupini ne-mutanata se primjenjuje operator samoučenja koji u sebi povezuje sve dosadašnje operatore i djeluje kao mini verzija modela alokacije. Operator samoučenja provodi se korištenjem umjetnih neuronskih mreža pomoću ekstenzije FLUKS programskog paketa GeoSOS. Nakon provedenog samoučenja, izračunava se funkcija podobnosti agenata samoučenja te se ta vrijednost uspoređuje s vrijednošću funkcije podobnosti agenata iz skupine ne-mutanata dobivenima prije provedbe samoučenja. Iz agenata koji u usporedbi imaju veću podobnost izračunava se ukupna funkcija podobnosti (zbroj vrijednosti funkcija podobnosti svih preživjelih tipova agenata). Ukoliko se novoizračunata ukupna funkcija podobnosti razlikuje od ukupne funkcije podobnosti odabranih agenata s početka faze, model se vraća na početak treće faze i izvršava novu iteraciju sve dok se rezultati tih dviju vrijednosti funkcije podobnosti ne izjednače. Kada se ukupne vrijednosti funkcije podobnosti izjednače završava treća faza i dobivaju se optimalne lokacije.

3.2.2.4. Udaljenost agenata od optimalnih lokacija

Nakon pronalaska optimalne lokacije agenata, u ovoj je fazi potrebno izračunati dostupnost tih lokacija. Dostupnost optimalnih lokacija agenata je izračunata na sličan način kao i varijabla dostupnost cestovne mreže, to jest u prvom koraku je izračunata udaljenost od optimalne lokacije koja je potom u drugom koraku reklasificirana pa je zatim korištena kao parametar za izračunavanje dostupnosti prema već navedenoj formuli. Za izračunavanje euklidske udaljenosti je, kao i ranije u radu, korištena naredba Euclidean Distance. Izračunom dostupnost optimalnih lokacija završava ova faza.

3.2.2.5. Faza određivanja „barijera“

U ovoj fazi rada kreirane su „barijere“. „Barijere“ su područja koja predstavljaju određenu prepreku kretanju mrava. Drugim riječima, „barijera“ označava neku vrstu negativnog tranzicijskog potencijala koja do određene mjere usmjerava i/ili usporava kretanje mrava. U kontekstu modela alokacije, „barijere“ su područja visokih troškova prenamjene i niske okolišne prihvatljivosti koja imaju vrlo lošu dostupnost do optimalne lokacije. Vrijednosti „barijera“ su dobivene kada se reklasificirane vrijednosti dostupnosti optimalnih lokacija zbroje s reklasificiranim vrijednostima troškova prenamjene objekata jedne gradske funkcije u objekte s drugom gradskom funkcijom i reklasificiranim vrijednostima okolišne prihvatljivosti promjene jedne vrste funkcionalne zone u drugu.

Troškovi prenamjene (Tab. 3.) služe kako bi se ispunile vrijednosti funkcije cilja minimizacije financijskih troškova. Troškovi prenamjene predstavljeni su standardnim vrijednostima koje označavaju udio troškova prenamjene objekata iz jedne funkcionalne zone u drugu.

Tab. 3. Standardne vrijednosti troškova prenamjene funkcionalnih zona

	Industrijske zone	Restriktivne zone	Poslovne zone
Industrijske zone	-	0,20	0,20
Restriktivne zone	0,90	-	0,90
Poslovne zone	0,45	0,45	-
Neodređene zone	1,80	1,80	1,80

Izvor: modificirao autor prema Zhang, Zeng i Bian, 2010

Najpovoljnije zone za prenamjenu su industrijske zone (20% prosječne cijene prenamjene), zatim poslovne (45% prosječne cijene prenamjene), potom stambene (90% prosječne cijene prenamjene), a najnepovoljnije su neodređene zone (80% više od prosječne cijene prenamjene).

Ti udjeli su reklasificirani na način da su više vrijednosti dodijeljen zonama koje imaju visoke vrijednosti troškova prenamjene, a niske obrnuto.

Okolišna prihvatljivost (Tab. 4.) služe kako bi se ispunile vrijednosti funkcije cilja maksimizacija urbane održivosti. Okolišna prihvatljivost predstavljena je matricom ekološke kompatibilnost promjene iz jedne zone u drugu na način da matrica računa ekološku kompatibilnost na dimenzijama susjedstva 3x3, dok se vrijednosti u matrici kreću od 0.0 do 1.0 pri čemu vrijednost 0.0 označava ekološku nekompatibilnost, a kako vrijednosti rastu tako se poboljšava i ekološka kompatibilnost (Zhang, Zeng i Bian, 2010).

Tab. 4. Okolišna prihvatljivost prenamjene funkcionalnih zona

	Neodređena zona	Ograničena zona	Stambena zona	Poslovna zona	Industrijska zona
Neodređena zona	1	1	1	1	1
Ograničena zona	1	1	1	0,5	0
Stambena zona	1	1	1	0,7	0
Poslovna zona	1	0,5	0,7	1	0,2
Industrijska zona	1	0	0	0,2	1

Izvor: modificirao autor prema Zhang, Zeng i Bian, 2010

Ti udjeli su reklasificirani na način da su više vrijednosti dodijeljene zonama koje imaju nižu ekološku kompatibilnost, a niske obrnuto.

3.2.2.6. Faza optimizacije kolonijom mrava

U ovoj fazi korištena je optimizacija kolonijom mrava koja je dobivena naredbom „Optimizacija područja“ (eng. *Area Optimization*) u programskom paketu GeoSOS. Optimizacija kolonijom mrava (eng. *ACO – Ant Colony Optimization*) je oblik kombinatorne optimizacije koja se sastoji od dva interaktivna koraka, a to su korak izgradnje rješenja te korak ažuriranja feromona (Lojen, 2016, prema: Talbi, 2009). Korak izgradnje rješenja odnosi se na sposobnost umjetnih mrava da kreira rješenja dodavanjem dodatnih svojstava u obliku feromonskog traga kojima se analiziraju dobro generirana rješenja, pamti njihova obilježja te na temelju toga izgrađuje nova i poboljšana rješenja (Lojen, 2016, prema: Talbi, 2009). Budući da se feromonski trag tijekom optimizacijskog procesa dinamički mijenja, dolazi do potrebe za njegovom ažuriranju koje se radi u dvije faze (faza isparavanja i faza ojačavanja) korištenjem već generiranih rješenja (Lojen, 2016, prema: Talbi, 2009). U fazi isparavanja automatski se snižava razina feromona čime se sprječava prijevremeno pronalaženje dobrih rješenja i

poticanje traženja raznovrsnih rješenja u određenom prostoru istraživanja, dok s druge strane, u fazi ojačavanja dolazi do ažuriranja feromonskog traga koje se vrši na tri različita načina (online korak po korak, online odgođeno i offline ažuriranje feromona) i u skladu s već generiranim rješenjima (Lojen, 2016, prema: Talbi, 2009). Optimizacija kolonijom mrava primijenjuje se za rješavanje NP-teških problema, odnosno optimizacijskih problema koji u polinomijalnom vremenu ne mogu dati egzaktno rješenje (Marković, 2006; Vresk, 2004). Drugim riječima, optimizacija kolonijom mrava se koristi pri rješavanju problema koji ne mogu dati precizno rješenje u kratkom vremenu. Jedan od takvih problema je i problem trgovačkog putnika. Problem trgovačkog putnika je optimizacijski problem izbora najkraćeg puta na grafu pri čemu se svaka lokacija obilazi samo jednom (Jakovčić, 2016; Marković, 2006). U modelu alokacije, optimizacija kolonijom mrava je korištena kako bi se prostorno-vremenski povezali agenti s najvišom vrijednošću funkcije podobnosti. Naime, na putu do optimalne lokacije s najvećom vrijednosti funkcije podobnosti agenti su se kroz generacije pomicali od ćelije do ćelije ostavljajući za sobom trag svojih kretanja. Slijedeći taj trag, umjetni mravi će nastojati pronaći najkraći put od optimalne lokacije jedne generacije do optimalne lokacije druge generacije. Također, u nastojanju da optimizaciju ostvari zacrtane ciljeve u radu se koriste već spomenute „barijere“ koje usmjeravaju kretanja agenata određenim tokom, što je u ovom slučaju prema području najnižih financijskih troškova i najveće ekološke koristi. Primjena „barijera“ je nužna kako bi došlo do optimalne funkcionalno-prostorne strukture koja bi u budućnosti predstavljala osnovu za dostizanje prostornog sklada te daljnjeg lokalnog i regionalnog razvoja. Uz to, „barijere“ su korisne i zbog toga što dovode do raznovrsnosti funkcionalnih zona. Naime, bez upotrebe „barijera“ bi svi agenti bili direktno usmjereni na neodređene zone čime bi se proširila, ali ne i poboljšala aktualna funkcionalno-prostorna struktura. Drugim riječima, mravi koji slijede trag agenata s dominantnom strategijom će lakše prijeći preko „barijere“ nastojeći doći do željenog cilja, to jest do optimalne lokacije. Razlog za to leži u činjenici da su agenti s dominantnom strategijom zbog visoke vrijednosti funkcije podobnosti češće preživljavali i prenosili svoja obilježja čime su njihovi tragovi prostornog pomaka kroz generacije puno jasniji od tragova ostalih agenata. S druge strane, mravi koji slijede trag agenata s dominirajuću strategiju imaju veći broj potencijalnih ruta, ali slabije tragove zbog čega često mijenjaju rute u potrazi za onom najkraćom, što drastično povećava njihov put do optimalne lokacije. Također, ukoliko se takvi mravi nađu pred „barijerom“ oni će zbog slabih tragova morati tražiti alternativni put kojim će zaobići „barijeru“, umjesto da jednostavno prijeđu preko. Ukoliko je neka „barijera“ previsoka, na primjer ako neka zona ima preveliku cijenu prenamjene ili je ekološki nekompatibilna za transformacije, mravi neće prijeći

preko nje već će tražiti drugu najpovoljniju rutu, odnosno proći će onim ćelijama (bez obzira u kojoj se funkcionalnoj zoni ta ćelija nalazi) koje imaju najjasnije izražene tragove prostornog pomaka kroz generacije. Time se dobiva lančani efekt kreiranja novih ruta što rezultira uključivanjem većeg broja ćelija u proces prostorne optimizacije, što dovodi do kvalitetnijih rješenja koja bolje zadovoljavaju već navedene ciljeve.

Optimizacije počinje određivanjem početnih parametara alfa, beta i ro. Vrijednost parametra alfa naglašava važnost pohlepne sile, vrijednost parametra beta označava važnost feromona, a vrijednost parametra ro ističe vrijednost faze isparavanja feromona. Parametar alfa je određen s vrijednošću 1, a parametar beta je određen s vrijednošću 3, što označava da je u analizi veća važnost posvećena feromonu. To potvrđuje i vrijednost parametra ro koja iznosi 0.90 što znači da je u optimizaciji pojačano isparavanje čime se potiče raznovrsnost rješenja. Konstanta (Q) je određena vrijednošću 10 koja označava broj optimalnih lokacija kroz koji mravi prolaze u toku optimizacije. Broj mrava određen je na način da se ukupan zbroj površina funkcionalnih zona podijeljen s površinom jedne ćelije.

Optimizacija se izvršava dok se ne ostvari kriterij zaustavljanja, a to može biti određeni broj iteracija koje je potrebno izvršiti, određeni vremenski period za koji se provodi optimizacija, određeni broj rješenja koji se nastoji pronaći i slično. U slučaju ove faze modela alokacije, kriterij zaustavljanja stupa na snagu nakon 1000 iteracija kada je procijenjeno da će i posljednji od ukupnog broja zadanih mrava doći do optimalne lokacije svake od zadanih godina.

3.2.2.7. Faza alokacije funkcionalnih zona

U konačnoj fazi modela analizirani su rezultati dobiveni kolonijom mrava. Pomicanjem mrava, najveća količina feromona dobivena je na istočnom dijelu grada (Orehovica, Pašac, Draga), na području Sušaka, Trsata i Srdoča te na obalnom području gdje se trenutno nalaze industrijska postrojenja. Time su ujedno ta područja označena kao područja s najvećom vjerojatnošću za promjenu tipa funkcionalne zone.

Na tim područjima je na mjesto dotadašnjeg tipa zone alocirani objekti onog tipa funkcionalne zone čiji su agenti u ćelijama na tom području ostavili najjasniji trag, odnosno oni agenti čiji je trag slijedila većina mrava iz kolonije. Time su dobiveni rezultati optimalne funkcionalno-prostorne strukture koja može poslužiti kao svojevrsni planerski „memento“ koji usmjerava prostorne planere prema kvalitetnijem planiranju i upravljanju funkcionalno-prostornom, a u konačnici i kompletnom prostornom strukturom Grada Rijeke. Nakon izvršene prostorne

optimizacije dobiveno je stanje funkcionalnih zona do 2030. godine. Kako bi se ustanovilo buduće stanje funkcionalnih zona u razdoblju nakon optimizacije izrađena je i simulacija optimizirane funkcionalno-prostorne strukture 2050. godine.

3.3. Ostale metode

U ostale metode ubrajaju se terenski rad, metoda deskripcije, statističke analize, metoda procjene, metoda scenarija te analiza literature i izvora. Također, u metode može se ubrojiti i krajobrazna metrika koja u ovom radu zapravo predstavlja statističku analiza fragmenata funkcionalnih zona. Fragmenti su objekti koji pripadaju jednoj vrsti funkcionalnih zona, a sa svih strana su okruženi objektima drugih zona. Za istraživanje kompaktnosti i raznolikosti funkcionalnih zona pomoću krajobrazne metrike korišten je programski dodatak LecoS koji se koristi u QGIS-u. LecoS omogućuje izračunavanje kompaktnosti i raznolikosti upotrebom globalnih i lokalnih pokazatelja povezanosti.

Globalni pokazatelji su:

- a) Shannonov indeks raznolikosti (engl. *Shannon Diversity Index* - SHDI)
- b) Shannonov indeks jednakosti (engl. *Shannon Evenness Index* - SHEI)
- c) Simpsonov indeks raznolikosti (engl. *Simpson Diversity Index* - SIDI)

Shannonov indeks raznolikosti prikazuje udio fragmenata svake vrste funkcionalne zone pomnožen s udjelom te vrste u ukupnoj funkcionalno-prostornoj strukturi s time da vrijednost 0 znači da nema raznolikosti, a što vrijednost indeksa sve više raste funkcionalno-prostorna struktura postaje sve raznovrsnija (Chelaru, Oiste i Mihai, 2014). Shannonov indeks jednakosti prikazuje raspodjelu fragmenata pojedinih vrsta funkcionalnih zona unutar ukupne površine funkcionalno-prostorne strukture (Chelaru, Oiste i Mihai, 2014). Ukoliko Shannonov indeks jednakosti iznosi 0 kada funkcionalno-prostorna struktura sadrži samo jedan fragment (bez raznolikosti), dok s druge strane, ako vrijednost Shannonovog indeksa jednakosti iznosi 1 tada je raspodjela površina funkcionalnih zona ujednačena (Chelaru, Oiste i Mihai, 2014). Ukratko, ako se vrijednosti indeksa približava 0 tada distribucija različitih fragmenata postaje sve više neujednačena (Chelaru, Oiste i Mihai, 2014). S druge strane, Simpsonov indeks raznolikosti označava vjerojatnost da će dva slučajno odabrana objekta pripadaju različitim funkcionalnim zonama (Chelaru, Oiste i Mihai, 2014). Što je vrijednost Simpsonovog indeksa veća, to je veća i razlikost funkcionalnih zona.

Deljniji uvid u kompaktnost i raznovrsnost funkcionalno-prostorne strukture moguće je dobiti na temelju lokalnih pokazatelja (Prilog 14.), koji se za razliku od globalnih pokazatelja ne primjenjuju na cijelinu nego individualno na svaku vrstu funkcionalnih zona (Chelaru, Oiste i Mihai, 2014).

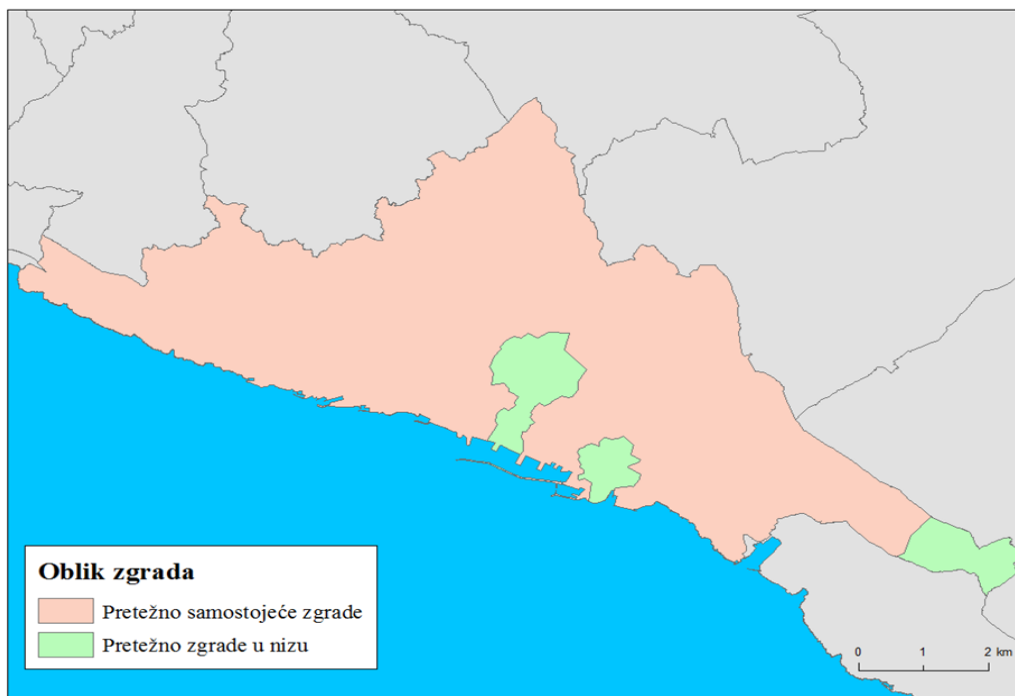
4. PROSTORNA STRUKTURA GRADA RIJEKE

Prostorna struktura Grada Rijeke se, kao i svaka druga prostorna struktura, sastoji se od tri bitne podstrukture, a to su:

- 1) morfološka struktura
- 2) funkcionalno-prostorna struktura
- 3) socijalno-prostorne struktura

4.1. Morfološka struktura

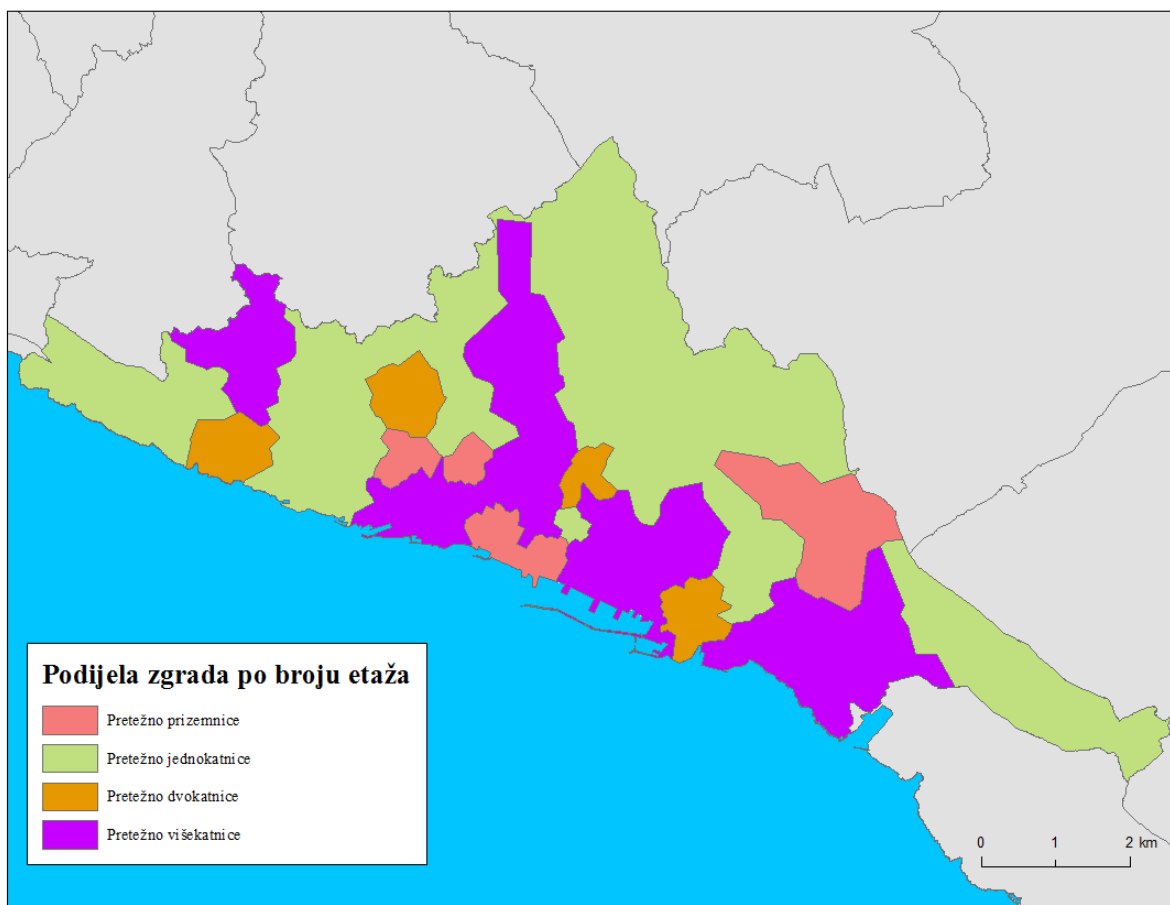
Morfološka struktura predstavlja prostorni raspored morfoloških elemenata i njihov međusobni odnos u gradskom prostoru, a to uključuju zgrade i blokove zgrada, trgove, zemljišne čestice, ulice, javne površine i slične objekte. Morfološka struktura može se odrediti na temelju oblika zgrada, broja etaža zgrada i starosti zgrada. Prema obliku zgrada, zgrade dijelimo na samostojeće zgrade i zgrade u nizu (Sl. 11.). Samostojeće zgrade prevladavaju u većem dijelu Grada s izuzetkom krajnjeg južnog dijela (Sveti Kuzam) te dijelova užeg i šireg centra Grada.



Sl. 11. Podijela zgrada u Gradu Rijeci prema obliku gradnje

Izvor: Samostalni terenski rad; Izvor 14

S druge strane, prema broju etaža zgrade u Gradu Rijeci se dijele na prizemnice, jednokatnice, dvokatnice i višekatnice (Sl. 12.). Središnji dio ima najveću raznovrsnost zgrada prema broju etaža što se može objasniti time da se to područje postepeno širilo i razvijalo kroz više vremenskih etapa nastojeći se prilagoditi snažnom demografskom pritisku na taj prostor. Naime, zbog velikog broja stanovnika i ograničenog područja za širenje, morfološka struktura se morala prilagoditi tim uvjetima na način da se počela razvijati u visinu. U ostalim dijelovima Grada, visina zgrada se je morala prilagođavati postojećim geomorfološkim uvjetima (prvenstveno nagibu padina) koji određuju dimenzije zgrada na način da se zbog negativnih svojstava reljefa često smanjuju prostor namijenjen za daljnje potencijalno širenje Grada.

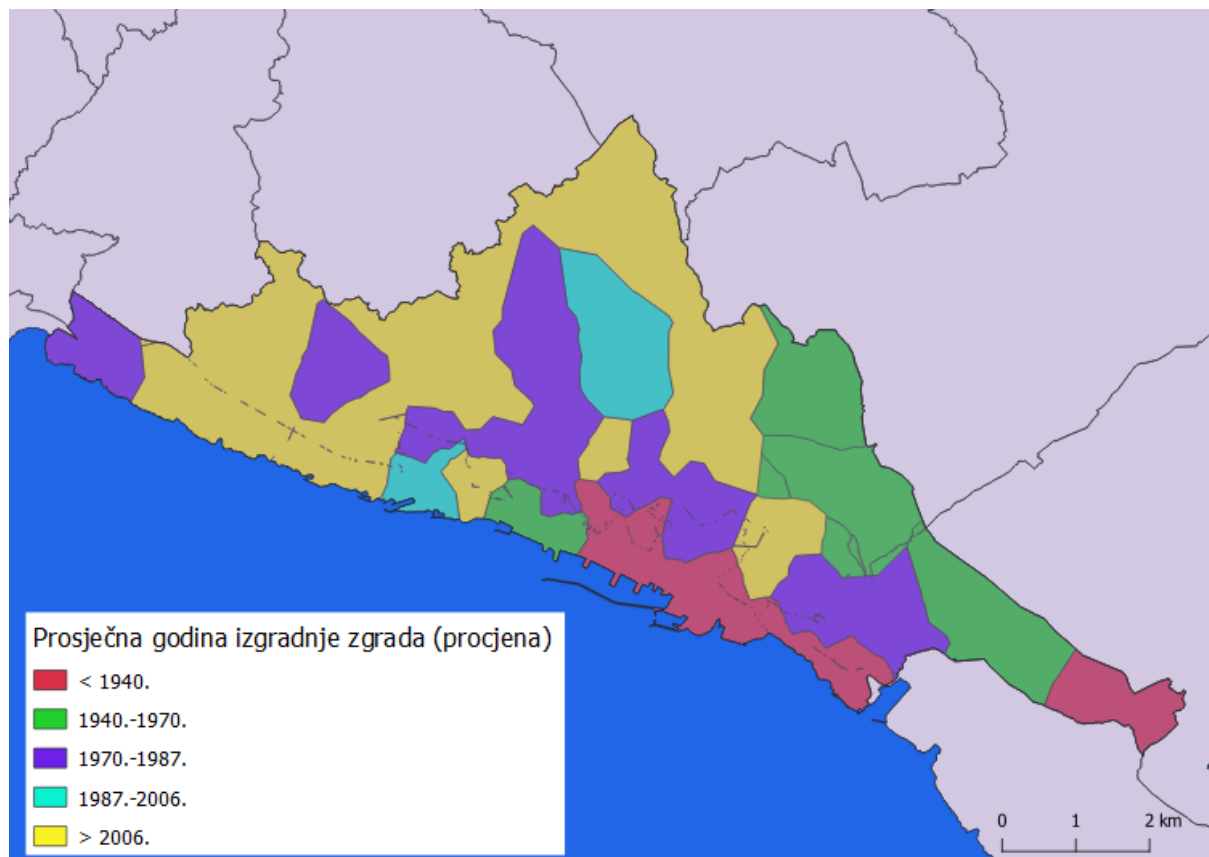


Sl. 12. Podijela zgrada u Gradu Rijeci po broju etaža

Izvor: Samostalni terenski rad; Izvor 14

U morfološkoj strukturi posebno značenje ima starost zgrada. Naime, na temelju starosti zgrada moguće je uočiti intenzitet i smjer urbanizacije kroz prošlost što može poslužiti kao korisna informacija za potencijalno širenje urbanih površina u budućnosti, a samim i za prostorno planiranje nekog urbanog područja. Prema starosti koristimo već navedenu tipologiju pa

razlikujemo zgrade prije 1940, zgrade između 1940. i 1970., zgrade između 1970. i 1987., zgrade između 1987. i 2006. te zgrade nakon 2006. godine (Sl. 13.).



Sl. 13. Podijela zgrada u Gradu Rijeci po starosti

Izvor: Samostalni terenski rad; Izvor 14

U prvu i drugu kategoriju spadaju područja južnog te središnjeg dijela Grada. Ti dijelovi predstavljaju dva odvojena naselja (Rijeka i Sveti Kuzam) koja čine osnovu današnjeg Grada Rijeke. Treću kategoriju čine područja zapadnog dijela i šireg centra Grada koji predstavljaju slijedeću etapu razvoja morfološke strukture u kojoj se ta dva naselja polako međusobno povezuju. S druge strane, u četvrtu i petu kategoriju spadaju područja sjevernog dijela Grada što upućuje na trendove širenja morfološke strukture Grada prema sjeveru koji u nešto manjoj mjeri vrijede i danas.

4.2. Funkcionalno-prostorna struktura

Funkcionalno-prostorna struktura grada određena je prostornim rasporedom gradskih funkcija. Te gradske funkcije mogu se razmatrati u cijelini, ali i kao samostalni prostorni sustavi unutar grada (Vresk, 2002).

Kao gradske funkcije u brojnoj se literaturi navode:

- 1) funkcija stanovanja
- 2) funkcija rada
- 3) funkcija odmora
- 4) funkcija opskrbe
- 5) funkcija obrazovanja
- 6) funkcija prometa i komunikacije

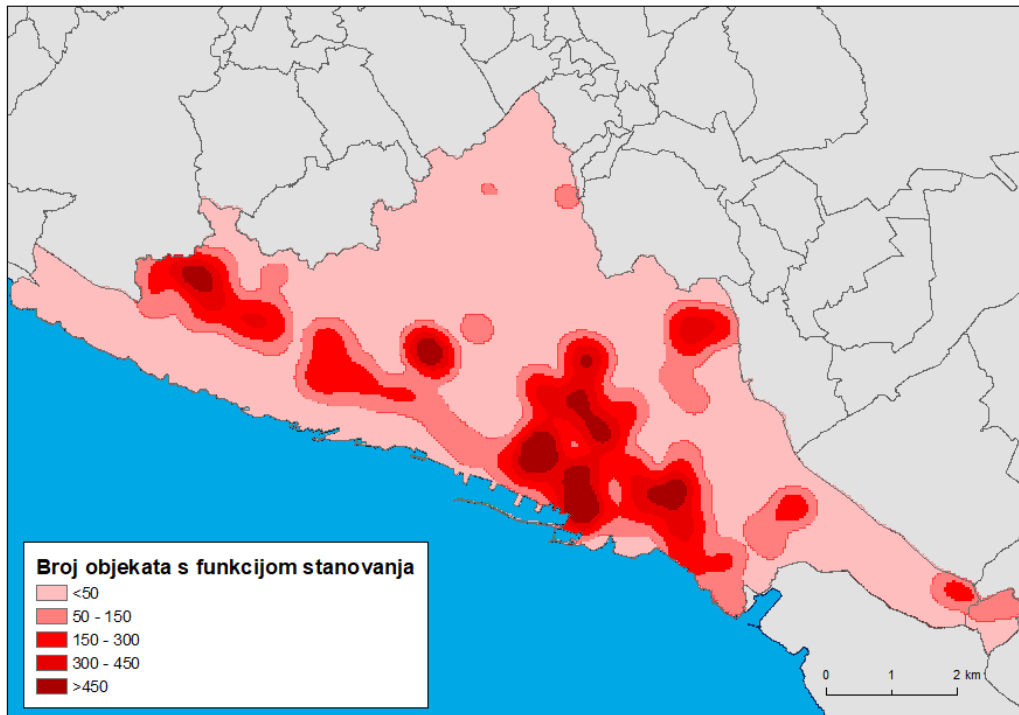
U kontekstu Grada Rijeke, zbog morfološke povezanosti, iste gradske funkcije koje su razmatrane na području grada Rijeke, razmatrane su i na području Svetog Kuzma.

4.2.1. Funkcija stanovanja

Objekti s funkcijom stanovanja dijele se na kuće i stambene zgrade. Kuće dominiraju na jugoistočnom dijelu grada (Orehovica, Draga, Sveti Kuzam) u kojem se nalazi manji broj stanovnika i kojeg krase manja gustoća naseljenosti, dok s druge strane, stanovi dominiraju u središnjem dijelu grada gdje je prisutna najveća raznovrsnost i najgušća izgrađenost objekata s funkcijom stanovanja (Prilog 15.).

To potvrđuje i gustoća funkcije stanovanja čije se vrijednosti kreću od manje od 50 objekata u područjima sa slabom koncentracijom do više od 450 objekata u područjima s jakom koncentracijom objekata te vrste (Sl.14).

Najveća koncentracija objekata s funkcijom stanovanja nalazi se na području od sjeverozapadnog do središnjeg dijela Grada, dok slabiju koncentraciju objekata s funkcijom stanovanja imaju rubni dijelovi Grada. Takva koncentracija objekata upućuje na izrazitu polarizaciju funkcije stanovanja koja se grupira oko dva glavna centra, a to su Srdoči na sjeveru i Sušak na jugu. Također, između ta dva postoji još jedan pol, a to je Škurinje.



Sl. 14. Gustoća funkcije stanovanja u Gradu Rijeci


Izvor: Izvor 12; Izvor 14

4.2.2. Funkcija rada

Objekti s funkcijom rada na području Grada Rijeke mogu se podijeliti na poslovne i industrijske objekte. U poslovne objekte se ubrajaju svi oni objekti koji služe za obavljanje uslužnih djelatnosti, dok u industrijske objekte ubrajamo industrijske objekte u užem smislu (služe za isključivo industrijsku proizvodnju) i industrijske objekte u širem smislu (osim za industrijsku proizvodnju mogu služiti i za obavljanje drugih proizvodnih djelatnosti (npr. skladišta, radionice i slično)). Kako što se može zaključiti iz već ranije izračunate varijable Grupiranje industrije, većina industrijskih objekata je smještena uz obalni dio središta grada. S druge strane, i kod poslovnih objekata također se može zamijetiti tendencija za smještanjem u užem centru grada gdje su većim dijelom smješteni manji poslovni objekti. Također, tu je smještena i Robna kuća, dok su ostali njoj slični objekti (Zapadni trgovački centar i Tower centar) smješteni u širem centru.

Detaljnije informacije o lokaciji i koncentraciji objekata s funkcijom rada moguće je dobiti na temelju gustoće funkcije rada (Sl. 15.) koja se kreće od manje od 10 objekata u područjima sa slabom koncentracijom do više od 40 objekata u područjima s jakom koncentracijom objekata

te vrste. Budući da su vrijednosti gustoće vrlo niske, to upućuje da ima malen broj objekata te funkcije, ali i na to da su ti objekti slabo rašireni u prostoru što dodatno potvrđuje visoku razinu centraliteta funkcije rada.



Sl. 15. Gustoća funkcije rada u Gradu Rijeci

Izvor: Izvor 12; Izvor 14


Naime, veliku koncentraciju objekata s funkcijom rada imaju područja uz obalu, dok unutrašnji dio Grada imaju nešto slabiju koncentraciju što će u budućnosti rezultirati još većim socioekonomskim razlikama.

4.2.3. Funkcija opskrbe

Objekti s funkcijom opskrbe na području Rijeke mogu se podijeliti na objekte vodoopskrbe, elektroopskrbe i plinoopskrbe. Također, ti isti objekti mogu se razmotriti na makro i mikro razini. S makro razine (Prilog 16.), proučavaju se oni objekti koji predstavljaju centralnu funkciju za područje geografske regije Sjeverno hrvatsko primorje, ali i pravce energetske infrastrukture od državnog značenja. Drugim riječima, tu razinu čine oni objekti, odnosno vodovi, koji opskrbljuju ne samo Grad Rijeku već i puno šire područje u daljnjoj i bližoj okolici Grada.

S mikro razine, proučavaju se oni objekti koji služe pretežno za opskrbu samog Grada, to jest infrastrukturni vodovi lokalne razine. Mikro razina djelomično uključuje i neke objekte koji su važni i za makro razinu iz razloga što je kod tih objekata teško povući jasnu granicu kojoj razini pripadaju budući da su oni i za mikro razinu jednako važni kao i za makro razinu.

Gustoća funkcije opskrbe (Sl. 15.) pokazuje da broj objekata te funkcije varira između manje od 150 objekata/km² u područjima sa slabom koncentracijom funkcije i više od 60 objekata/km² u područjima s velikom koncentracijom funkcije.



Sl. 15. Gustoća funkcije opskrbe u Gradu Rijeci

Izvor: Izvor 12; Izvor 14


Svi mjesni odbori pokazuju veliku koncentraciju objekata s funkcijom opskrbe, s tim da najveću koncentraciju pokazuju oni mjesni odbori koji imaju veću gustoću izgrađenosti.

4.2.4. Funkcija odmora

Objekti s funkcijom odmora mogu se podijeliti na sportske objekte, objekte za rekreaciju te objekte za provođenje slobodnog vremena. Sportski objekti uključuju one objekte koji služe za organizirano bavljenje amaterskih i/ili profesionalnim sportom. Sportski objekti uključuju

sportske dvorane i borilišta, stadione, sportske bazene i slično. Neki od poznatijih sportskih objekata su nogometni stadioni Kantrida, Rujevica i Krimeja, bazeni Kantrida te Športska dvorana Zamet (Centar Zamet). Objekti za rekreaciju uključuju one objekte u kojima se ljudi mogu neobavezno okupljati i družiti s ciljem održavanja sportskog načina života, a to također uključuje i ona sportska igrališta koja su namijenjena građanima na slobodno korištenje sa ili bez određene novčane naknade, ali i gradske parkove koji osim za rekreaciju mogu poslužiti i za ostale slične aktivnosti. Za razliku od sportskih objekata i objekata za rekreaciju, objekti za provođenje slobodnog vremena služe stjecanju novih znanja, kulturno uzdizanje te povećanje osjećaja ugone. Takvi objekti uključuju muzeje, knjižnice, kazališta, kino dvorane, sakralne objekte i slično. Kao jedan od najpoznatijih objekata takve vrste ističe se Hrvatsko narodno kazalište „Ivan pl. Zajc“.

Gustoća funkcije (Sl. 16.) odmora pokazuje da broj objekata te funkcije varira između manje od 15 objekata/km² u područjima sa slabom koncentracijom funkcije i više od 60 objekata/km² u područjima s velikom koncentracijom funkcije.



Sl. 16. Gustoća funkcije odmora u Gradu Rijeci

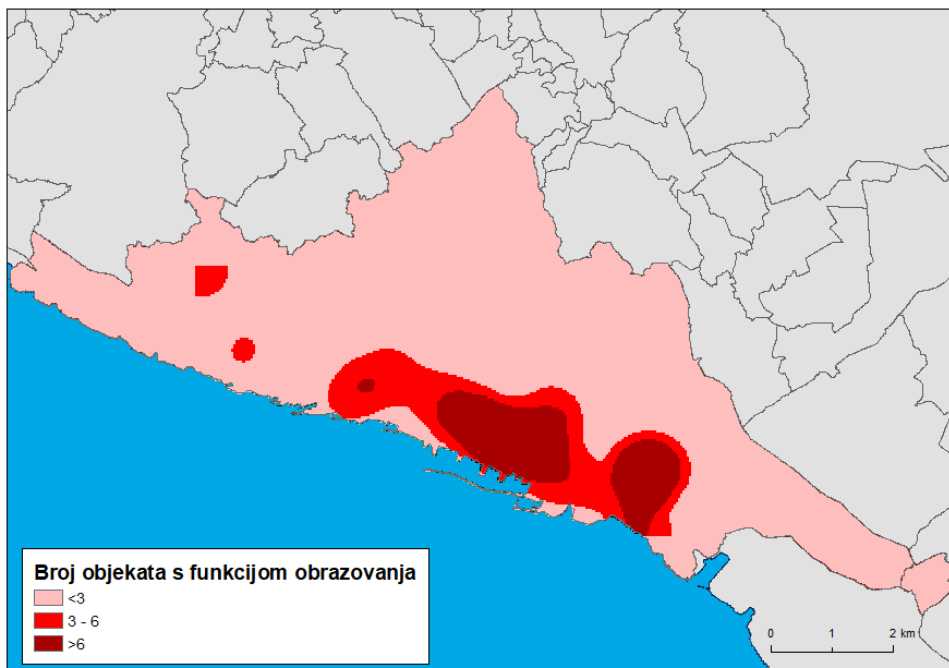
Izvor: : Izvor 12; Izvor 14

Najveću koncentraciju objekata s funkcijom odmora ima područje središnjeg dijela Grada. Općenito, objekti s funkcijom odmora su radi bolje dostupnosti često smješteni na granici dva ili više mjesnih odbora.

4.2.5. Funkcija obrazovanja

Funkcija obrazovanja dijeli se na objekte predškolskog, osnovnoškolskog, srednješkolskog i visokoškolskog obrazovanja.

Gustoća funkcije obrazovanja (Sl. 17.) pokazuje da se objekti te funkcije slabo grupiraju te da njihov broj varira između manje od 3 objekata/km² u područjima sa slabom koncentracijom funkcije i više od 6 objekata/km² u područjima s velikom koncentracijom funkcije.



Sl. 17. Gustoća funkcije obrazovanja u Gradu Rijeci

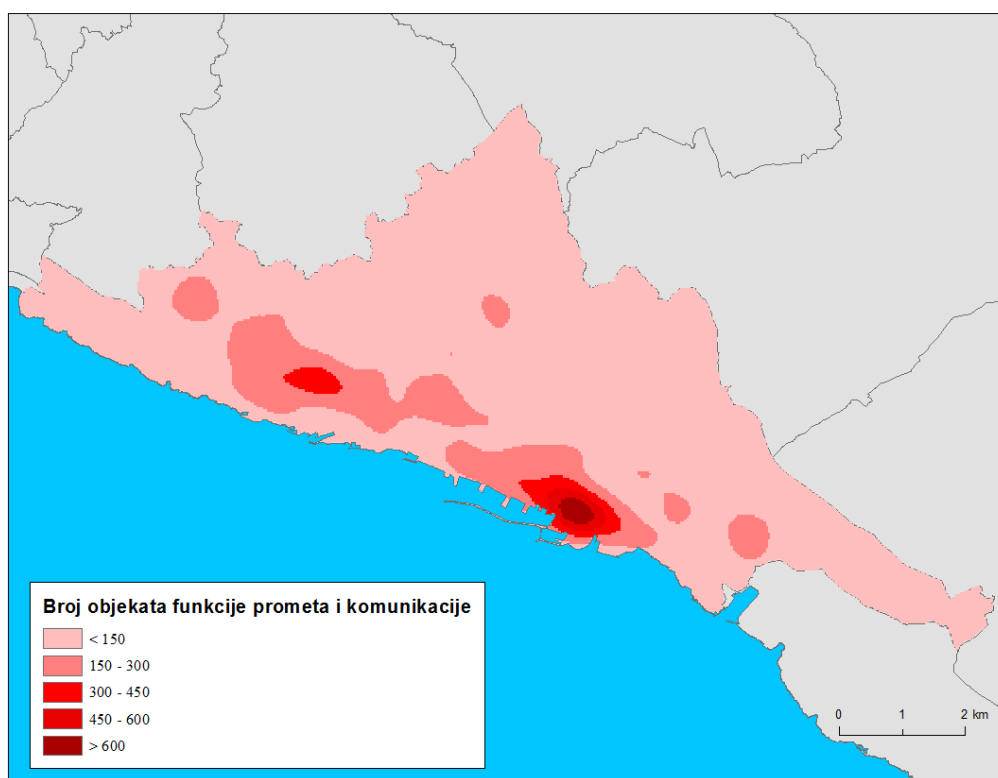
Izvori: : Izvor 12; Izvor 14

Rezultati gustoće funkcije obrazovanja pokazuju snažnu koncentraciju u središtu grada i na prostoru Sušaka, gdje se nalazi sveučilišni kampus koji bi u budućnosti trebao postati važan znanstveno-obrazovni centar Rijeke, ali i cijele države.

4.2.6. Funkcija prometa i komunikacije

Objekti s funkcijom prometa mogu se podijeliti se na objekte cestovnog, željezničkog, pomorskog i zračnog prometa. Od tih objekata posebno su analizirani objekti cestovnog i željezničkog prometa. Objekti cestovnog prometa uključuju autoceste, brze ceste, županijske ceste, lokalne ceste, nerazvrstane ceste i ostale objekte. S druge strane, objekti željezničkog prometa uključuju željezničku prugu i prateće objekte.

Najveću koncentraciju objekata s funkcijom prometa (Sl. 18.) imaju središnji dijelovi Grada što za posljedicu ima čestu pojavu prometnih gužvi i sličnih problema vezanih uz prometni sustav Grada. S druge strane, u ostatku Grada gustoća je vrlo niska što u budućnosti može dovesti to snažnije prometne marginalizacije tog područja.



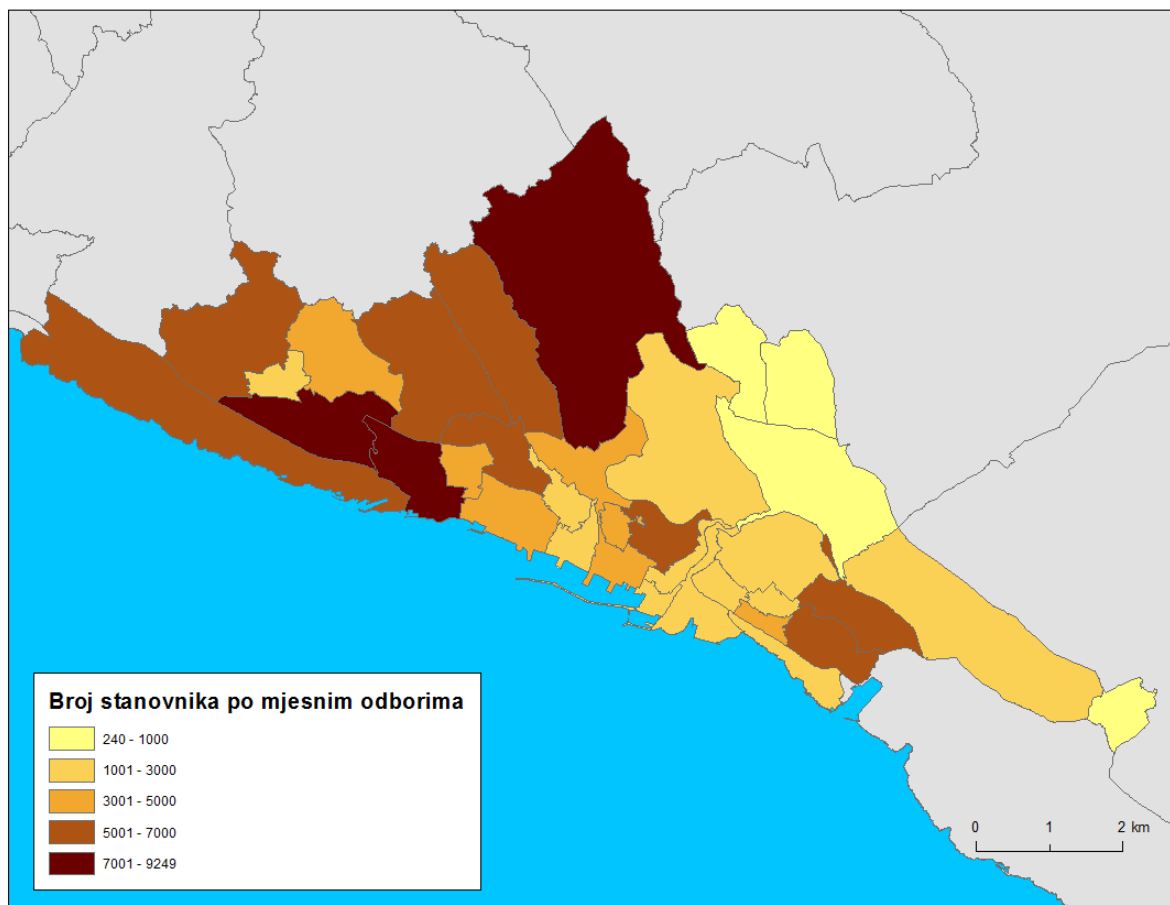
Sl. 18. Gustoća funkcije prometa u Gradu Rijeci

Izvor: : Izvor 12; Izvor 14

4.3. Socijalno-prostorna struktura

Socijalna struktura Grada Rijeke određena je na temelju broja stanovnika i gustoće naseljenosti po mjesnim odborima. Broj stanovnika po mjesnim odborima kreće se od 240 stanovnika u Svetom Kuzmu do 9249 stanovnika koliko ih ima mjesni odbor Sveti Nikola (Krnjevo) (Sl. 19.).

Prema broju stanovnika, najslabije su naseljena područja Svetog Kuzma, Pašca, Orehovice i Svilna, a najjače područja Drenove, Zameta i Krnjeva.




Sl. 19. Broj stanovnika po mjesnim odborima Grada Rijeke

Izvor: Izvor 13

Iako tako, slično kao i broj stanovnika, i gustoća naseljenosti je podijeljena u 5 kategorija (Prilog 17.), pri čemu najmanju gustoću naseljenosti imaju jugoistočni dijelovi Grada, a najveću područja Gornje Vežice, Zameta i Krnjeva.

5. PRAKTIČNI PRIMJER UPOTREBE PROSTORNE OPTIMIZACIJE – PROMJENA FUNKCIONALNO-PROSTORNE STRUKTURE GRADA RIJEKE U BUDUĆNOSTI

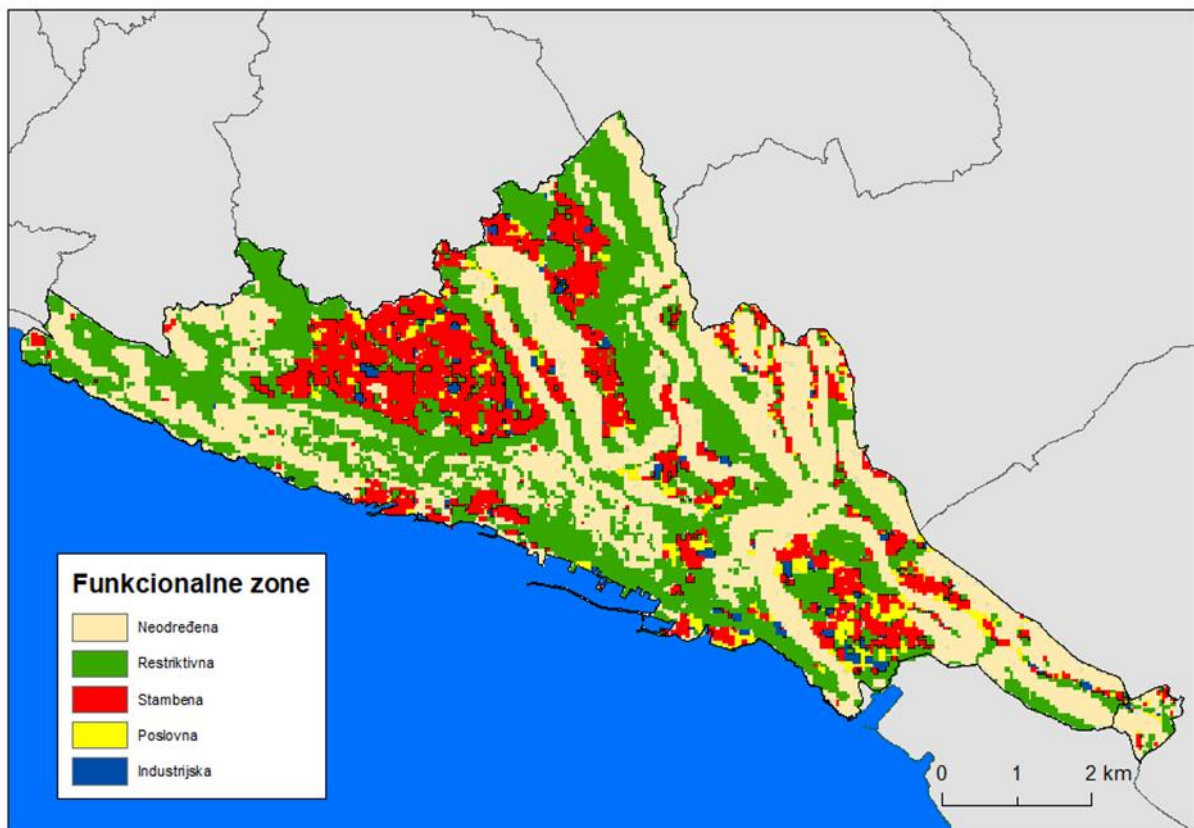
Scenariji promjene funkcionalno-prostorne strukture Grada Rijeke do 2050. godine mogu se podijeliti na scenarij prostornog širenja funkcionalnih zona Grada Rijeke bez prostorne optimizacije i na scenarij prostornog širenja funkcionalnih zona Grada Rijeke na temelju prostorne optimizacije. Iako oba scenarija predviđaju prostorno širenje gradskih funkcija, ipak postoje značajne razlike između njih. Naime, scenarij promjene bez prostorne optimizacije dobiven je na temelju modela promjene (Sl. 20.), a osnovu pronalazi u nastavljanju aktualnih procesa na postojećoj funkcionalno-prostornoj strukturi sukladno prostorno-planskim dokumentima i povijesnim promjenama strukture.



Sl. 20. Simulacija funkcionalno-prostorne strukture Grada Rijeke 2050. godine na temelju modela promjene

Izvor: Izvor 12

S druge strane, kao suprotnost tom scenariju, kreiran je optimistični scenarij koji svoje ime duguje činjenici da nastoji pronaći najbolje moguće rješenje te predviđa korake koje je potrebno učiniti kako bi se to rješenje i realiziralo. Drugim riječima, prema rezultatima krajobrazne metrike optimistični scenarij prikazuje kako bi izgledala funkcionalno-prostorna struktura nakon provedbe prostorne optimizacije, odnosno nakon provedbe modela alokacije (Sl. 21.).



Sl. 21. Simulacija funkcionalno-prostorne strukture Grada Rijeke 2050. godine na temelju modela alokacije

Izvor: Izvor 12

Upotrebom globalnih pokazatelja povezanosti provedena je usporedba trenutne funkcionalno-prostorne strukture s potencijalnim budućima strukturama (Prilog 18.) koja je pokazala da najveću kompaktnost i raznovrsnost funkcionalnih zona ima funkcionalno-prostorna struktura dobivena modelom alokacije, odnosno prostornom optimizacijom.

5.1. Scenarij 1: Prostorno širenje gradskih funkcija Grada Rijeke bez prostorne optimizacije (pesimistični scenarij)

Scenarij 1 je eksplorativni kvantitativni scenarij koji se zasniva na rezultatima dobivenima modelom promjene, a zbog toga što se ne predviđa značajnija poboljšanja funkcionalno-prostorne strukture može se reći da se radi o pesimističnom scenariju.

Ključne značajke pesimističnog scenarija na temelju krajobrazne metrike (Prilog 19.):

- širenje i razvoj grada neće biti praćeni značajnijim izmještanjem gradskih funkcija iz centra grada
- funkcionalno-prostorna struktura će i dalje ostati strogo centralizirana
- doći će do dodatnog povećanja razlika u razvijenosti između centra i periferije, budući da će bogatije stanovništvo nastojati ostati u centru grada gdje ima veću dostupnost gradskih funkcija, dok će siromašnije stanovništvo ostati živjeti na periferiji gdje će imati slabiju dostupnost gradskih funkcija
- povećava se površina neodređenih zona što se javlja kao posljedica smanjene potražnje za nekom od gradskih funkcija
- smanjenje broja stanovnika utjecati će i na smanjenje broja objekata gradskih funkcija
- isto tako, depopulacija smanjuje površinu ograničenih zona na način da smanjenje broja stanovnika utječe na smanjenje potreba za povećanjem broja objekata koji pripadaju ovoj vrsti zone pa njihov broj ostaje isti, a u nekim dijelovima grada se smanjuje
- površina industrijskih funkcionalnih zona pokazuje značajna povećanja što ne događa zbog priljeva nove industrije u grad već zbog povećane izgradnje skladišnih prostora i proširenja postojećih pogona

Scenarij prostornog širenja gradskih funkcija bez prostorne optimizacije ili pesimistični scenarij predviđa minimalne promjene u funkcionalno-prostornoj strukturi grada. Naime, model promjene funkcionalne strukture predviđa da će većina gradskih funkcija ostati koncentrirana u samom centru grada Rijeke i njegovoj široj okolini, dok će rubni dijelovi Grada i u budućnosti imati slabiju dostupnost funkcija. Drugim riječima, predviđa se da će funkcionalno-prostorna struktura Grad Rijeke u slijedećih 30-ak godina prolaziti kroz razdoblje stagnacije, to jest da se u narednom tridesetogodišnjem razdoblju neće značajnije mijenjati.

5.2. Scenarij 2: Prostorno širenje gradskih funkcija Grada Rijeke na temelju prostorne optimizacije (optimistični scenarij)

Scenarij 2 je normativni kvantitativni scenarij koji se zasniva na rezultatima dobivenima modelom alokacije.

Ključne značajke scenarija na temelju rezultata krajobrazne metrike (Prilog 20.):

- kreiranje sekundarnih centara razvoja na području Pehlina i Trsata
- kvalitetnije unutargradsko povezivanje kao posljedica konstantne prostorne interakcije između centra grada, sekundarnih centara i periferije
- smanjenje ekonomskih razlika između centra i periferije
- postizanje više razine urbane održivosti
- povećanje dostupnosti funkcija
- diverzifikacija funkcionalno-prostorne strukture
- relokacija i/ili prenamjena velikih industrijskih funkcionalnih zona
- stvaranje novih industrijskih funkcionalnih zona za smještaj objekata ekološki prihvatljive industrije
- povećanje raznovrsnost funkcionalnih zona kao posljedica decentralizacije funkcija stanovanja i rada
- smanjenje površina ograničenih zona kao posljedica njihovog prilagođavanja na alokaciju stambenih, poslovnih i industrijskih zona

Scenarij prostornog širenje gradskih funkcija Grada Rijeke na temelju prostorne optimizacije ili optimistični scenarij predviđa premještanje gradskih funkcija iz centra grada prema periferiji na način da se gradske funkcije razmjestu u skladu s trenutnim razvojnim mogućnostima vodeći pritom računa o ekonomskoj i ekološkoj učinkovitosti. Drugim riječima, model alokacije predviđa da će se većina gradskih funkcija decentralizirati na način da će se jedan dio objekata s funkcijom rada premjestiti na rubove grada, odnosno na područje Srdoča i Sušaka što će potaknuti snažnije doseljavanje u taj prostor i bolju reorganizaciju funkcije stanovanja. Također, u tom području, kao posljedica alokacije gradskih funkcija stambenih, poslovnih i industrijskih zona dolazi do smanjenja i reorganizacije gradskih funkcija ograničenih zona čime se smanjuju ekonomski troškovi i postiže bolja organizacija prostora. Naime, kompaktnijom raspodjelom gradskih funkcija smanjuje se potreba za daljnjim nepotrebnim prostornim širenjem određenih funkcionalnih zona, u ovom slučaju ograničenih zona, otvara se prostor za druge funkcionalne zone čime se postiže racionalnije upravljanje prostorom i stvara osnova za

kvalitetnije planiranje prostora u budućnosti. Time se dokazuje međusobna uzročno-posljedična povezanost između gradskih funkcija. To jest, dokazano je da će promjena lokacije jedne vrste gradskih funkcija utjecati na to da se ovisno o njoj razmještaju i druge vrste gradskih funkcija. Uz to, prema modelu alokacije, jedan dio funkcija stanovanja premjestio bi se na područje riječke luke i brodogradilišta „3. Maj“. Naime, na tom području scenarij predviđa promjenu funkcionalno-prostorne strukture u smislu da se postojeće funkcije relociraju, a postojeći objekti prenamjene u stambeno-poslovne prostore.

6. DALJNJA ISTRAŽIVANJA

U daljnjim istraživanjima na temu prostorne optimizacije valjalo bi posvetiti posebnu pažnju odnosu prostorne optimizacije i GIS-a te odnosu prostorne optimizacije i prostornog planiranja. Budući da se prostorna optimizacija bavi prostornim problemima, važnost GIS-a u rješavanju problema prostorne optimizacije uključuje upravljanje prostornim podacima, vrednovanje prostornih osobina i odnosa, pomoć u rješavanju problema te vizualizaciju rješenja (Tong i Murray, 2012, prema: Longley i Batty, 1996, Church, 1999, Church, 2002, Malczewski, 1999, Church i Murray 2009, Murray 2010). Također, osim navedenog postoji i mogućnost da se u daljnjim istraživanjima posebna pažnja posveti izradi jedinstvenog programskog dodatka za prostornu optimizaciju u okviru programskog paketa QGIS.

S druge strane, daljnja istraživanja na temu odnosa prostorne optimizacije i prostornog planiranja moglo bi rezultirati nekim radom vezanim uz geodizajn. Naime, geodizajn je relativno novi pristup prostornom planiranju koji nastoji pronaći ravnotežu između arhitektonskog i geografskog načina planiranja prostora, a važna odrednicu tog pristupa planiranja je prostorna optimizacija.

7. ZAKLJUČAK

U ovom radu, dan je prikaz prostorne optimizacije kao skupa tehnika i metoda koja u budućnosti može imati važnu ulogu u istraživanjima urbane geografije. Također, na primjeru Grada Rijeke pokazano je kako funkcionalno-prostorna struktura nakon provedbe prostorne optimizacije pokazuje veću kompaktnost i raznovrsnost funkcionalnih zona nego što je to slučaj s trenutnom strukturom. Također, u radu je dokazano da će funkcionalno-prostorna struktura bez provedbe prostorne optimizacije i u budućnosti zadržati nejednak raspored funkcionalnih zona, a samim time i gradskih funkcija povećavajući pritom razlike u razvijenosti između centra i periferije. Uz to, u radu su potvrđene zadane hipoteze:

1) H1: *Razvoj funkcionalno-prostorne strukture bez prostorne optimizacije utjecati će na povećanje centralizacije gradskih funkcija u centru grada*

Ova hipoteza je potvrđena. Naime, rezultati modela promjene pokazuju malu razliku u promjeni funkcionalnih zona čime se potvrđuje da većina gradskih funkcija ostaje koncentrirana u centru grada.

2) H2: *Provedbom prostorne optimizacije stvoriti će se heterogena funkcionalno-prostorna struktura*

Ova hipoteza je potvrđena. Naime, prostorna optimizacija pokazala je da heterogene funkcionalno-prostorne strukture imaju bolju kompaktnost, raznovrsnost i dostupnost pa je takva struktura poželjna i za Grad Rijeku

3) H3: *Nakon provođenja prostorne optimizacije, funkcionalno-prostorna struktura ima veću unutarnju koheziju (između pojedinih gradskih funkcija)*

Ova hipoteza je potvrđena. Naime, različite vrste funkcionalnih zona nakon prostorne optimizacije su više izmješane i bolje povezane.

Provedbom prostorne optimizacije na primjeru Grada Rijeke nastojalo se ukazati na potencijal prostorne optimizacije u reorganizacije funkcionalno-prostorne strukture, ali i prostora u cjelini. Taj potencijal može se najbolje uočiti ukoliko se razmotre pozitivni učinci do kojih bi optimizacija u konačnici dovela, a koji bi označili zaokret u budućem planiranju što bi rezultiralo boljom prostornom raspodjelom gradskih funkcija.

LITERATURA

- 1) Armstrong, M. P., 2000: Geography and Computational science, *Annals of the American Geographers* 90 (1), 46-56.
- 2) Bognar, A., 1992: Inženjerskogeomorfološko kartiranje, *Acta Geographica Croatica* 27, 173-184.
- 3) Chelaru, D.-A., Oiste, A.-M., Mihai, F.-C., 2014: Quantifying the changes in landscape configuration using open source GIS. Case study: Bistrita subcarpathian valley, u: *14th International Multidisciplinary Scientific GeoConference on ECOLOGY, ECONOMICS, EDUCATION AND LEGISLATION SGEM 2014*, Albena, Bugarska, 557 – 565.
- 4) Church, R. L., 1999: Location modelling and GIS, u: *Geographical information systems*, 2. izdanje (ur. Longley, P. i dr.), Wiley, New York, 293-303.
- 5) Church, R. L., 2001: Spatial optimization models, u: *International encyclopedia of social & behavioral sciences* (ur. Smelser, N. J., Baltes, P. B.), Elsevier, New York, 14811-14818.
- 6) Church, R. L., 2002: Geographic information systems and location science, *Computers & Operations Research* 29 (5), 41-62.
- 7) Church, R. L., Murray, A. T., 2009: *Business site selection, locations and GIS*, Wiley, New York.
- 8) Čalija Matijević, M., Radišić, B., 2013: Nashova ravnoteža, *Osječki matematički list* 13, 105-119.
- 9) Damjanić, T., 2008: *Primjena evolucijskih algoritama za rješavanje aproksimacijskog problema*, diplomski rad, Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu, Zagreb.
- 10) de Sousa, L., da Silva, A. R., 2011: Review of spatial simulation tools for geographic information systems, u: *Proceedings of the Third International Conference on Advances in System Simulation (SIMUL 2011)* (ur. Omerović, A.), International Academy, Research, and Industry Association (IARIA), Barcelona, 1-6.
- 11) Delmelle, E., 2010: *Spatial Optimization Methods*, u: *Encyclopedia of Human Geography*, 2657-2659.
- 12) Dolušić, M., 2017: *Polarizacija naseljenosti u riječkoj aglomeraciji*, diplomski rad, Geografski odsjek Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Zagreb.

- 13) Droždjek, T., 2015: *Genetski algoritmi i primjene*, diplomski rad, Matematički odsjek Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Zagreb.
- 14) Guan, D. J., Gao, W. J., Watari, K., Fukahori, H., 2008: Land use change of Kitakyushu based on landscape ecology and Markov model, *Journal of Geographical Sciences* 18, 455-468.
- 15) Hewitt, R., Díaz Pacheco, J. and Moya Gómez, B., 2013: A cellular automata land use model for the R software environment, *GeoFocus* 14, 1-22.
- 16) Horvat, T., 2007: *Procjena vrijednosti stambenog objekta troškovnom metodom*, diplomski rad, Geodetski fakultet Sveučilišta u Zagrebu, Zagreb.
- 17) Ileković, A., 2017: *Evolucijska teorija igara*, diplomski rad, Matematički odsjek Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Zagreb.
- 18) Jakovčić, M., 2016, *Prometna geografija, nastavni materijali*, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Zagreb.
- 19) Jogun, T., 2016: *Simulacijski model promjene zemljišnog pokrova u Požeško-slavonskoj županiji*, diplomski rad, Geografski odsjek Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Zagreb.
- 20) Kegalj, I., 2015: *Procjena, utjecaja lučkih procesa na okoliš formiranjem okolišnog indeksa*, doktorska disertacija, Tehnički fakultet Sveučilišta u Rijeci, Rijeka.
- 21) Kuby, M. J., 1989: A location-allocation model of Losch's central place theory: Testing on a uniform lattice network, *Geographical Analysis* 21 (3), 16-37.
- 22) Ligmann-Zielinska, A., 2016: Spatial Optimization, u: *International Encyclopedia of Geography: People, the Earth, Environment and Technology*, John Wiley & Sons Ltd, 1-6.
- 23) Ligmann-Zielinska, A., Church, R. L., Jankowski, P., 2005: Sustainable Urban Land Use Allocation with Spatial Optimization, u: *Proceedings of the 8th International Conference on GeoComputation* (ur. Yichun, X., Brown, D.G.), University of Michigan, Ann Arbor, MI 48109 USA, 1-18.
- 24) Lojen, S., 2016: *Primjena heurističkih metoda u mjeriteljstvu*, diplomski rad, Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu, Zagreb.
- 25) Longley, P. A., Batty, M., 1996: *Spatial analysis: Modelling in a GIS environment*, GeoInformation International, Cambridge, UK.

- 26) Malczewski, J., 1999: *GIS and multicriteria decision analysis*, Wiley, New York.
- 27) Marković, H., 2006: *Primjena optimizacije kolonijom mrava na rješavanje problema trgovačkog putnika*, seminarski rad iz predmeta Algoritmi u sustavima upravljanja, Zavod za elektroniku, mikroelektroniku, računalne i inteligentne sustave Fakulteta elektrotehnike i računarstva Sveučilišta u Zagrebu, Zagreb.
- 28) Miller, H. J., Shaw, S. L., 2001: *Geographic information systems for transportation: Principles and applications*, Oxford University Press, New York.
- 29) Murray, A. T., 2010: Advances in location modeling: GIS linkages and contributions, *Journal of Geographical Systems* 12 (3), 35-54.
- 30) Nieto-Morote, A., Ruz-Vila, F., 2011: A Fuzzy Approach to Construction Project Risk Assessment, *International Journal of Project Management* 29, 220-231.
- 31) Saaty, T. L., 1977: A scaling method for priorities in hierarchical structures, *Journal of mathematical psychology* 15 (3), 234-281.
- 32) Saaty, T. L., 1980: *Multicriteria Decision Making: The Analytic Hierarchy Process*, RWS Publication, 4922 Ellsworth Ave., Pittsburgh, PA 15213 USA.
- 33) Scott, A. J., 1971: *Combinatorial programming, spatial analysis and planning*, Methuen, London.
- 34) Sharaf, A., Jie, S., 2008: Calibration and Assessment of Multitemporal Image-based Cellular Automata for Urban Growth Modeling, *Photogrammetric Engineering & Remote Sensing* 74 (12), 1539–1550.
- 35) Talbi, E.-G., 2009: *Metaheuristics – From design to implementation*, John Wiley & Sons, Hoboken.
- 36) Tharayil, Y., 2016: *Simulation of land use change in Thiruvananthapuram Corporation*, Kerala University Thiruvananthapuram, Thiruvananthapuram.
- 37) Tong, D., Murray, A. T., 2012: Spatial Optimization in Geography, *Annals of Association of American Geographers* 102 (6), 1290-1309.
- 38) Vrček, S., 2012: Tipologija izgradnje i podijela zgrada prema razdoblju gradnje i energetske potrebama, *Tehnički glasnik* 6 (1), 60-64.

- 39) Vresk, D., 2004: *Aproksimacijski algoritmi za NP-teške probleme*, diplomski rad, Matematički odsjek Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Zagreb.
- 40) Vresk, M., 1990: *Grad u regionalnom i urbanom planiranju*, Školska knjiga, Zagreb.
- 41) Vresk, M., 2002: *Grad i urbanizacija*, Školska knjiga, Zagreb
- 42) Yang, X., Zheng, X.-Q., Lv, L.-N., 2012: A spatiotemporal model of land use change based on ant colony optimization, Markov chain and cellular automata, *Ecological Modelling* 233, 11-19.
- 43) Zhang, H. H., Zeng, Y. N., Bian, L., 2010: Simulating Multi-Objective Spatial Optimization Allocation of Land Use Based on the Integration of Multi-Agent System and Genetic Algorithm, *International Journal of Environmental Research* 4 (4), 765-776.

IZVORI

- 1) Izvor 1: MOLUSCE, Next GIS, <http://nextgis.com/blog/molusce/> (08.09. 2019.)
- 2) Izvor 2: Prostorni plan uređenja Grada Rijeke, 2017, <https://www.rijeka.hr/teme-za-gradane/stanovanje-i-gradnja/urbanisticko-planiranje-2/prostorni-planovi/prostorni-plan-uredenja-grad-rijeke/> (09.03.2019.)
- 3) Izvor 3: Generalni urbanistički plan Grada Rijeke, 2009, <https://www.rijeka.hr/teme-za-gradane/stanovanje-i-gradnja/urbanisticko-planiranje-2/prostorni-planovi/generalni-urbanisticki-plan-grad-rijeke/> (09.03.2019.)
- 4) Izvor 4: Pokazatelji troškova građenja, 2017, <https://www.arhitektika.hr/files/file/vijesti/2017/pdf/Pokazatelji%20troškova%20građenja%202017.pdf> (25.06. 2019.)
- 5) Izvor 5: Cjenik građevinskog zemljišta Grada Rijeke, 2015, <https://www.rijeka.hr/wp-content/uploads/2016/07/Cjenik-građevinskog-zemljišta-pročišćeni-tekst.pdf> (07.04.2019.)
- 6) Izvor 6: Nacrt programa zaštite zraka, ozonskog sloja, ublažavanja klimatskih promjena i prilagodbe klimatskim promjenama Grada Rijeke za razdoblje 2018. - 2022., 2019, https://www.rijeka.hr/wp-content/uploads/2019/05/Nacrt_Programa_Zastite_zraka_GradRijeka_2019.pdf (03.03.2019.)
- 7) Izvor 7: Pareto optimalno rješenje, http://www.unizd.hr/portals/4/nastavni_mat/1_godina/ekonomija/ekonomija_17.pdf (09.04.2019.)
- 8) Izvor 8: Monte Carlo simulacija, <https://www.mathworks.com/discovery/monte-carlo-simulation.html> (09.04.2019.)
- 9) Izvor 9: Markovljevi lanac, <https://www.merriam-webster.com/dictionary/Markov%20chain> (09.04.2019.)
- 10) Izvor 10: HAOP, <http://www.haop.hr/hr> (03.03.2019.)
- 11) Izvor 11: KD VODOVOD I KANALIZACIJA d.o.o., www.kdvik-rijeka.hr/ (03.03.2019.)
- 12) Izvor 12: Open Street Map, <https://www.openstreetmap.org/#map=7/44.523/16.460> (09.01.2019.)

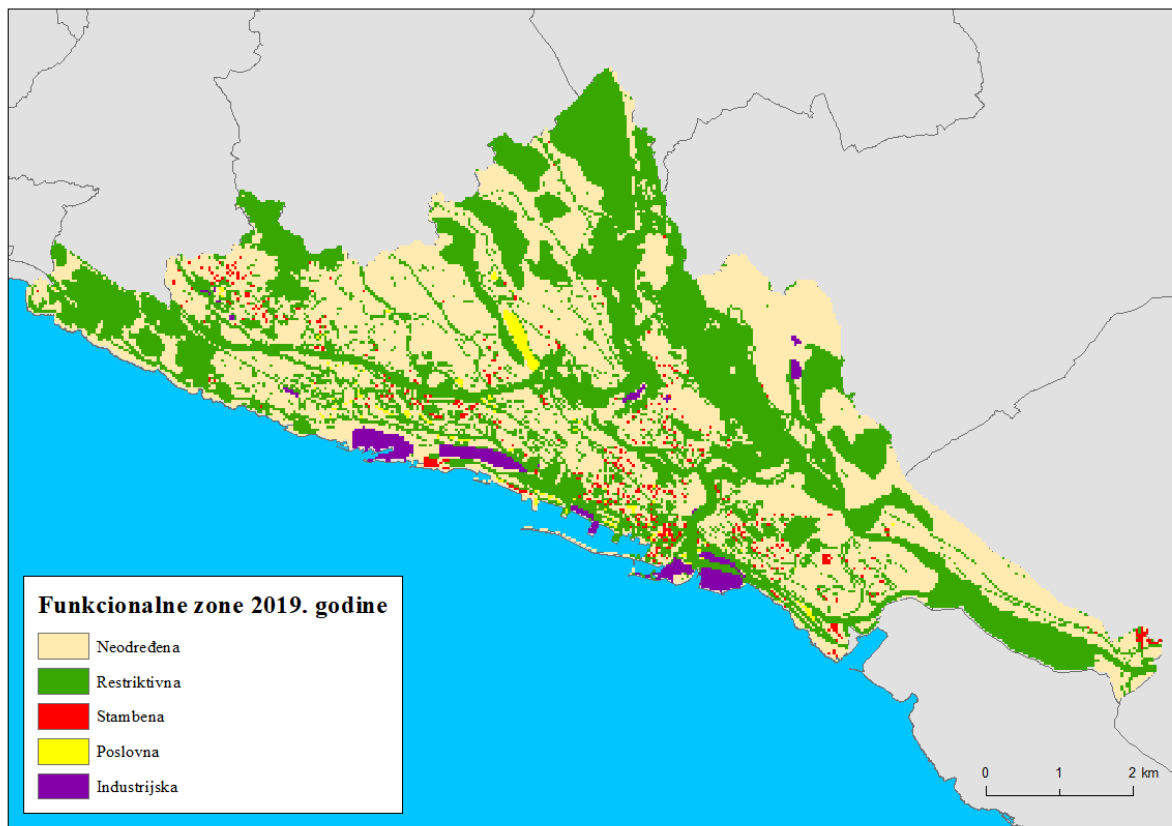
13) Izvor 13: Grad Rijeka, <https://www.rijeka.hr/>
(09.03.2019.)

14) Izvor 14: *Središnji registar prostornih jedinica (SRPJ)*, 2013

15) Izvor 15: Open Street Map, povijesni podaci, Geofabrik, <https://www.geofabrik.de/data/>
(09.03.2019.)


16) Izvor 16: *Digitalni atlas Republike Hrvatske*, GISdata, Zagreb, 2005.

PRILOZI



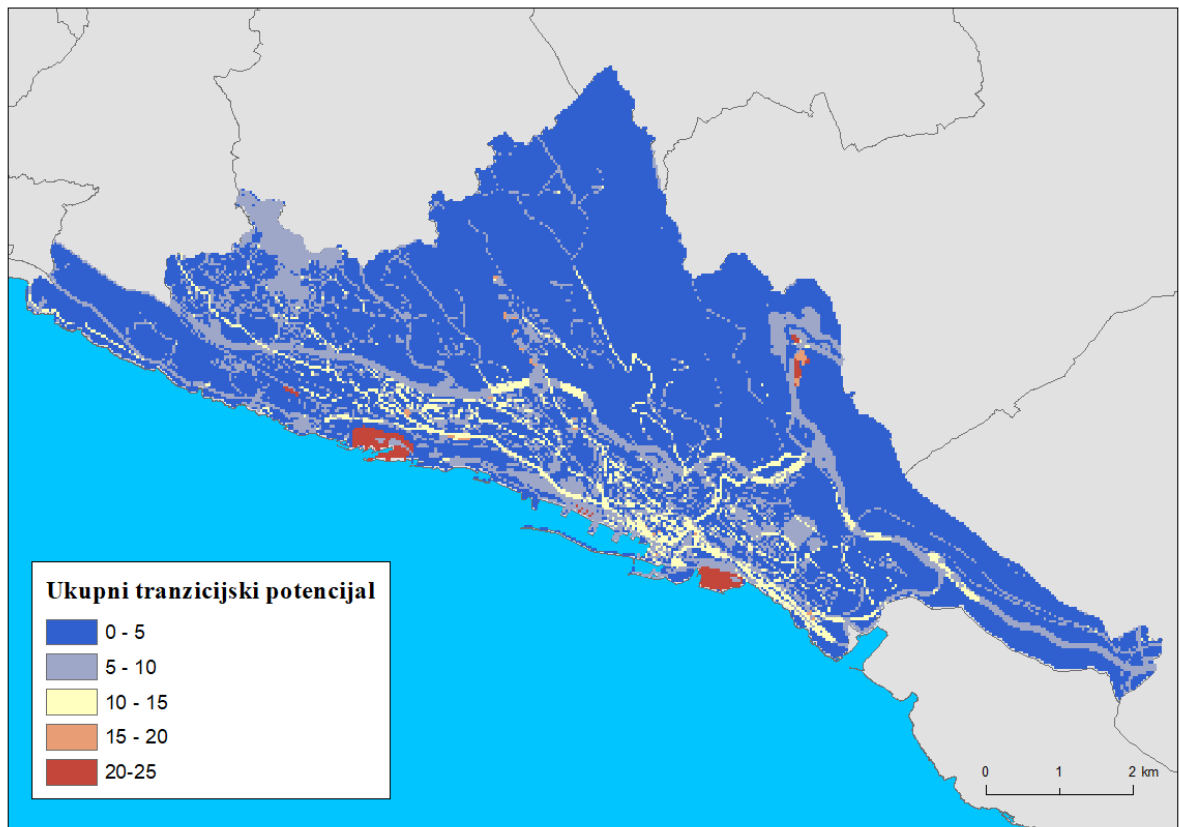
Prilog 1. Funkcionalno-prostorna struktura Grada Rijeke 2019. godine

Izvor: Izvor 12



Prilog 2. Funkcionalno-prostorna struktura Grada Rijeke 2014. godine

Izvor: Izvor 15




Prilog 3. Ukupni tranzicijski potencijal promjene funkcionalnih zona u Gradu Rijeci

Izvor: izradio autor prema Izvor 14

Prilog 4. Vrijednosti indeksa kvalitete zraka po kategorijama onečišćenja

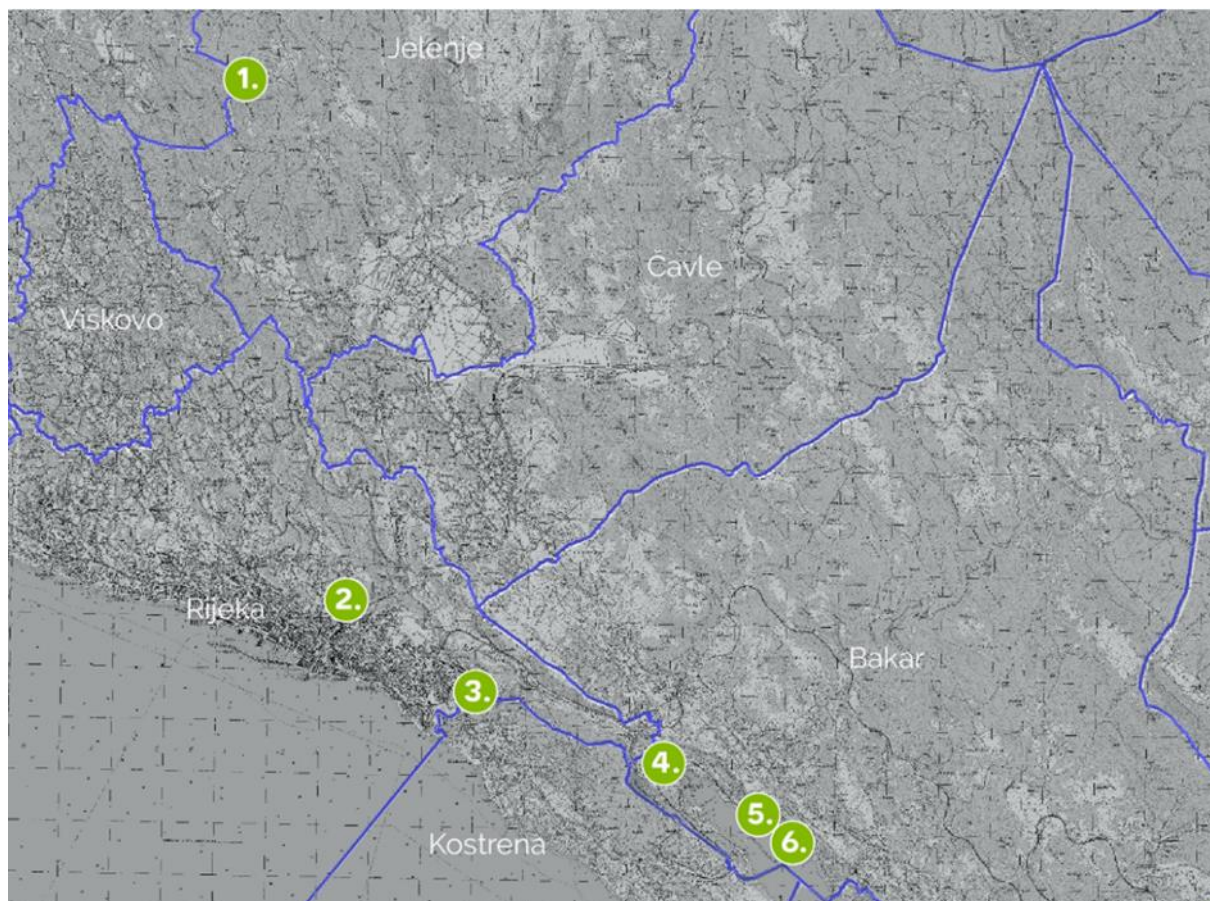
ONEČIŠĆENJE	RASPON VRIJEDNOSTI INDEKSA	KONCENTRACIJE ONEČIŠĆUJUĆIH TVARI (µg/m ³)								
		NO ₂	PM ₁₀		O ₃	PM _{2.5}		CO	SO ₂	
		1 sat	1 sat	24 sata	1 sat	1 sat	24 sata	8-satna	1 sat	
VRLO VISOKO	>100	>400	>180	>100	>240	>110	>60	>20000	>500	
VISOKO	100	400	180	100	240	110	60	20000	500	
	75	200	90	50	180	55	30	10000	350	
SREDNJE	75	200	90	50	180	55	30	10000	350	
	50	100	50	30	120	30	20	7500	100	
NISKO	50	100	50	30	120	30	20	7500	100	
	25	50	25	15	60	15	10	5000	50	
VRLO NISKO	25	50	25	15	60	15	10	5000	50	
	0	0	0	0	0	0	0	0	0	

Izvor: Izvor 10



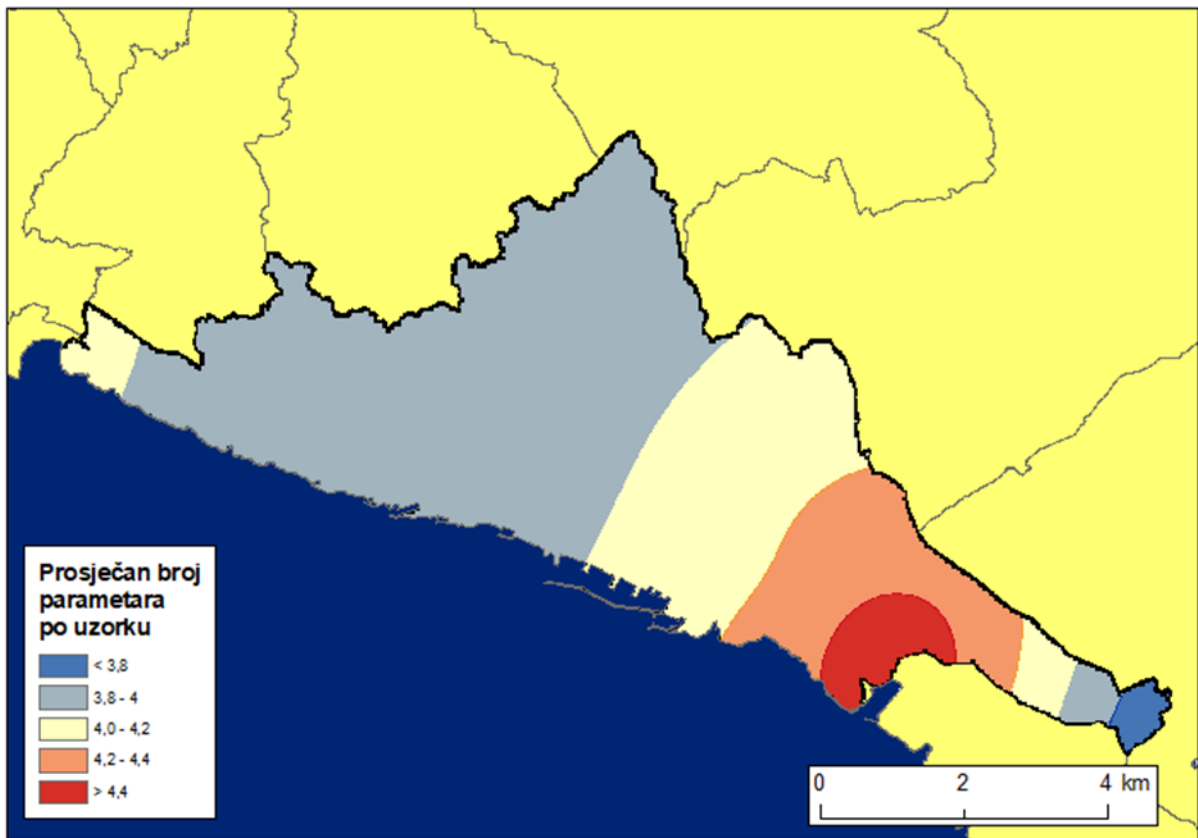
Prilog 5. Indeks kvalitete zraka u Gradu Rijeci

Izvor: Izvor 10




Prilog 6. Izvori pitke vode na širem riječkom području

Izvor: Izvor 11



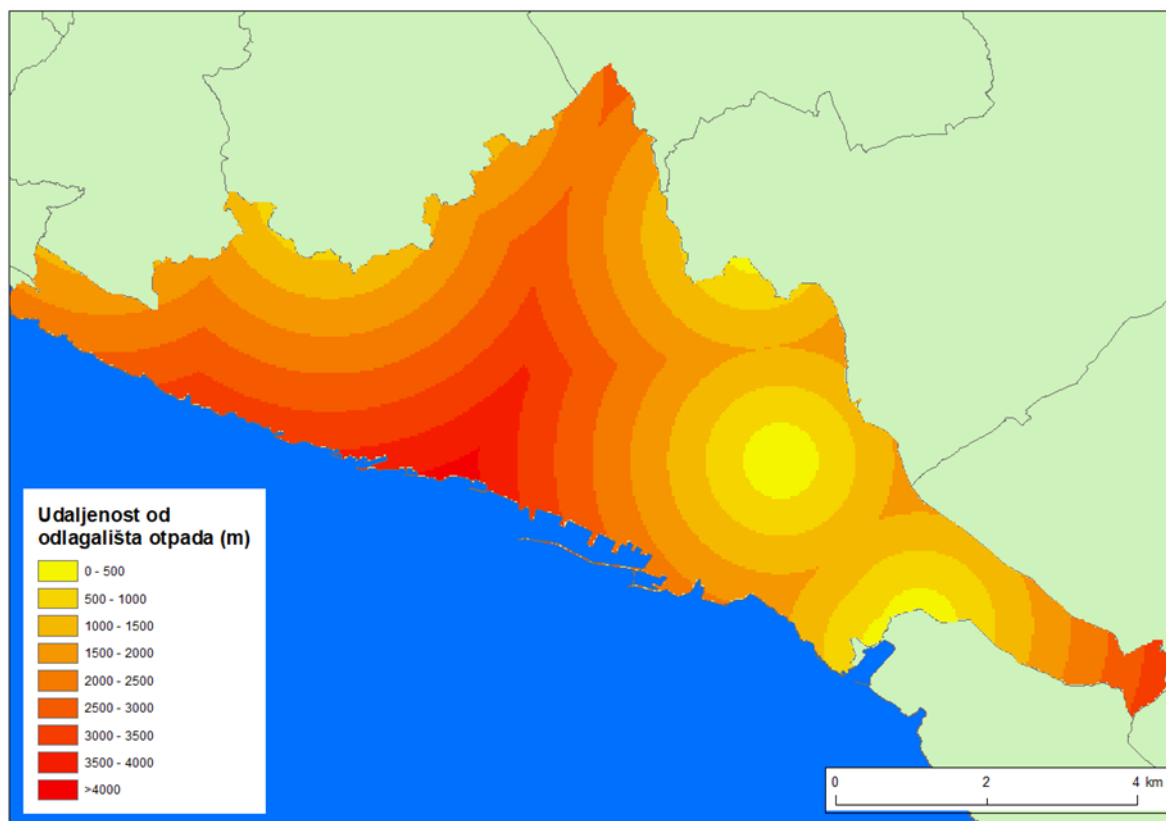
Prilog 7. Prosječne vrijednosti broja negativno ocijenjenih parametara po uzorku vode

Izvor: Izvor 11




Prilog 8. Prosječna jačina buke u Gradu Rijeci

Izvor: Izvor 10



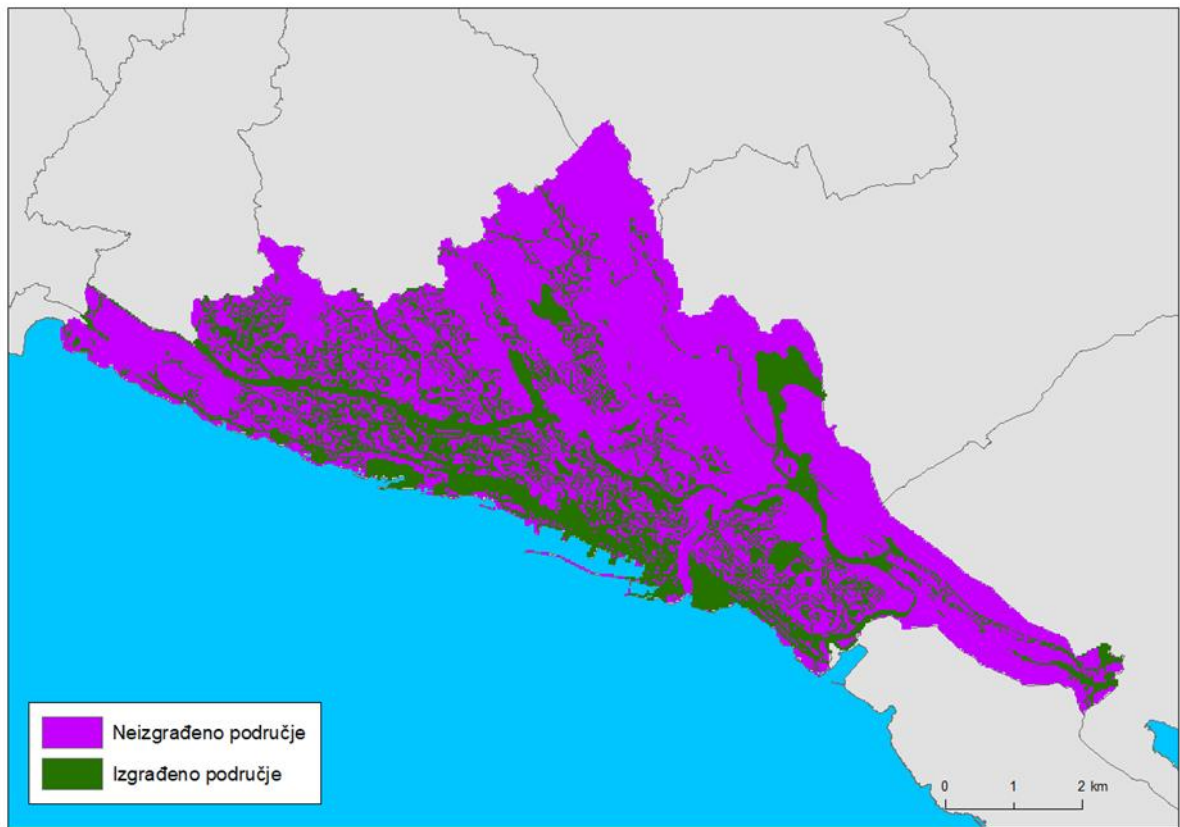
Prilog 9. Udaljenost od najbližeg odlagališta otpada u Gradu Rijeci

Izvor: Izvor 10



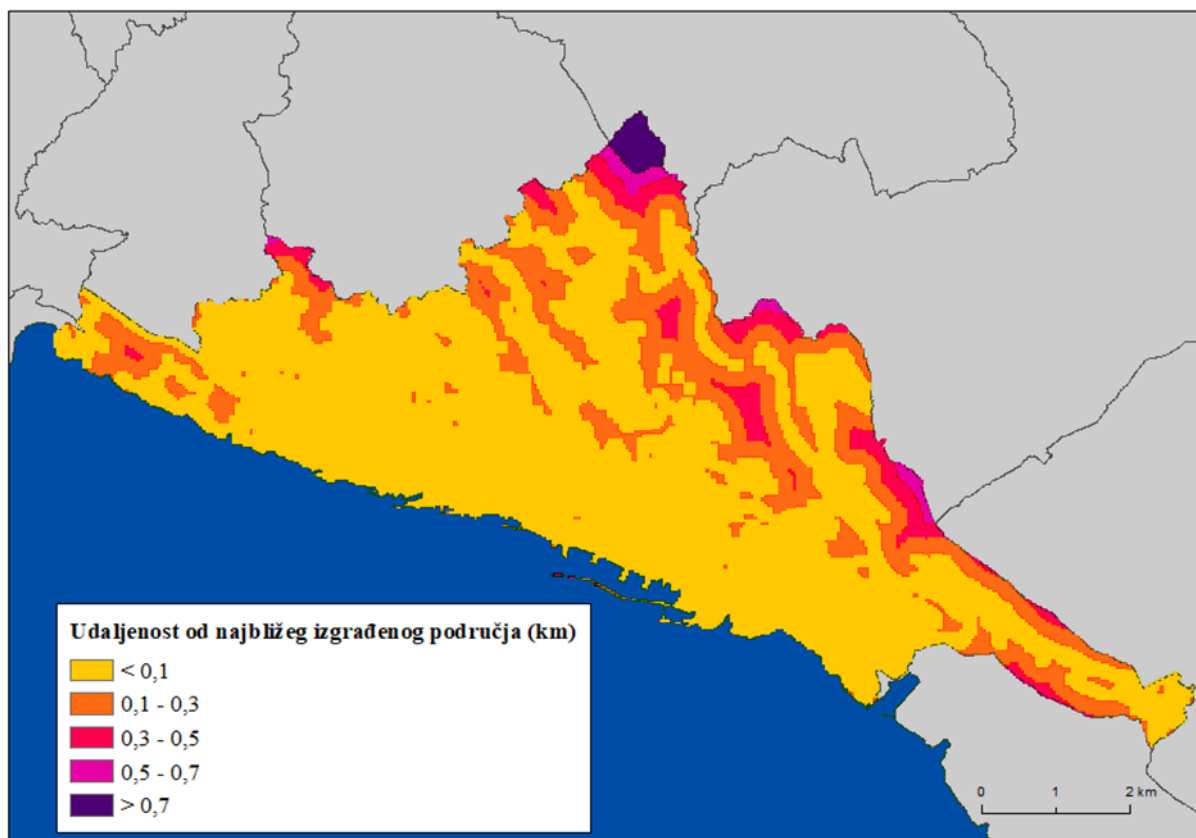
Prilog 10. Udaljenost od centra Grada Rijeke

Izvor: Izvor 12




Prilog 11. Izgrađeno područje Grada Rijeke

Izvor: Izvor 12



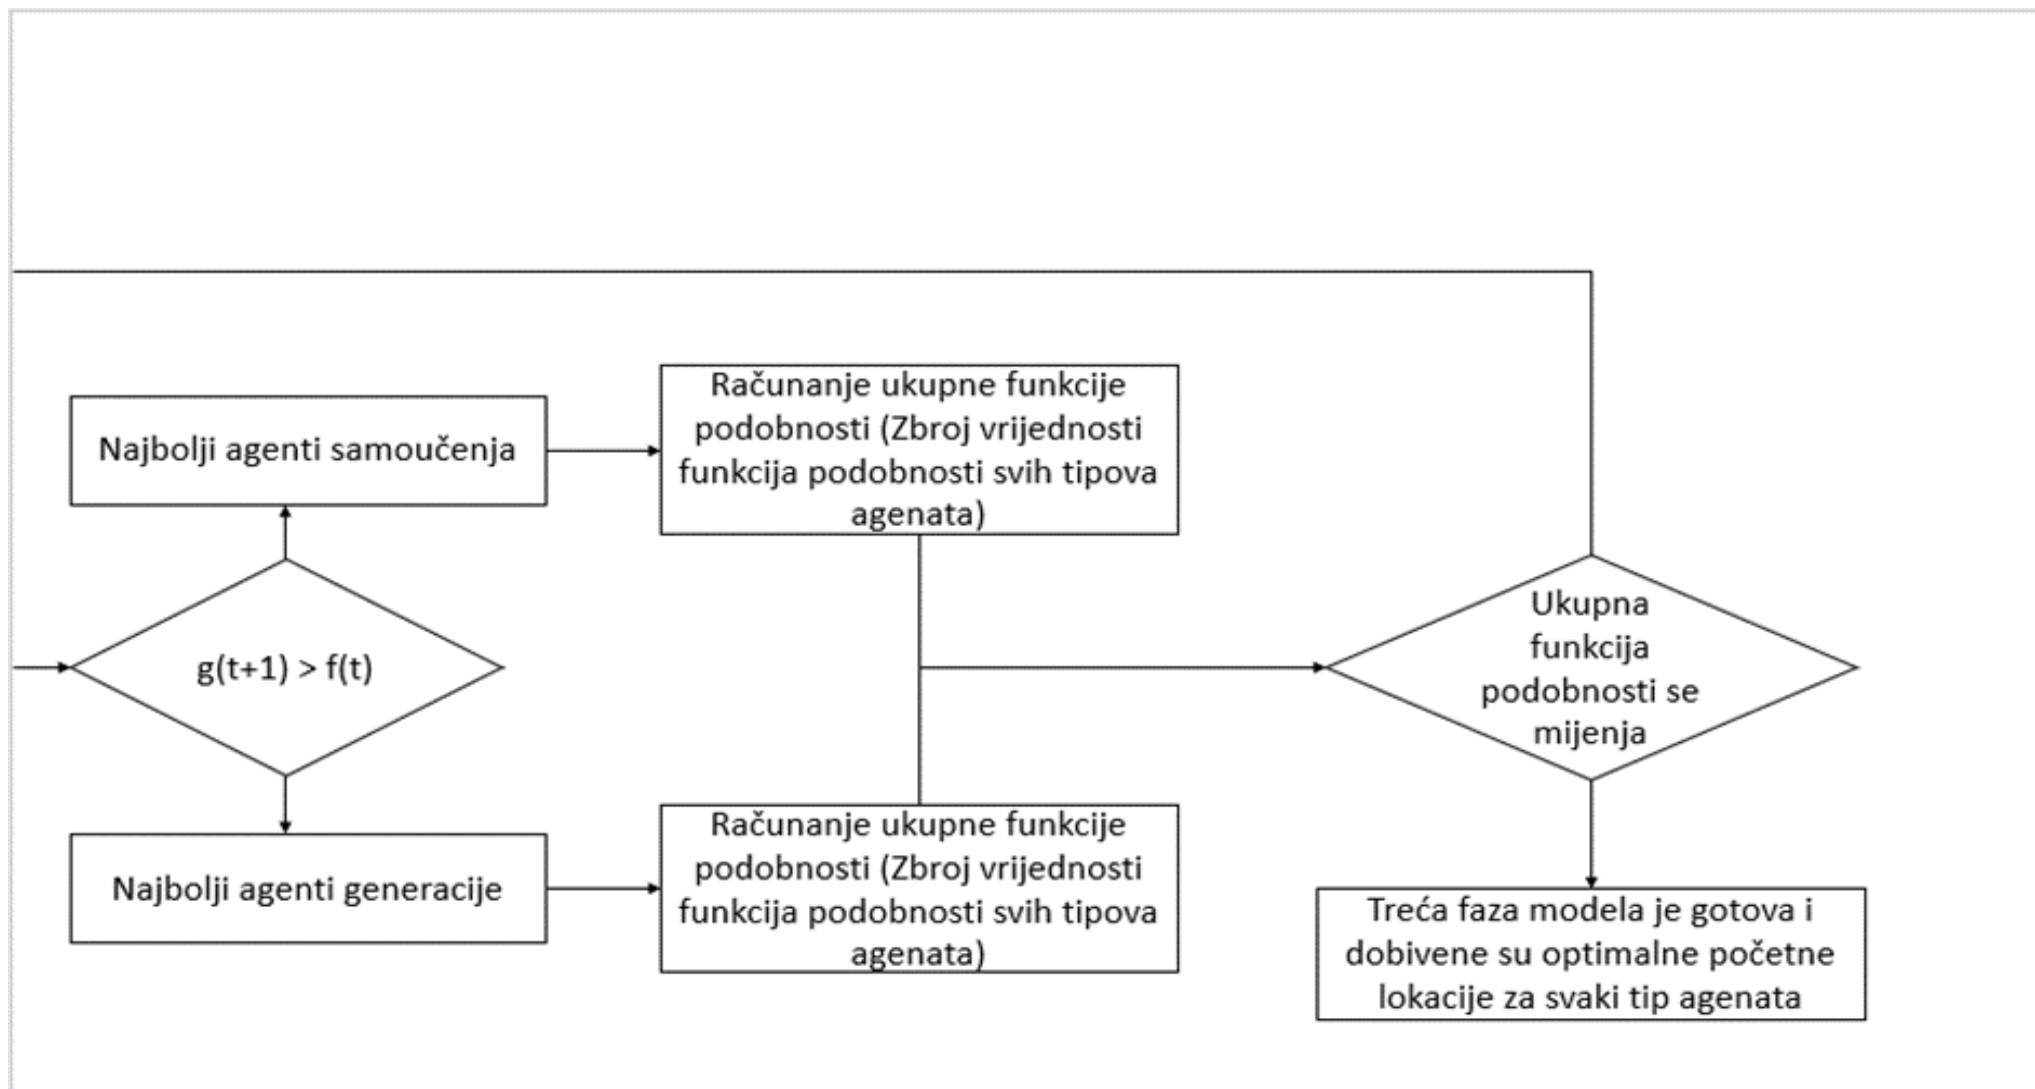
Prilog 12. Udaljenost objekata od najbližeg izgrađenog područja u Gradu Rijeci

Izvor: Izvor 12



Prilog 13. Dijagram toka treće faze modela alokacije (prvi dio)

Izvor: izradio autor prema Zhang, Zeng i Bian, 2010



Prilog 13. Dijagram toka treće faze modela alokacije (drugi dio)


Izvor: izradio autor prema Zhang, Zeng i Bian, 2010

Prilog 14. Lokalni pokazatelji povezanosti funkcionalnih zona unutar funkcionalno-prostorne strukture

Ime	Kratica	Kratki opis (mjerna jedinica)
Ukupna površina funkcionalnih zona	LC	Predstavlja zbroj površina svih ćelija određene vrste funkcionalnih zona (ha)
Udio u funkcionalno-prostornoj strukturi	LP	Udio ćelija iz određene vrste funkcionalnih zona u ukupnom broju ćelija klasificiranog rastera funkcionalno-prostorne strukture (%)
Duljina rubova	EL	Predstavlja ukupnu duljinu granice između svih fragmenata određene funkcionalne zone i fragmenata ostalih zona (m).
Gustoća rubova	ED	Predstavlja zbroj duljina svih rubnih segmenata odgovarajuće vrste funkcionalne zone podijeljen s ukupnom površinom funkcionalno-prostorne strukture (m/ha)
Broj fragmenata	NP	Predstavlja broj identificiranih fragmenata za svaku vrstu funkcionalnih zona (br. frag.)
Gustoća fragmenata	PD	Predstavlja broj fragmenata odgovarajuće vrste funkcionalnih zona podijeljen s ukupnom površinom funkcionalno-prostorne strukture (br./100 ha)
Površina najvećeg fragmenta	GPA	Predstavlja površinu najvećeg fragmenta određene vrste funkcionalne zone (ha)
Površina najmanjeg fragmenta	SPA	Predstavlja površinu najmanjeg fragmenta određene vrste funkcionalne zone (ha)

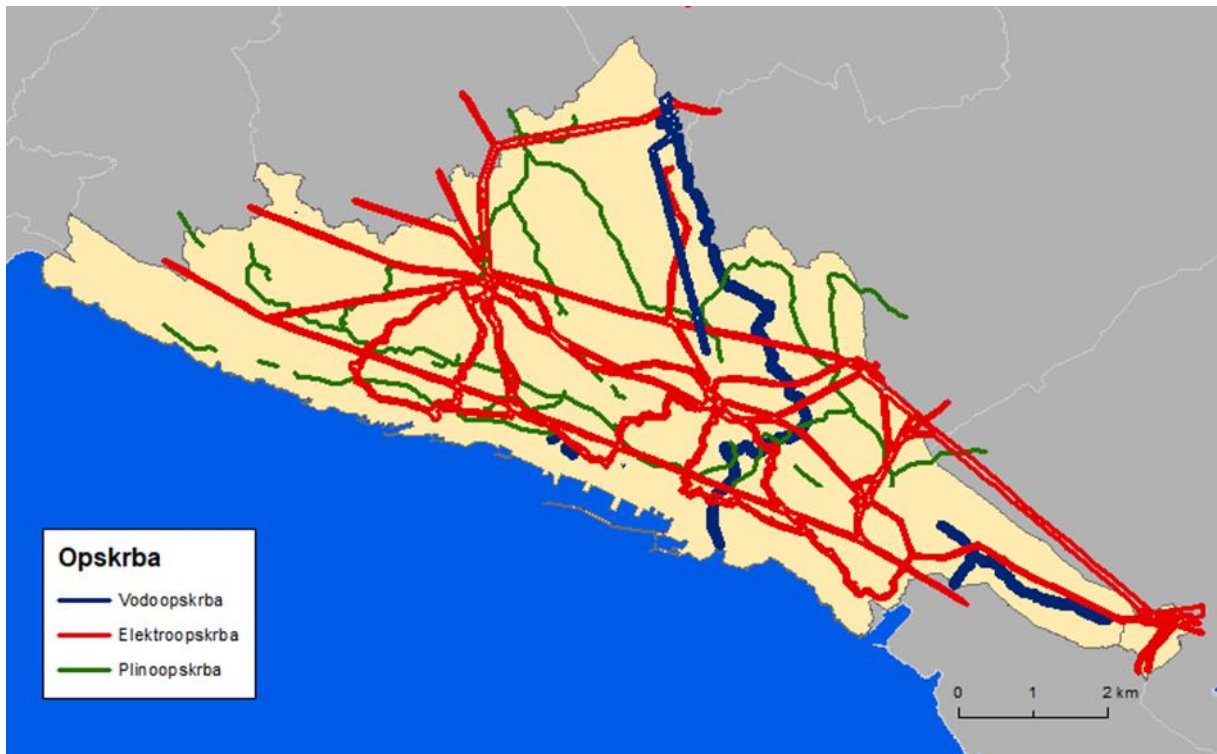
Površina prosječnog fragmenta	MPA	Predstavlja prosječnu površinu fragmenata određene vrste funkcionalne zone (ha)
Prosječna udaljenost fragmenata	MPD	Predstavlja prosječnu euklidsku udaljenost između svih fragmenata iste vrste funkcionalnih zona (m)
Različitost funkcionalno-prostorne strukture	D	Predstavlja vjerojatnost da dvije nasumično odabrane ćelije pripadaju istom fragmentu ($0 \leq D < 1$)
Učinkovitost miješanja	m	Predstavlja vjerojatnost da su dvije nasumično odabrane ćelije međusobno povezane, to jest da su dio istog fragmenta (ha)
Indeks cijepanja	S	Predstavlja broj fragmenata dobiven dijeljenjem ukupne površine određene vrste funkcionalnih zona na više različitih dijelova jednake površine na način da nova konfiguracija predstavlja željeni udio te vrste funkcionalnih zona u funkcionalno-prostornoj strukturi (br.).

Izvor: modificirao autor prema Chelaru, Oiste i Mihai, 2014



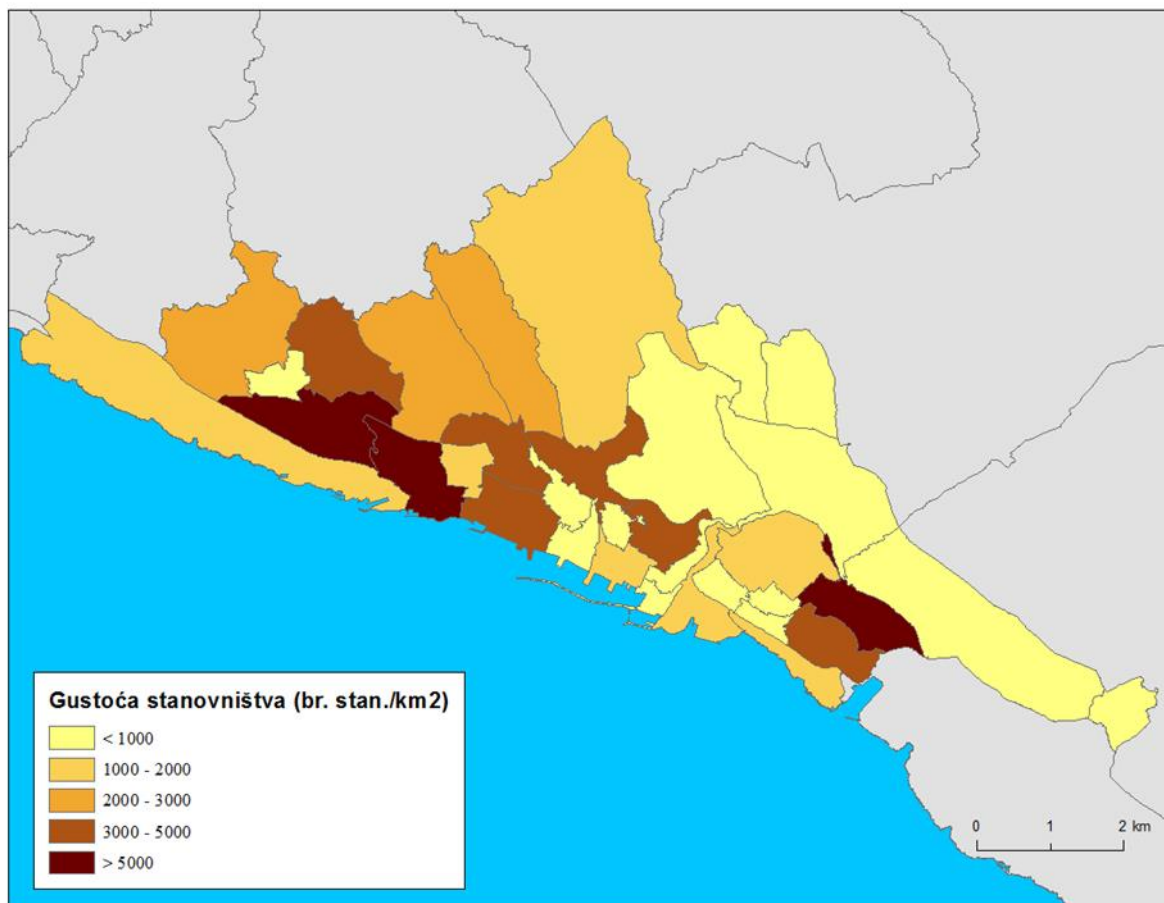
Prilog 15. Udio objekata s funkcijom stanovanja po vrstama i mjesnim odborima u Gradu Rijeci

Izvor: Izvor 12



Prilog 16. Objekti funkcije opskrbe (makro razina) u Gradu Rijeci

Izvor: Izvor 3



Prilog 17. Gustoća stanovništva po mjesnim odborima Grada Rijeke

Izvor: Izvor 13

Prilog 18. Usporedba raznovrsnosti trenutne i potencijalne (dvije varijante) funkcionalne-prostorne strukture Grada Rijeke prema globalnim pokazateljima povezanosti

Godina (Funkcionalno-prostorna struktura)	SHDI	SHEI	SIDI
2019. (trenutna)	0,874	0,543	0,533
2050. (prema modelu promjene)	0,883	0,549	0,540
2050. (prema modelu alokacije)	1,193	0,741	0,657

Prilog 19. Lokalni pokazatelji povezanosti funkcionalno-prostorne strukture Grada Rijeke
2050. godine prema modelu promjene

	LC	LP	EL	ED	NP	PD	GPA	SPA	MPA	MPD	D	m	S
Neodređene zone	19607350	0,451	571340	0,013	250	5,752	4286275	1225	78429,399	4156,189	0,975	1096026,820	39,649
Restriktivne zone	21980175	0,506	543480	0,013	430	9,894	17942575	1225	51116,686	4007,576	0,829	7436939,364	5,843
Stambene zone	687225	0,016	66150	0,002	303	6,972	25725	1225	2268,069	3569,080	0,999	86,570	501984,693
Poslovne zone	325850	0,007	20370	0,001	82	1,887	131075	1225	3973,780	2761,491	0,999	416,586	104316,613
Industrijske zone	856275	0,020	21700	0,001	27	6,213	231525	1225	31713,889	3320,088	0,999	3095,011	14040,943

Prilog 20. Lokalni pokazatelji povezanosti funkcionalno-prostorne strukture Grada Rijeke
2050. godine prema modelu alokacije

	LC	LP	EL	ED	NP	PD	GPA	SPA	MPA	MPD	D	m	S
Neodređene zone	17813950	0,135	273350	0,006	81	1,918	12749800	1225	21925,309	4121,932	0,906	3977554,321	10,618
Restriktivne zone	14627725	0,111	312480	0,007	305	7,221	4111100	1225	47959,754	4227,714	0,984	670335,043	63,007
Stambene zone	5377750	0,041	167510	0,004	200	4,735	1390375	1225	26888,750	4307,862	0,998	67713,245	623,741
Poslovne zone	2807700	0,021	117180	0,003	208	4,925	256025	1225	13498,558	3900,229	0,999	4206,314	10040,988
Industrijske zone	1608425	0,012	72030	0,002	171	4,049	62475	1225	9405,994	3964,190	0,999	945,913	44650,583