

Umjeravanje mikroskopskog prometnog modela primjenom genetskog algoritma

Glibota, Vjeko

Master's thesis / Diplomski rad

2021

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

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:119:811277>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-10-06**



Repository / Repozitorij:

[Faculty of Transport and Traffic Sciences -
Institutional Repository](#)



**SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI**

Vjeko Glibota

**UMJERAVANJE MIKROSKOPSKOG PROMETNOG MODELA
PRIMJENOM GENETSKOG ALGORITMA**

DIPLOMSKI RAD

Zagreb, 2021.

Zagreb, 16. rujna 2021.

Zavod: **Zavod za inteligentne transportne sustave**
Predmet: **Umjetna inteligencija**

DIPLOMSKI ZADATAK br. 6064

Pristupnik: **Vjeko Glibota (0135232412)**
Studij: **Inteligentni transportni sustavi i logistika**
Smjer: **Inteligentni transportni sustavi**

Zadatak: **Umjeravanje mikroskopskog prometnog modela primjenom genetskog algoritma**

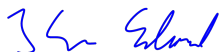
Opis zadatka:

Mikroskopski prometni simulacijski modeli se koriste u svrhu prometnog planiranja, izrade prometnih rješenja i provjeri sustava upravljanja prometnih mreža. Pomoću njih je također moguće napraviti evaluaciju alternativa prometnih rješenja prije njihove same implementacije. U svrhu izrade točne simulacije nužno je prethodno umjeriti simulacijski model primjenom skupa stvarnih prometnih podataka. Jedna od mogućnosti je primjena genetskog algoritma. U radu je potrebno napraviti pregled pristupa za umjeravanje mikroskopskih simulacijskih modela cestovnog prometa s naglaskom na primjenu genetskog algoritma, implementirati genetski algoritam za umjeravanje mikroskopskih prometnih modela te za odabrano semaforizirano raskrižje izraditi umjeren simulacijski model uz pripadnu ocjenu kvalitete.

Zadatak uručen pristupniku: 9. veljače 2021.

Rok za predaju rada: 16. rujna 2021.

Mentor:



izv. prof. dr. sc. Edouard Ivanjko

Predsjednik povjerenstva za
diplomski ispit:

Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

**UMJERAVANJE MIKROSKOPSKOG PROMETNOG MODELA
PRIMJENOM GENETSKOG ALGORITMA**

**MICROSCOPIC TRAFFIC MODEL CALIBRATION USING
THE GENETIC ALGORITHM**

Mentor: izv. prof. dr. sc. Edouard Ivanjko

Student: Vjeko Glibota
JMBAG: 0135232412

Zagreb, rujan 2021.

Zahvale

Ovim putem bih se zahvalio svome mentoru izv. prof. dr. sc. Edouardu Ivanjku na strpljenju i brojnim savjetima za vrijeme studija i izrade ovog diplomskog rada. Zahvalio bih se i kolegi Mladen Miletiću, mag. ing. traff. na vremenu i umjeravanjima prilikom izrade ovog rada. Uz to bih se zahvalio i kolegama u Sjevernoj Makedoniji, posebno Prof. Danieli Koltovskoj Nechoska na pruženim podacima i uputama prilikom izrade ovog diplomskog rada. Zahvalio bih se i obitelji Strelar za podršku, pomoć i razumijevanje tijekom cijelog mog studija. Također, zahvalio bih se svojoj obitelji, pogotovo svojoj majci, na pruženoj potpori, motivaciji i strpljenju.

Sažetak

Naslov: Umjeravanje mikroskopskog prometnog modela primjenom genetskog algoritma

Primjena prometnih modela u današnje vrijeme je postala učestala praksa, a sve češće i poželjna prije bilo kakve implementacije novog prometnog rješenja na terenu, te naknadnog testiranja. Izgradnja dodatne prometne infrastrukture ili bilo kojeg skupog infrastrukturnog zahvata, bez prethodne simulacije budućeg prometnog rješenja može se smatrati arhaičnim i neefikasnim pristupom. Uzimajući u obzir konstantno povećanje zahtjeva cestovnog prometa i nemogućnost predviđanja optimalnog iskorištavanja trenutačnih i budućih kapaciteta. Uz pomoć inteligentnih transportnih sustava se prikupljaju vrijednosti parametara s terena, koji se koriste za umjeravanje prometnog modela. Razvoj računalnih tehnologija i aplikacija su omogućili upotrebu složenih algoritama, poput genetskog algoritma, koji je korišten u ovom radu, prilikom umjeravanja prometnih simulacijskih modela. Točnije, genetski algoritam je korišten za umjeravanje prometnog toka svakog pojedinog privoza unutar raskrižja, a za to je korišten PTV VISSIM simulacijski program unutar kojeg se vršila simulacija, povezana s programskim jezikom Python putem COM veze. Umjeravanje je uspjelo po ciklusu od jednog sata optimizirati prometni tok, ovisno koliko se razlikuju ulazne vrijednosti od izlaznih prometnih tokova odabranog izoliranog raskrižja, koje bi trebale biti približno iste ili iste. Kod umjeravanja modela u ciklusu od 24 sata, umjeravanje simulacije je ovisilo o omjeru ulaznih i izlaznih vrijednosti vozila za svaki pojedini sat. Strojno učenje koristeći genetski algoritam je trajalo u periodu od par sati za jedan sat, do četiri dana za period od 24 sata. Kod perioda od 24 sata, svaki veći omjer broja vozila za pojedini sat, za svaki privoz može rezultirati neprihvatljivim vrijednostima funkcije dobrote, što na kraju generira lošija rješenja. Prilikom manjeg volumena prometnog toka po privozu i kraćih ciklusa, poput jednog sata, modul genetskog algoritma generira optimalna rješenja za taj ciklus, u odnosu za period od cijelog dana, gdje koeficijenti privoza odstupaju izvan granica prihvatljivih okvira.

Ključne riječi: Inteligentni transportni sustavi, umjeravanje prometnog modela, genetski algoritam, mikroskopska simulacija prometa, izolirana raskrižja, strojno učenje.

Abstract

Title: Microscopic traffic model calibration using the genetic algorithm

Application of traffic models nowadays has become a common practice, and is preferable before any implementation of new traffic solutions on the field, and subsequent testing. The construction of additional transport infrastructure or any expensive infrastructure intervention, without prior simulation of a future transport solution can be considered an archaic and inefficient approach. Taking into account the constant increase of road traffic demands, the impossibility of predicting the optimal use of current and future capacities. With the help of intelligent transport systems, the values of parameters from the terrain are collected, which are then used to calibrate the traffic model. The development of computer technologies and applications has enabled the use of complex algorithms while calibrating traffic simulation models. Genetic algorithm is used in this master's thesis to calibrate the traffic flow of each individual approach within the intersection, and for this, PTV VISSIM simulation program was used. Within VISSIM the simulation was performed, associated with Python programming language via COM connection. The calibration was able to optimize the traffic flow in one hour interval, depending on how different the input values are from the output traffic flows of the selected isolated intersection, which should be approximately the same. When calibrating the model in a 24-hour cycle, the calibration of the simulation depended on the ratio of vehicle input and output values, for each individual hour. Initiated machine learning using a genetic algorithm lasted for a couple of hours, for an one hour simulation, to four days for an 24-hour simulation. Within a period of 24 hours, any higher ratio of vehicle numbers per hour, for each approach can result in unacceptable values for the fitness function, which ultimately generated poorer solutions. With a smaller volume of traffic flow per approach and shorter cycles, such as one hour, the genetic algorithm module generates optimal solutions, compared to the period for the whole day, where the coefficients for every approach deviated beyond acceptable limits.

Keywords: Intelligent transport systems, traffic model calibration, genetic algorithm, microscopic traffic simulation, isolated intersection, machine learning

Sadržaj

1. Uvod	1
2. Primjena mikroskopskih simulacijskih modela	4
2.1. Općenito o mikroskopskim simulacijskim modelima	4
2.2. Pouzdanost mikrosimulacijskog modela	6
3. Pregled pristupa umjeravanju prometnih simulacijskih modela	7
3.1. Ciljevi umjeravanja	7
3.2. Pristupi umjeravanja	9
3.3. Predloženi pristup umjeravanju	11
4. Genetski algoritam i umjeravanje prometnih simulacijskih modela	12
4.1. Funkcija dobrote	13
4.2. Genetski operatori	13
4.2.1. Selekcija	14
4.2.2. Križanje	14
4.2.3. Mutacija	16
4.3. Evaluacija genetskog algoritma	16
5. Implementacija genetskog algoritma za umjeravanje mikroskopskih simulacijskih modela	17
5.1. Upotreba genetskog algoritma za potrebe umjeravanja	18
5.2. Definiranje funkcije dobrote	20
6. Simulacijski rezultati	22
6.1. Simulacijsko sučelje	23
6.2. Općenito o prometnom modelu	25
6.3. Analiza rezultata simulacije	27
6.3.1. Umjeravanje satnog perioda	28

6.3.2.	Umjeravanje dnevnog perioda koristeći neumjerene vrijednosti ulaznih tokova	30
6.3.3.	Umjeravanje dnevnog perioda koristeći umjerene vrijednosti ulaznih tokova	33
7.	Zaključak	37
	Popis literature	40
	Popis ilustracija	42
	Popis tablica	44

1. Uvod

Povećan i kontinuirani rast cestovnog prometa, i prometa općenito, rezultira zagušenjima u prometu, samim time povećanjem kašnjenja, buke, onečišćenja, prometnih nesreća, te ostalih negativnih utjecaja na korisnike i okolinu. Takvi slučajevi su najčešći upravo u gradskim sredinama, gdje postoji kontinuirani rast korisnika cestovnog prometa. Efikasnijim upravljanjem prometnom infrastrukturom mogu se umanjiti negativni utjecaji ne ispunjavanja zahtjeva cestovnog prometa, što predstavlja jedno od rješenja prilikom nastojanja da se prometni tok optimizira. Kao alat za evaluaciju koriste se prometne simulacije za buduća prometna rješenja ili strategije.

Mikroskopski prometni simulacijski modeli su modeli koji uzimaju u obzir jedan dio prometne mreže poput raskrižja, dionice ili nekog drugog dijela prometne infrastrukture u svrhu planiranja i evaluacije rješenja, posebno u slučajevima u kojima je provedba na terenu teško izvediva ili skupa. Takva vrsta alata, osim u prometnom inženjerstvu se koristi i u analizi upravljanja, jer je simulacija jednostavniji, ekonomičniji i brži način provjere pri implementaciji pojedinog prometnog rješenja.

Razvojem novijih tehnologija, raznih aplikacija i računalne snage, omogućilo se rješavanje prometnih zadataka u kraćem periodu u odnosu na prethodno vremensko upitne procese poput ručnog brojanja prometa, pa i samog računanja. Da bi računanje takvih zadataka rezultiralo zadovoljavajućim rješenjem, trebaju se koristiti vjerodostojni podatci, dobiveni sa terena, te da je odstupanje tih istih podataka što manje od stvarne prometne situacije. Da bi se dobili takvi podatci, koriste se pouzdani načini prikupljanja, poput inteligentnih transportnih sustava, na temelju kojih se može dobiti približno stanje na dijelu prometnice. Prema [1], ITS se može definirati kao holistička, upravljačka i informacijsko-komunikacijska(kibernetska) nadogradnja klasičnoga sustava prometa i transporta kojim se postiže znatno poboljšanje performansi, odvijanje prometa, učinkovitiji transport putnika i robe, poboljšanje sigurnosti u prometu, udobnost i zaštita putnika, manja onečišćenja okoliša, itd.

Koristeći dobivene podatke moguće je prikazati stvarnu prometnu situaciju pomoću simulacijskog modela. Takvi modeli koriste različite parametre, koji koriste poznate podatke da bi prikazali pojedinu prometnu situaciju ili proces približan onome na terenu. Mikroskopski simulacijski modeli sadržavaju brojne neovisne parametre da bi opisali upravljanje prometnim

operacijama unutar simulacije poput karakteristika prometnog toka, ponašanja vozača za pojedino područje, prilagođavanja brzine prilikom skretanja i slično. U nekim slučajevima, kao što je u ovom diplomskom radu, koristimo poznate vrijednosti, da bismo dobili parametre bitne za usmjeravanje vozila unutar raskrižja. Simulacijski modeli koriste različite parametre koje je potrebno umjeriti u svrhu što vjerodostojnijeg prikaza prometne simulacije. Vrijednosti za pojedine parametre trebaju biti iste kao u stvarnoj prometnoj situaciji, ili barem približne, ovisno o svrsi pojedine prometne simulacije i podacima koje posjedujemo. U tom slučaju korištenje simulacijskih modela se može smatrati testiranjem optimalnosti pojedinih prijedloga nadogradnje klasičnog sustava prometa i transporta. U tu svrhu je izrazito važno koristiti umjereni simulacijski model.

Optimizacijskim metodama poput genetskog algoritma koji je korišten u ovom radu, gdje se koristi velik broj podataka prilikom umjeravanja, mogu se naći rješenja za izrazito teške zadatke u kratkom periodu, što opet ovisi o zahtjevima. Na temelju optimiziranog simulacijskog modela koji bi trebao biti bolji u odnosu na početni, mogu se donositi bolje i kvalitetnije odluke, stoga je umjeravanje parametara ključna komponenta bilo kakvog uspješnog prometnog modela. Neki od daljnjih koraka mogu biti nadogradnja postojeće infrastrukture, izmjena tehnologije na prometnoj infrastrukturi, podešavanje signalnog plana ili neki drugi postupci kojima se može poboljšati prometni proces poput protoka vozila, sigurnosti, harmonizacije itd.

Cilj ovog rada je predložiti i ocijeniti opći postupak umjeravanja mikroskopskih simulacijskih modela koristeći se genetskim algoritmom. Valjanost predloženog postupka ocijenjeno je i prikazano korištenjem studija slučaja s aktiviranim signaliziranim raskrižjem pomoću široko rasprostranjenog mikroskopskog simulatora cestovnog prometa, VISSIM.

Ovaj diplomski rad je podijeljen u sedam poglavlja. Nakon uvoda je u drugom poglavlju opisan način primjene mikroskopskih simulacijskih modela, načina korištenja, unosa parametara, mogućnosti primjene, te same pouzdanosti simulacijskog modela. Upravo je umjeravanje navedeno kao bitan postupak za generiranje pouzdanog simulacijskog modela. U sklopu trećeg poglavlja je opisan postupak umjeravanja modela, te pristup kojim bi se generiralo optimalno rješenje parametara. Cilj umjeravanja je usklađenje između vrijednosti modela i mjerenja s terena. Uz to su prikazane ulazne i izlazne vrijednosti vozila na privozima odabranog izoliranog raskrižja, koje se razlikuju za neprihvatljiv broj vozila, ali su svakako korištene za umjeravanje modela. Četvrto poglavlje objašnjava genetski algoritam, te njegovu implementaciju u svrhu generiranja općenitog optimalnog rješenja. U petom poglavlju je objašnjena implementacija

genetskog algoritma za diplomski rad, objašnjenje programskog kôda unutar Pythona, te način povezivanja postojećeg modula upravljanja simulacijom s VISSIM simulacijom u svrhu optimiziranja koeficijenata raspodjele prometnih tokova za pojedine privoze raskrižja. Unutar šestog poglavlja su rezultati simulacija, analize grafova, dobivenih vrijednosti, odnosi funkcija dobrote za pojedine simulacije, i geni ili rješenja za svaku pojedinu simulaciju. U sedmom poglavlju je naveden zaključak, uz prijedlog postojećih proširenja postojećeg algoritma, poboljšanja podataka za umjeravanje poput brzine, te ostalih parametara koji su vezani uz umjerene vrijednosti, vjerodostojnost generiranog modela i vrijednosti sa terena.


2. Primjena mikroskopskih simulacijskih modela

Prema [2], mikroskopski simulacijski modeli simuliraju pojedinačna kretanja vozila i njihove interakcije u pruženoj okolini na osnovu čega se procjenjuju prometne performanse pojedinog cestovnog sustava. Modeli simulacije prometa učinkoviti su i moćni alati za simulaciju sustava i upravljanje tokovima prometa. Njihova glavna prednost je omogućavanje evaluacije alternativnih prometnih rješenja prije njihove provedbe, odnosno implementacije, te prikaz simulacije u uvjetima koje bi bilo teško promatrati u stvarnom svijetu, a da se korisnici ne podvrgnu izrazitim neugodnostima ili opasnostima, koje bi takvi testovi mogli uzrokovati. Povećana upotreba mikrosimulacijskih modela u transportnom inženjerstvu i planiranju rezultirala je evolucijom i sofisticiranosti mikrosimulacijskih modela. Mikrosimulacija može prometnom inženjeru pružiti korisne i vrijedne informacije o izvedbi postojećeg prometnog sustava i prikazati moguća poboljšana, ali isto tako može biti aktivnost koja oduzima puno vremena i resursa. Simulacijski modeli su sada naširoko u upotrebi za planiranje, projektiranje, upravljanje mrežama autocesta i inteligentnih transportnih sustava. Korištenje simulacija zahtijeva opsežno znanje o samom modelu i njegovim ograničenjima, kao i izvrsno razumijevanje teorije prometnih tokova na kojima se model zasniva [2], [3].

2.1. Općenito o mikroskopskim simulacijskim modelima

Mikroskopske prometne simulacije se sve više i učestalije primjenjuju za evaluaciju dizajna transportnih sustava, prometnih operacija i alternativnih mogućnosti upravljanja. Simulacija je jeftina, bez nepotrebnog rizika i s neusporedivom brzinom implementacije u odnosu na stvarna rješenja. Kao što je prepoznato prema Priručniku o kapacitetu autocesta (engl. Highway Capacity Manual - HCM) [4], simulacija postaju vrijedan alat u procjeni prometnog rješenja, te se pomoću istih simulacija mogu prikazati pojedini parametri i vrijednosti koji se ne mogu prepoznati pomoću tradicionalnog planiranja ili analizom modela. Još jedan od razloga popularnosti simulacijskih modela su atraktivne animacije, stohastička varijabilnost za snimanje prometnih uvjeta u stvarnom svijetu i sposobnost modeliranja složenih geometrijskih kolnika što je vidljivo na slici 1. Pod složenim modeliranjem smatramo sustave gradskih ulica i autocesta,

pješačkih površina, tehnologije upravljanja i informiranja koje se mogu implementirati poput semaforiziranog raskrižja i slično [5]. Osim navedenih primjera mikrosimulacije su prihvaćene za procjenjivanje određenih veličina, koje nisu jednostavne za procijeniti ili izmjeriti na terenu. Neke od njih su kvaliteta zraka, potrošnja goriva, uzročnici prometnih nesreća ili potencijalnih rizika u prometu i prihodi od cestarina. Simulacijski alati se mogu iskoristiti za tehnologije poput inteligentnih transportnih sustava, te usporedbu takvog rješenja u odnosu na klasična rješenja poput proširenja prometnice ili usmjeravanja postojećeg toka prometa [6].



Slika 1: Primjer 3D vizualizacije mikrosimulacije

Kod sve veće primjene prometnih simulacijskih alata i u svrhu evaluacija, bitna je vjerodostojnost same mikrosimulacije. Potencijalne poteškoće prilikom generiranja simulacija zapravo su same simulacije, točnije koliko su približne generirane vrijednosti bliske u odnosu na stvarnu situaciju. Modeli pružaju mogućnost uvida u vrijednosti pojedinih parametara koji su odgovorni za prethodno navedene karakteristike, ali i izmjena istih vrijednosti u svrhu prilagodbe pojedinih prometnih uvjeta [5]. Većina mikroskopskih simulacijskih modela zahtjeva različite vrste parametara, koji bi mogli opisati karakteristike prometnog toka, upravljačkog prometnog sustava, ponašanja prilikom vožnje i slično. Osnovni ulazni parametri poput geometrije, broja vozila, i postavki prometnih signala su jednostavni za izmjeriti. Međutim, neke od umjernih parametara koji su povezani s ponašanjem vozača, nije moguće prikupiti na terenu. Zbog toga je uobičajena praksa da se koriste unaprijed zadane vrijednosti omogućene od strane korisnika mikroskopskog simulacijskog modela ili minimalno umjereni model temeljen na procjeni inženjera. S obzirom da je dokazano da simulacijski modeli pod unaprijed zadanim postavkama ne moraju točno prikazati stanje na terenu, samim time postoji mogućnost generiranja nepouzdanih rezultata [7].

2.2. Pouzdanost mikrosimulacijskog modela

Proces prilagođavanja i finog podešavanja parametara modela korištenjem realističnih podataka koji održavaju lokalne prometne uvjete je umjeravanje modela. Analize zasnovane na simulacijskim modelima često se izvode sa zadanim postavkama vrijednosti parametara ili ručno prilagođenim vrijednostima. Postupak strogog umjeravanja modela se često izostavlja jer zahtijeva mnogo vremena kao i ogromnu količinu terenskih podataka. Nalazi i zaključci zasnovani i na neumjerenim ili neprikladno umjerenim modelima mogu biti zavaravajući, pa čak i pogrešni. Zaključak je taj da je ispravno umjeravanje ključni korak u simulacijskim aplikacijama [5].

Da bi se postigla odgovarajuća pouzdanost simulacijskih modela, ključno je primjeniti rigorozan postupak umjeravanja, prije provođenja bilo kakvog proučavanja ili analiza. Promjene parametara tijekom umjeravanja moraju biti obranjive i opravdane od strane inženjera ili korisnika zaduženog za umjeravanje. Glavni razlog umjeravanja je upravo razumno podudaranje između podataka s terena i rezultata simulacijskog modela [5]. Dokazano je da početne granične vrijednosti umjerenih parametara ne sadrže optimalno rješenje, pa samim time simulacijski model ne može biti umjeren, i ako optimizacijska metoda pronađe optimalno rješenje unutar područja pretrage. To je očito, zbog područja pretrage koji ne uključuje uvjete na terenu. Iako je takav pristup uspješno testiran na izoliranom signaliziranom raskrižju [7], poželjno je testirati umjeravanje takvih modela unutar veće prometne mreže.

3. Pregled pristupa umjeravanju prometnih simulacijskih modela

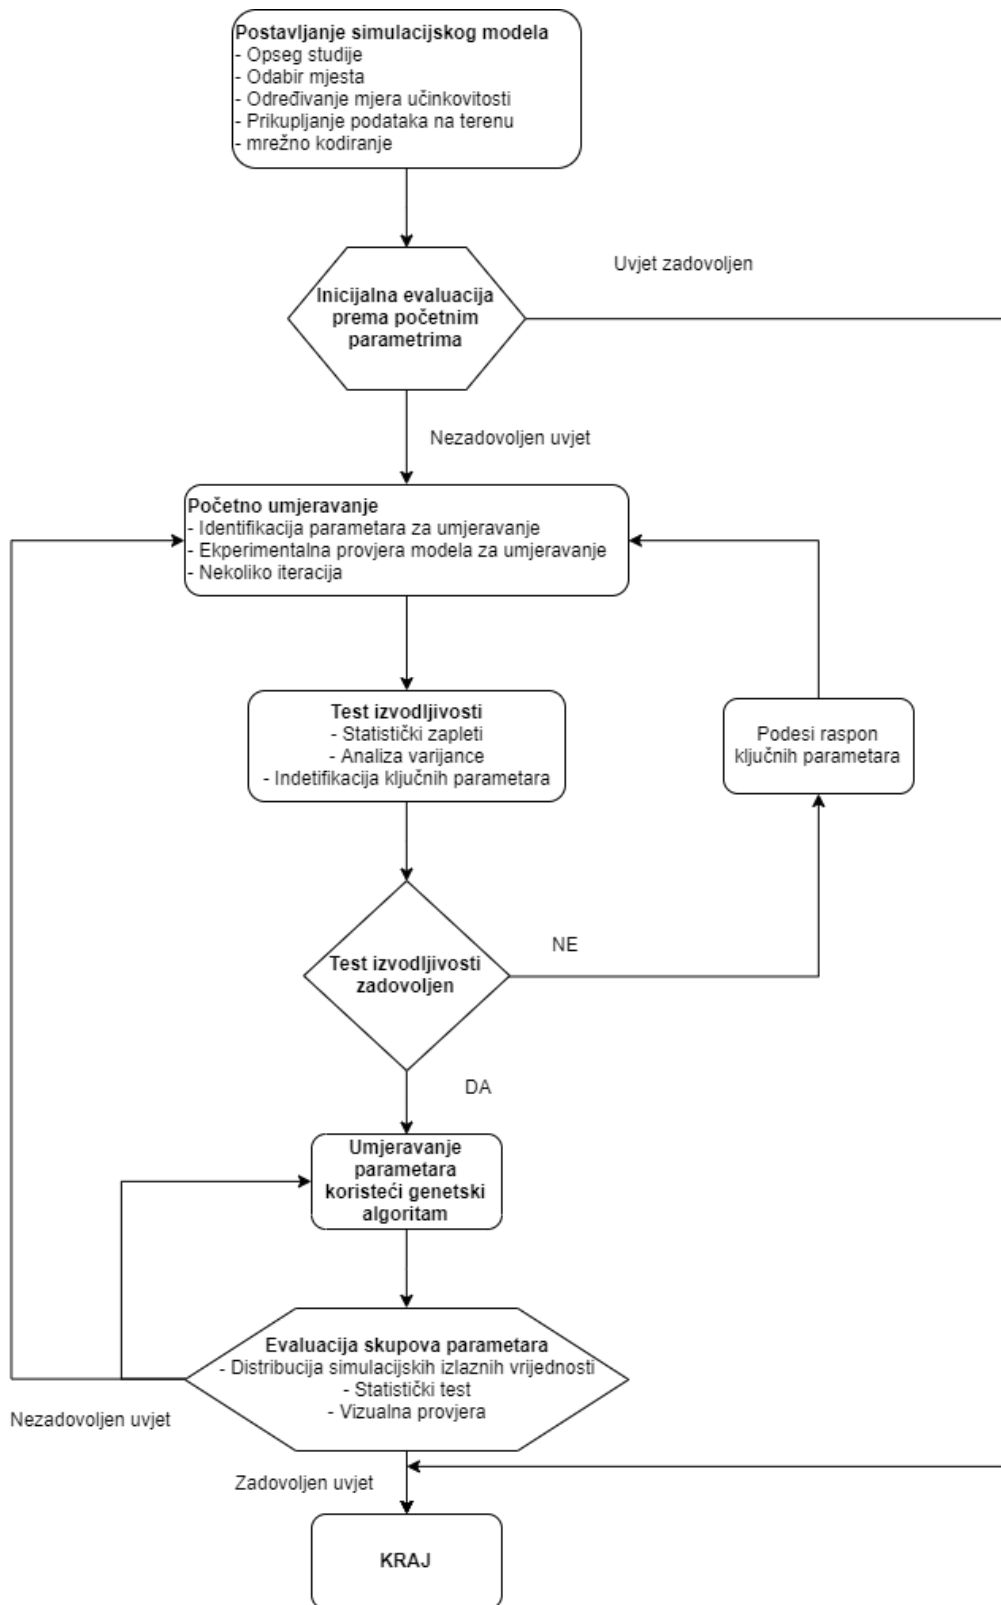
Umjeravanje je proces kroz koji inženjer ili neki drugi korisnik simulacijskog alata podešava parametre modela, uspoređuje rezultate simulacije s empirijskim podacima i provjerava mogućnost simulacijskih modela za optimalan prikaz promatranog prometnog toka. Stručnjaci zaduženi za razvoj simulacijskog modela unose zadane vrijednosti parametara modela, koji odražavaju podatke korištene pri provjeri valjanosti korištene programske podrške. Prilikom primjene modela na druge regije nužno je umjeravanje parametara modela kako bi se poboljšala reprezentacija simulacije sukladno osobitosti suučesnika u prometu i vrsti vozila koja se koriste [5].

Metoda korištena u ovom radu za umjeravanje mikrosimulacijskog modela je upravo metoda koja se zasniva na načelima evolucije i prirodne selekcije, a to je genetski algoritam. Prednosti su generiranje rješenja s više točaka, čime se povećava vjerojatnost pronalaska globalnog, umjesto lokalnog optimuma. Iz tog razloga je korisno za probleme sa složenim prostorom za pretraživanje, kao što je slučaj prometnog toka simulacije. Genetski algoritam je uspješno primijenjen na mnoge aspekte prometnog inženjerstva, kao što su simulacijsko modeliranje protoka prometa, vrijeme trajanja prometnog signala, te planiranje za održavanje infrastrukture i slično [5].

3.1. Ciljevi umjeravanja

Cilj umjeravanja modela je postići najbolje moguće usklađenje između procjena performansi modela i mjerenja performansi na terenu. Postoje ograničenja količine vremena i truda koje svatko može uložiti u uklanjanje pogrešaka u modelu. Umjeravanje je odrađena minimizacijom razlike između simulirane i promatrane vrijednosti broja vozila koja ulaze i izlaze iz raskrižja. Da bi simulacijski modeli bili ispravno podešeni, potrebno je umjeravanje i validacija modela. Umjeravanje modela je definirana kao proces kod kojeg individualna komponenta simulacijskog modela je podešena ili prilagođena tako da model može točno reprezentirati izmjerene vrijednosti ili promatrane prometne uvjete. Komponente parametara simulacijskog modela koje zahtijevaju umjeravanje uključuju operacija upravljanja, karakteristike prometnog

toka i ponašanje vozača. Umjeravanje modela se ne bi trebalo zamijeniti s validacijom, odnosno provjerom točnosti modela. [6]. Pristup rješavanja jednog takvog zadatka je vidljiv na dijagramu na slici 2.



Slika 2: Pristup umjeravanja prometnog mikroskopskog modela, [5]

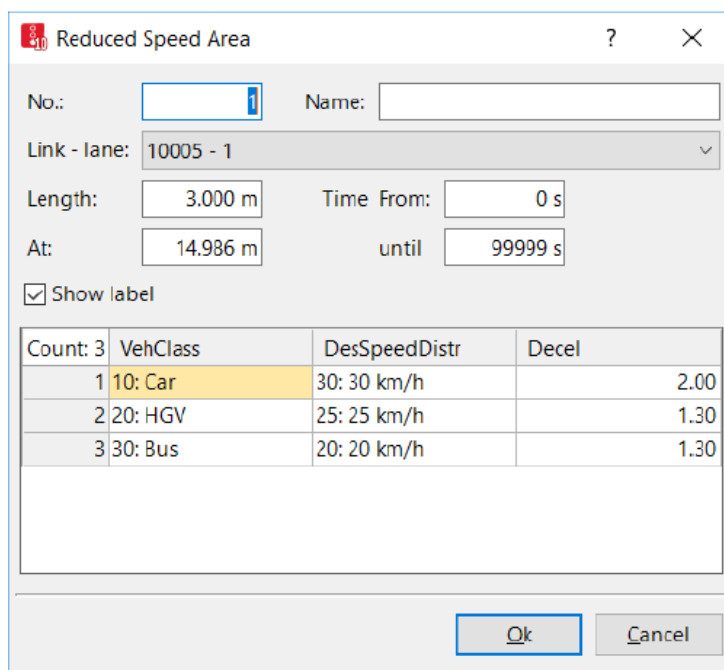
Validacija modela testira točnost modela uspoređujući vrijednosti prometnog toka generirane modelom s vrijednostima dobivenih s terena koje su vidljive u tablici ulaza 1, i tablici izlaza 2. Validacija je direktno povezana sa procesom umjeravanja zato što su prilagodbe prilikom umjeravanja nužne za poboljšanje sposobnosti modela za repliciraju prometne uvjete sa terena. Proces umjeravanja se može opisati kao proces koji sadrži sedam koraka komponenti [6]:

- a) Definiranje ciljeva i zadataka studija;
- b) Određivanje potrebnih terenskih podataka;
- c) Odabir mjera učinkovitosti;
- d) Utvrđivanje kriterija ocjenjivanja;
- e) Zastupljenost prometne mreže;
- f) Ponašanje usmjeravanja upravljačkog programa;
- g) Ocjenjivanje izlaza modela.

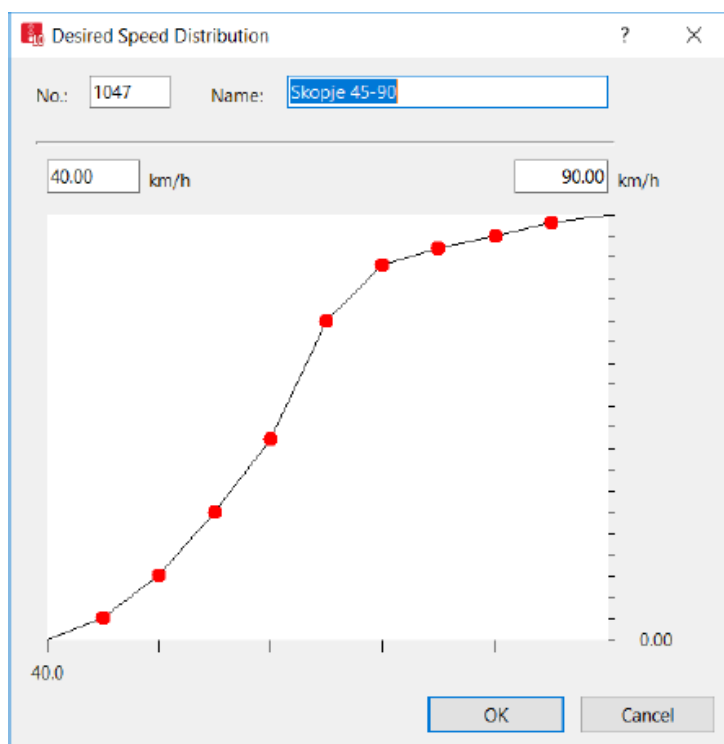
Ovaj proces pruža osnovne smjernice, ali ne daje izravni postupak provođenja umjeravanja i validacije.

3.2. pristupi umjeravanja

Dvije grupe parametara zahtijevaju umjeravanje u simulaciji prometnog modela, a to su parametri ponašanja u vožnji, i parametri ponašanja pri putovanju. Neke od parametara, koji su podešeni u mikroskopskom simulatoru VISSIM za diplomski rad, mogu se vidjeti na slikama 3 i 4, gdje je podešena distribucija brzine u području od 40 do 90 km/h i područja sa smanjenom brzinom koja su postavljena na mjesta usmjeravanja vozila unutar raskrižja, zbog sigurnosti i autentičnosti modela. Model za slijeđenje vozila je podešen kao *Wiedemann*⁷⁴ model. Navedeni parametri su umjereni prema uputama kolega iz Sjeverne Makedonije specifično za njihovo područje.



Slika 3: Područje reducirane brzine prilikom skretanja u raskrižju



Slika 4: Željena distribucija brzine

Ponašanje u vožnji još uključuje ubrzanje, promjenu trake i modele raskrižja. Ponašanje pri putovanju predstavljeno je izborom rute modela. Tokovi polazišta i odredišta, ili O-D matrica, su važne ulazne vrijednosti u simulacijski model, s time da zbog prostornog opsega aplikacije, O-D matrica, posebno dinamička, nije lako dostupna, tako da ulazni O-D tokovi moraju biti

procijenjeni [8].

Pristupi umjeravanju obično navode rješavanje ovakvog problema putem optimizacije, gdje se parametri prometnog modela nastoje minimizirati koristeći ciljnu funkciju, izmjerom razlike između simulacijskog rezultata i mjerenja na terenu. Zbog stohastike mikrosimulacije i kompliciranog odnosa između parametara i njihovog rezultata, teško je izračunati gradijent funkcije. Iz tog razloga znanstvenici koriste heurističke metode za pretragu optimalnih vrijednosti parametara. Neki od njih su genetski algoritam, simulirano prekaljivanje, kompleksni algoritam pa čak i, pokušaj i nabrojanje grešaka. Navedene metode automatiziraju proces umjeravanja do neke granice, te je činjenica da poboljšavaju simulaciju u odnosu na postavke početnih vrijednosti [9].


3.3. Predloženi pristup umjeravanju

Umjeravanje uključuje pregled i prilagodbu brojnih parametara modela, od kojih svaki utječe na rezultate simulacije. Neki od tih parametara koji su bitni u ovom diplomskom radu su obujam vozila na ulazu u raskrižje, usmjeravanje vozila unutar raskrižja, distribucija brzine, područja reducirane brzine, razmak slijeđenja itd. Čovjek je faktor koji je često u korelaciji sa ostalim parametrima. Prilikom umjeravanje se lako naći u beskonačno iterativnom procesu, umjeravajući jedno odstupanje, da bi se pronašlo veće odstupanje negdje drugdje. Iz tog razloga je bitno razbiti postupak umjeravanja u niz logičkih, uzastopnih koraka za umjeravanje. Parametri modela se moraju podijeliti u kategorije i svakom kategorijom se mora posebno baviti. Dostupno umjeravanje parametara u koje je analitičar siguran da ne želi umjeravati, i parametre u koje je manje siguran da ne treba umjeravati, prema čemu je nužna nekakva vrsta prilagodbe [2]. U ovom diplomskom radu je zbog velike razlike u podacima ulaza i izlaza vozila iz raskrižja bilo nužno osim umjeravanja postojećih vrijednosti vidljivo u tablici 1, napraviti umjeravanje sa približnim ulaznim i izlaznim vrijednostima da se provjeri funkcionalnost genetskog algoritma te njegova efikasnost na jednom takvom primjeru.

4. Genetski algoritam i umjeravanje prometnih simulacijskih modela

Genetski algoritam (GA), koji je stvoren od strane John H. Hollanda, je metoda pretraživanja koja se zasniva na načelima evolucije i prirodne selekcije [3]. Pod pojmom GA podrazumijevaju se postupci traženja i optimiranja koji pripadaju većoj skupini evolucijskih algoritama (EA) [10].

Postoje dva koncepta upravljanja genetskim algoritmom, a to su generacijski i eliminacijski GA. Generacijski GA je skup rješenja koji se može u svakoj iteraciji potpuno izmjeniti, dok eliminacijski GA može zadržati najbolja moguća rješenja u svakoj iteraciji. Stohastički (slučajno) pretražuje prostor rješenja na osnovu "prirodnog" izbora najsposobnijih kandidatnih rješenja [11], kao što je prikazano na slici 5.



Slika 5: Osnovni ciklus genetskog algoritma, Izvor: <https://www.diagrameditor.com/>

Razvoj umjetne inteligencije se jako oslanja na primjeni načela živih organizama, gdje isti promatraju učenje kao natjecanje među populacijom od kandidata koji teže ka rješenju problema. Funkcija dobrote (engl. fitness function) evaluira svako rješenje na temelju kojeg se odlučuje da

li će doprinosti sljedećoj generaciji rješenja. Na osnovu toga operacijama analognima transferu gena kao kod reprodukcije, algoritam kreira novu populaciju kandidata koji reprezentiraju potencijalna rješenja [11] [12], prikazano na slici 5.

4.1. Funkcija dobrote

Populacija jedinki predstavlja skup postojećih rješenja problema za optimizaciju, dok se nova rješenja problema kreiraju iz postojećih rješenja. Jedan od primjera su dva roditelja ili dva rješenja, iz čega se generiraju dva nova rješenja kao njihova djeca. Dok kriterijska funkcija ili funkcija dobrote određuje kvalitetu pojedinog rješenja rangirajući ih, te odabirući najbolja rješenja. Svaki sljedeći skup rješenja bi na temelju toga trebao biti bolji u odnosu na prethodni. Genetski algoritam inicijalizira početnu populaciju prema uzorcima kandidata u populaciji. Obično je inicijalna populacija postavljena slučajno. Evaluacija kandidata pretpostavlja funkciju dobrote u tom trenutku. Čest slučaj izračuna dobrote kandidata je testiranje na setu za treniranje, čime vraća postotak točne klasifikacije. Koristeći takvu funkciju dobrote, evaluacija je dodijeljena svakom kandidatu [13].

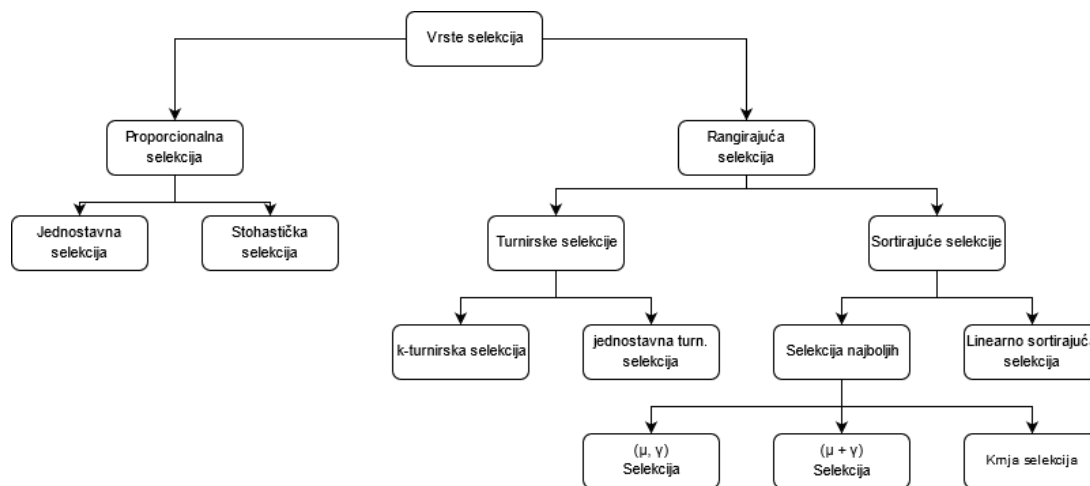
Prilikom ciklusa genetskog algoritma, te generiranih novih rješenja i odabira najboljih, primjenjuju se genetski operatori na odabrana rješenja uz provjeru ispravnosti novog rješenja. Upravo u tom dijelu ciklusa genetskog algoritma se vrši većina umjeravanja generiranih rješenja koji nastoje doći do globalnog optimuma [11].

4.2. Genetski operatori

Nakon evaluacije svakog kandidata, algoritam odabire par kandidata za rekombinaciju. Rekombinacija koristi genetske operatore da bi se generirali nova rješenja koji kombiniraju komponente njihovih roditelja. U slučaju prirodne evolucije, dobrot kandidata određuje opseg kandidata koji se reproducira, s time da kandidati s najvećim evaluacijama imaju najveću vjerojatnost reprodukcije. Seleckija je prema navedenom često vjerojatnosna, gdje slabiji član ima manju vjerojatnost za reprodukciju, ali nisu odmah eliminirani. Neki od kandidata s manjom funkcijom dobrote prežive, jer postoji mogućnost da sadržavaju bitnu komponentu rješenja, poput dijela gena, čime reprodukcija predstavlja funkciju koja bi trebala sačuvati to rješenje [12].

4.2.1. Selekcija

Selekcija je proces odabira rješenja genetskog algoritma u svrhu očuvanja dobrih rješenja, te odbacivanja loših rješenja, gdje su vrste selekcija vidljive na slici 6. U procesu selekcije se često koristi elitizam koji čuva najbolja rješenja [11].




Slika 6: Vrste selekcija genetskog algoritma, Izvor: <https://www.diagrameditor.com/>

Jednostavna selekcija se ujedno i naziva metoda ruleta, gdje vjerojatnost pojedinog rješenja ovisi o iznosu dobrote jedinke. Određujući kumulativnu dobrotu, te omjer dobrote jedinke i ukupne dobrote populacije, generira se N slučajnih brojeva i odabire se rješenje u čiji je interval kumulativne dobrote upao generirani broj. Neučinkovita prilikom malih razlika u kvaliteti rješenja [11].

U diplomskom radu se koristi bitna turnirska selekcija, gdje se slučajnim odabirom određenog broja rješenja radi turnir među njima, čime se odbacuje najlošije rješenje ili odabire najbolje. Jednostavan turnir je između dva rješenja, dok K -turnirska selekcija radi turnir između k rješenja, [11]

4.2.2. Križanje

Postoji određen broj genetskih operatora koji generiraju potomstvo koji imaju značajke njihovih roditelja, a najčešći je upravo operator križanja, koji imitira prirodnu spolnu reprodukciju. Križanje odabire dva kandidata rješenja i dijeli ih, zamjenjujući komponente da bi generirao dva nova kandidata. Slika 7 prikazuje križanje sa n -točaka prekida, s obzirom da ne možemo znati o kojim će se točno genima raditi koji će se križati, te koliko će biti točaka prekida [11] [12].



Slika 7: Križanje s n-točaka prekida, [11]

Križanjem se postiže brza konvergencija optimumu, te postoji opasnost da optimizacija završi u lokalnom optimumu, što je povezano sa zadržavanjem dobrih svojstava roditelja. Od križanja se koriste:

1. Uniformno križanje;
2. Križanje S n-točaka prekida;
3. Aritmetičko križanje;
4. Heurističko križanje.

Uniformno križanje je primjer gdje svako dijete sadržava pola gena pojedinog roditelja. Dok je križanje s n točaka prekida, slučajno, te se odabiru jedno ili više mjesta mjesta križanja, gdje je prikazano na slici 7 primjer križanja sa dvije točke prekida. Osim navedenih vrsta križanja imamo i aritmetičko križanje koje se koristi kod prikaza rješenja u obliku realnih brojeva, što je vidljivo na formuli ispod. Parametar a je slučajni težinski koeficijent iz intervala $[0, 1]$, i određuje koliko će utjecaja na pojedino dijete imati pojedini roditelji [11].

$$\text{Dijete 1} = a * \text{roditelj1} + (1-a) * \text{roditelj2}_{(1)}$$

$$\text{Dijete 2} = (1-a) * \text{roditelj1} + a * \text{roditelj2}_{(2)}$$

Heurističko križanje se koristi kod prikaza rješenja u obliku realnih brojeva, a križanje se obavlja kako je vidljivo na u formuli ispod, gdje je parametar r slučajni težinski koeficijent $[0, 1]$. Moguća pojava problema je moguća kod kreiranja prvog djeteta, jer se može naći izvan intervala pretraživanja rješenja. Nakon n pokušaja generiranja koeficijenta r , lošiji roditelj postaje Dijete 1 [11].


$$\text{Dijete 1} = \text{bolji roditelj} + r * (\text{bolji roditelj} - \text{lošiji roditelj})_{(3)}$$

$$\text{Dijete 2} = \text{bolji roditelj}_{(4)}$$

5. Implementacija genetskog algoritma za umjeravanje mikroskopskih simulacijskih modela

Pomoću genetskog algoritma se simulira proces prirodne evolucije, s mogućim rješenjima koji predstavljaju pojedince u populaciji mogućih rješenja. Početna populacija generira se nasumično, pri čemu se mjeri pojedinačna razina prilagodbe okolišu (kvaliteta rješenja) koja se mjeri prema već spomenutoj funkciji dobrote. Ta populacija se sprema u listu rješenja prilikom simulacija, te se svakom novom simulacijom umjerava pomoću funkcije dobrote. Ti pojedinci su predstavljeni nizovima, ili točnije kromosomima koji predstavljaju individualne karakteristike, gene. Svaki gen predstavlja jedan parametar umjeravanja, u slučaju optimizacije, jednu varijablu rješenja. Zaključak je da je skup parametara koji generiraju rješenje, kromosom, a populacija je skup kromosoma. Optimizacija se sastoji u stvaranju uzastopnih generacija pojedinaca. U svakoj novoj generaciji stvaraju se novi pojedinci iz prethodne generacije pomoću procesa selekcije i reprodukcije radi razmjene genetskog materijala. Upravo je to način na koji se generira dvanaest novih rješenja svakom novom simulacijom za statično usmjeravanje vozila. Koriste se i drugi genetski operatori već prethodno navedeni, poput mutacije koja je prisutna u jednom od 12 gena prilikom svake iteracije, za uvođenje varijabilnosti, te novih rješenja u genski fond. Mutacija se koristi za nasumičnu izmjenu nekih gena u populaciji rješenja, pošto se može dogoditi da postojeći geni ne sadrže optimalno rješenje, čime bi mutacija trebala proširiti pretragu [3]. To bi trebalo potaknuti već postojeća rješenja da uvedu rješenje kojih nema u postojećoj populaciji od dvanaest statičnim usmjeravanja vozila. U ovom diplomskom radu se pojedino rješenje generira na način da postoji zadanih 12 usmjeravanja vozila unutar raskrižja, ili točnijeg naziva, statično usmjeravanja vozila koje možemo vidjeti na slici 9. Svako pojedino usmjeravanja predstavlja jedan gen, jedno statično usmjeravanje vozila. Prilikom pokrenutog modula, generiraju se nova rješenja na temelju funkcije dobrote, koja se računa na osnovu GEH statistike za svaki pojedini privoz. To rezultira time da svaki pojedini privoz ima 3 usmjeravanja vozila: lijevo, ravno i desno. Modul genetskog algoritma generirajući nova rješenja, prelazi područje pretrage tražeći globalni optimum, koristeći se upravo operatorima da bi dobio ta ista rješenja. U slučaju ovog zadatka svaki privoz je povezan sa drugim na način da povećanjem koeficijenta rješenja za

pojedino statično usmjeravanja vozila može rezultirati zagušenjem na određenom dijelu dionice. Ti koeficijenti nikad ne prelaze u desetice, uvijek su na jedinicama, zbog jake konvergencije u slučaju prevelikog koeficijenta. Razlog tome je priroda PTV VISSIM-a koji bi za vrijednosti usmjeravanja trebao zbirno imati koeficijent jedan za pojedini privoz, gdje se osnovica može malo promjeniti prilikom umjeravanja. Dobar primjer je ako GA prilikom optimizacije povećava koeficijent usmjeravanja vozila za skretanje lijevo, dolazi do zagušenja na prometnici jer većina vozila želi skrenuti lijevo, a signalni plan i kapacitet prometne infrastrukture to ne dozvoljavaju. Iz tog razloga se javljaju velike oscilacije GEH statistike za privoze s velikim priljevom vozila poput Jane Sandanski SZ - JI i obratno, što je vidljivo na slici 19 i prilikom umjeravanja za period od cijelog dana. Genetski algoritam upravo umjerava statično umjeravanje vozila za svako skretanje, na svakom pojedinom privozu, koristeći prethodno navedene operatore i funkciju dobrote.




Slika 9: Statično usmjeravanje vozila unutar raskrižja s pripadajućim kraticama

5.1. Upotreba genetskog algoritma za potrebe umjeravanja

Za potrebe umjeravanja simulacije prometnog modela korišten je PyGAD modul, Python knjižnica otvorenog kôda za izgradnju genetskog algoritma i optimizaciju algoritama strojnog učenja. Modul radi s modulima Kerasom i PyTorchem, otvorenim izvorom okvira, drugim riječima skupom alata nužnim za izradu stranica, korisničkih sučelja, aplikacija i slično. PyGAD

podržava različite vrste operatora, križanja, mutacije i odabira roditelja, te omogućuje optimiziranje različitih problema pomoću genetskog algoritma prilagođavanjem funkcije dobrote [14].



Slika 10: Ciklus genetskog algoritma prema PyGAD modulu, [15]

Jedan od procesa koji je korišten je elitizam, sastoji se od odabira pojedinaca koji su najbolje prilagođeni okolišu za reprodukciju, kako bi se osiguralo nasljeđivanje najboljih osobina na potomke istih pojedinaca. U ovom radu u procesu selekcije se upravo koristi proces selekcije, koji čuva najbolje rješenje [3] [11]. Proces implementacije genetskog algoritma je vidljiv na slici 10, skupa sa svim operatorima, i omogućenim funkcijama. Prilikom generiranja svakog

pojedinih kromosoma, osim navedenih operatora koristimo i Prilikom umjeravanja koristio se elitizam, u čijem se slučaju čuvaju dobra rješenja, što je vidljivo iz generiranih rješenja, koja se sačuvana i nakon N iteracija. Osim elitizma prilikom selekcije, kod križanja se koristilo križanje s dvije točke prekida, da bi se izbjegla zadržavanja u lokalnom optimumu i po mogućnosti išlo prema globalnom optimumu. U istu svrhu se koristila mutacija, gdje je podešeno da prilikom mutacija barem jedan gen (rješenje) bude podvrgnuto mutaciji koja može biti jednostavna i mijesajuća, ovisno kako se modul odluči. Razlog je pretraga područja za boljim rješenjima.

Kromosom, ili skup rješenja, se sastoji od 12 gena, koji predstavljaju 12 koeficijenata koji se koriste za usmjeravanje vozila pojedinih privoza. Postavljajući ih unutar postojećeg modula kao vrijednosti usmjeravanja vozila prilikom skretanja, te pokrećući simulaciju prometnog modela u svrhu generiranja funkcije dobrote, svaka sljedeća iteracija se umjerava upravo na dobivenoj dobroti funkcije.

5.2. Definiranje funkcije dobrote

U svrhu umjeravanja svakog privoza, za period od jednog sata je generirana GEH statistika za svaki privoz. GEH statistika je koeficijent ili točnije omjer između dvostruke, kvadratne razlike obujma prometa prometnog modela i stvarnog obujma, u odnosu na zbroj omjera stvarnog obujma prometa i modela, što je vidljivo na sljedećoj formuli. Ukratko riječ je o predstavljanju prikladnosti modela, gdje se uzima u obzir apsolutna razlika i postotna razlika između modeliranih i promatranih protoka. Cilj je postići najbolje moguće podudaranje između procjena performansi modela i vrijednosti izmjerenih na terenu. Međutim, postoji ograničenje količine vremena i truda koji svatko može uložiti u uklanjanje pogrešaka u modelu. Stiže se do točke gdje velika napori ne rezultiraju poboljšanom točnošću, pa čak i suprotno. Iz tog razloga stručnjak ili analitičar koji se bavi sa umjeravanjem mora znati kada treba stati [2]. GEH statistika se izračunava na sljedeći način:

$$GEH_j = \sqrt{2(x_i - y_i)^2 / (x_i + y_i)} \quad (5)$$

gdje je X obujam prometa po satu iz modela prometa (generirani obujam iz modela), a Y je broj sati prometa u stvarnoj situaciji (izmjereni obujam). Trebalo bi napomenuti da GEH statistika nije bez jedinica, već ima jedinice (vozila/sat), pošto su X i Y , obujam vozila po satu, te da

nije statistički test, već empirijska formula koja se koristi za niz analiza prometa. Dobiveni koeficijent putem GEH formule treba biti ispod 5 za 85 posto zasebnih privoza, čime se zaključuje da umjereni mikrosimulacijski model sa više od 25 posto zasebnih privoza koji imaju GEH koeficijent iznad 5 sje zapravo nevjerodostojan [16].

U svrhu izrade ovog diplomskog rada, simulacija je izvršena za raskrižje sa četiri privoza, te je svaki privoz imao 3 zasebna prometna toka. Svaki od tih prometnih tokova, ili koeficijenata rješenja koji se nastoje optimizirati putem GA se moralo umjeriti upravo koristeći se GEH statistikom ili funkcijom dobrote. Prilikom računanja toka izlaznih privoza, bilo je nužno umjeriti svaki prilazni tok, ali na način da pri umjeravanju se uzima zbroj svih vozila koja ulaze u taj pojedini izlazni privoz, te se uspoređuje s vrijednosti koja je dana od strane kolega iz Sjeverne Makedonije. Upravo, koristeći se tim vrijednostima, model se umjeravao računajući GEH statistiku za svaki pojedini izlazni privoz.

Zbrojem GEH statistike koja je za svaki izlazni privoz bila zasebna, se računala ukupna GEH vrijednost za cjelokupno raskrižje. Daljnim dijeljenem broja jedan sa tom vrijednošću se dobivala funkcija dobrote, koja se koristila za umjeravanje cjelokupnog GA koristeći se još ostalim operatorima. Prilikom umjeravanja koristio se elitizam, u čijem se slučaju čuvaju dobra rješenja, što je vidljivo iz generiranih rješenja, koja se sačuvana i nakon N iteracija. Osim elitizma prilikom selekcije, kod križanja se koristilo križanje s dvije točke prekida, da bi se izbjegla zadržavanja u lokalnom optimumu i po mogućnosti išlo prema globalnom optimumu. U istu svrhu se koristila mutacija, gdje je podešeno da prilikom mutacija barem jedan gen(rješenje) bude podvrgnuto mutaciji koja može biti jednostavna i miješajuća, ovisno kako se modul odluči. Razlog je pretraga područja za boljim rješenjima.

6. Simulacijski rezultati


U ovom poglavlju analiziraju se rezultati umjeravanja pojedinih privoza, u periodu od 24 sata. Ujedno je prikazan i prometni model koji je korišten, skupa s pripadajućim signalnim planom, te umjerenom simulacijom s prihvatljivim ulaznim vrijednostima u odnosu na podatke na terenu, gdje je primjećeno povećanje odstupanja u odnosu na prvo umjeravanje. Prethodno spomenuto raskrižje je vidljivo na slici 11, s pripadajućim privozima, te je označeno crvenim kvadratom na karti grada Skopja, prikazano na slici 12.



Slika 11: Prikaz raskrižja na karti sa pripadajućim ulicama,
Izvor:<https://www.openstreetmap.org/edit#map=17/41.98817/21.46190>

Prema karti, prikazane vrijednosti u tablicama 1 i 2 prikazuju obujam prometa po svakom privozu unutar raskrižja, gdje se na tablicu 1 odnose vrijednosti tokova ulaznih privoza, a na

tablicu 2 vrijednosti tokova izlaznih privoza. Velika razlika od više od 7.000 vozila između ulaznih i izlaznih privoza rezultira upravo simulacijama koje su nevjerodostojne. Samim time prilikom generiranja funkcije dobrote, uzima se vrijednost koja ne može u potpunosti umjeriti naš model da bude optimalan u odnosu na stvarno stanje u prometu. Iz tog razloga je napravljeno umjeravanje modela tokom cijelog dana koristeći se navedenim podacima iz tablica, da bi se prikazala neefikasnost u slučaju velikog odstupanja izlaznih i ulaznih tokova privoza 12.



Slika 12: Prikaz raskrižja na karti grada Skopja,
Izvor:<https://www.openstreetmap.org/edit#map=13/41.9988/21.4480>


Iz tog razloga je također generirana tablica koja uspoređuje razlike zbroja privoza po satu, i na temelju omjera izlaznih i ulaznih tokova u tom vremenskom periodu, generira se koeficijent, kojim je pomnožem svaki privoz za taj pojedini vremenski interval. Time je dobivena tablica koja ima približne vrijednosti kao izmjereni izlazni tokovi privoza, čime se želi prikazati umjeravanja modela u slučaju odličnog omjera izlaznih i ulaznih tokova privoza, što je i vidljivo u tablici 3.

6.1. Simulacijsko sučelje

Algoritam za umjeravanje broja vozila za pojedine prometne privoze izrađen je u programskom jeziku Python, verziji 3.9.5, koji je povezan sa simulacijskim programskim alatom VISSIM, putem VISSIM COM (engl. Component Object Model) [17] sučelja vidljivo na slici 13.

Tablica 1: Tablica vrijednosti tokova ulaznih privoza iz raskrižja Jane Sandanski, ASNOM Bulevard i Vasko Karangelski za period od jednog dana

Interval[s]	Asnom	Vasko Karangelski	J. Sandanski SZ - JI	J. Sandanski JI - SZ
3600	38	54	238	137
7200	31	30	115	74
10800	19	15	55	38
14400	7	8	39	17
18000	9	17	33	23
21600	21	26	46	54
25200	130	58	209	253
28800	636	342	576	1.393
32400	495	295	718	937
36000	384	315	753	765
39600	355	314	883	757
43200	416	349	914	812
46800	396	347	980	760
50400	382	355	1.058	736
54000	450	380	1.149	837
57600	395	468	1.389	836
61200	444	470	1.749	837
64800	410	391	1.570	808
68400	307	300	1.022	724
72000	428	294	998	695
75600	286	221	790	631
79200	171	178	614	502
82800	123	150	564	366
86400	91	89	439	232
Ukupno	6.424	5.466	16.901	13.224



Slika 13: Prikaz COM sučelja

potrebe pokretanja genetskog algoritma korišten je PyGAD modul [14], putem kojeg se zadaju vrijednosti poput broja generacija, broja rješenja, vrste selekcije, postotak mutacije, broj gena

Tablica 2: Tablica vrijednosti tokova izlaznih privoza iz raskrižja Jane Sandanski, ASNOM Bulevard i Vasko Karangelski za period od jednog dana


Interval[s]	Asnom	Vasko Karangelski	J. Sandanski SZ - JI	J. Sandanski JI - SZ
3600	33	115	168	209
7200	34	54	103	102
10800	15	37	60	42
14400	9	16	27	34
18000	9	21	30	37
21600	33	36	67	39
25200	95	145	367	145
28800	367	531	1.964	517
32400	337	470	1.426	642
36000	358	483	1.120	698
39600	418	470	1.092	816
43200	475	505	1.159	898
46800	498	491	1.173	993
50400	552	535	1.049	1.024
54000	487	616	1.148	1.074
57600	502	711	1.103	1.374
61200	561	866	1.142	1.572
64800	272	875	1.029	1.311
68400	167	522	902	983
72000	168	532	1.052	927
75600	120	385	873	793
79200	108	289	636	597
82800	119	266	460	500
86400	56	175	312	376
Ukupno	5.793	9.146	18.462	15.703

u kromosomu, funkcije dobrote i slično [15]. Nakon postavljanja vrijednosti, cjelokupna se simulacija pokreće unutar funkcije dobrote, koja generira GEH statistiku ili drugim riječima našu funkciju dobrote na temelju usporedbe generiranog modela i stvarne situacije. Svakom iteracijom postižu se nova rješenja, te nove vrijednosti funkcije dobrote, koja umjerava tražene vrijednosti ka optimalnom rješenju.

6.2. Općenito o prometnom modelu


U ovom radu se koristi simulacijsko modeliranje protoka prometa, dobivenih vrijednosti iz Sjeverne Makedonije, u gradu Skopje, na križanju Jane Sandanski, Vasko Karangelski i ASNOM Bulevard. Za potrebe rada napravljen je prometni model koristeći se PTV VISSIM simulacijskim softverom, unutar kojeg je napravljen model istoimenog raskrižja vidljivog na slici 15. Osim

izrađenog modela bilo je nužno prilagoditi signalni plan za navedeno raskrižje da protok vozila za vrijeme volumno najvećeg vršnog sata može biti harmoniziran. U tu svrhu je uzet signalni plan dobiven od kolega iz Ureda za upravljanje prometom grada Skopja, Sjeverna Makedonija, te je uzet jedan ciklus signalnog plana za isto raskrižje u periodu jutarnjeg vršnog sata.



Slika 14: Prikaz izrađenog VISSIM modela raskrižja u Skopju

Prilikom pokretanja simulacije, broj vozila koji bi bili generirani kao pogreška prilikom pokrenute simulacije bio je zanemariv, čime je zaključeno da je korišteni fiksni signalni plan, vidljiv na slici 14, prihvatljiv. Ujedno je utvrđeno prilikom izvođenja i pregleda simulacije da je prometni tok harmoniziran, bez velikih zagušenja, izuzev perioda vršnog sata.



Slika 15: Fiksni signalni plan za raskrižje Jane Sandanski, Vasko Karangelski i ASNOM Bulevard

Broj vozila koji je zadan za ulaz, te izlaz iz raskrižja po svakom pojedinom privozu je zaprimljen također, od kolega iz Sjeverne Makedonije. Uz pomoć tih vrijednosti je rađeno umjeravanje prometnog modela, čime se moglo usporediti realistične vrijednosti raskrižja, s vrijednostima generiranih iz modela. Mogući problem prilikom umjeravanja korištenjem genetskog algoritma je upravo razlika između broja vozila koja ulaze i koja izlaze iz raskrižja. Prema dobivenim podacima razlika nije bila zanemariva, te je zaključeno da će se ulazne vrijednosti približno podesiti prema vrijednostima izlaza. Iz tog razloga generirana je umjerena simulacija za točne podatke s terena, te simulacija s podešenim ulaznim brojem vozila.

6.3. Analiza rezultata simulacije

Prilikom generiranja rezultata simulacije, svakom iteracijom se umjeravaju koeficijenti privoza unutar raskrižja, na način da se uspoređuje broj vozila generiranih iz modela za svaki pojedini privoz i podataka dobivenih s terena, u satnom periodu za cijeli dan.

U svrhu analize rezultata umjerene su vrijednosti s terena u kojima postoji razlika od 7.000 vozila čime se nastojalo pokazati umjereni model na temelju genetskog algoritma, ali s prisutnom greškom.

Osim podataka s terena, umjereni su isti podatci broja vozila po svakom privozu na osnovu

omjera ulaznog broja vozila u raskrižja sa izlaznim brojem vozila, za svaki sat. Na osnovu toga dobiveni su približne vrijednosti ulaznih i izlaznih broja vozila iz raskrižja što je vidljivo u tablici ukupnih ulaznih vrijednosti.

Tablica 3: Tablica umjerenog broja vozila koja ulaze u raskrižje u odnosu na tablicu 1

Interval[s]	Asnom	Vasko Karangelski	J. Sandanski SZ - JI	J. Sandanski JI - SZ
3600	43	61	268	154
7200	36	35	135	87
10800	23	18	67	46
14400	8	10	47	21
18000	11	20	39	27
21600	25	31	55	64
25200	150	67	242	293
28800	729	392	660	1.597
32400	582	347	844	1.102
36000	461	378	903	918
39600	430	380	1.069	917
43200	507	425	1.114	990
46800	503	441	1.245	966
50400	477	443	1.321	919
54000	531	449	1.357	988
57600	472	559	1.660	999
61200	525	556	2.069	990
64800	450	429	1.722	886
68400	336	328	1.118	792
72000	475	326	1.107	771
75600	322	249	890	711
79200	190	198	683	559
82800	138	168	631	409
86400	98	96	474	251
SUM	7.522	6.406	19.720	15.457


Kada se navedene vrijednosti usporede s izlaznim vrijednostima, razlika je za jedno vozilo, te se htjela provjeriti pouzdanost umjerenog modela sa indentičnim brojem vozila na ulazu i izlazu, s vrijednostima koje su dobivene od kolega iz Sjeverne Makedonije.

6.3.1. Umjeravanje satnog perioda


U svrhu provjere modula koji je korišten prilikom umjeravanja prometnog mikrosimulacijskog modela, trebalo je testirati moguće postavke operatora, ali i provjeru umjeravanja putem postojeće funkcije dobrote koristeći se modelom koji traje jedan sat. Koristeći prethodno prikazani model [15] i vrijednosti iz tablica 1 i 2, kao ulazne i izlazne vrijednosti tokova privoza,

pokrenuto je umjeravanje modela koje je u prosjeku završavalo kroz par sati, te kojim bi GEH bio unutar zadovoljavajućeg intervala. Uzet je interval u periodu od 00:00h do 01:00 zbog jednostavnosti primjene i brzine optimizacija. GEH vrijednosti su vidljive na slici 16, dok su rješenja generirana na slici 18. Kumulativnu funkciju dobrote prikazanu na slici 17, za cjelokupno raskrižje kod svakog najboljeg rješenja za vrijeme pojedine simulacije, prihvati samo najbolje rješenje, ili već postojeće najbolje rješenje. Zbog toga je broj generacija na slici 17 prikazan u manjem broju, u odnosu na cjelokupnu populaciju za period umjeravanja mikrosimulacijskog modela. To vrijedi i za sve ostale koeficijente dobrote.

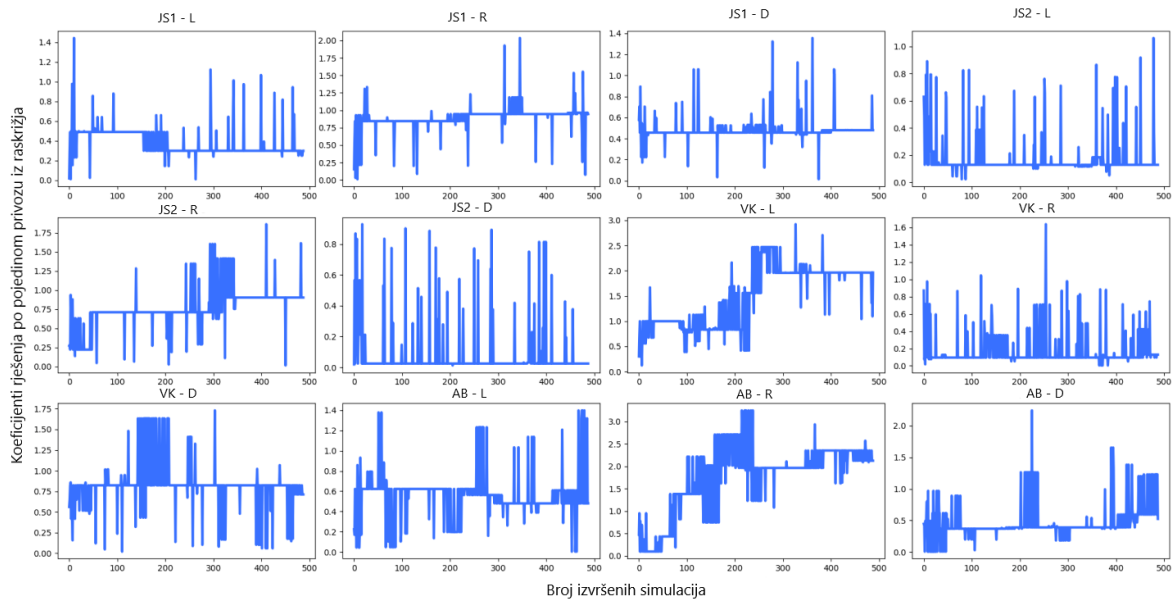
Umjereni model je dao zadovoljavajuće rezultate GEH statistike po privozima što je vidljivo na slici 16 na samom kraju, a rješenja se mogu iščitati iz slike 18 gdje krajnji rezultati po pojedinom grafu prikazuju najbolje rješenje.



Slika 16: GEH statistika svih ispitanih rješenja po pojedinom privozu za period od jednog sata, (umjereni broj vozila koja ulaze u raskrižje)



Slika 17: Najbolje vrijednosti funkcije dobrote za period od jednog sata, (umjereni broj vozila koja ulaze u raskrižje)



Slika 18: Pojedinačna vrijednost gena za svako rješenje, za period od jednog sata, (umjereni broj vozila koja ulaze u raskrižje)


6.3.2. Umjeravanje dnevnog perioda koristeći neumjerene vrijednosti ulaznih tokova

Kod umjeravanja dnevnog perioda koristeći podatke s terena kod kojih postoji velika razlika između ulaznog i izlaznog broja vozila, očekivano je da će funkcija dobrote ili kumulativna GEH statistika biti nezadovoljavajuća. Razlog tome je višak od 7.000 automobila kod izlaznog obujma iz raskrižja, zbog kojeg nikada nećemo imati vjerodostojnu mikroskopsku simulaciju. Umjeravanje jednog takvog modela je odrađeno jer se htjela prikazati stvarna situacija u prometu u kojoj imamo greške prilikom brojanja. Logično je na temelju toga zaključiti da će postojati odstupanja u stvarnim situacijama u prometu u kojima sudjeluje gotovo 50.000 vozila unutar jednog raskrižja. Osim tog razloga, postoji i potreba usporedbe takvog modela sa modelom koji ima približno iste ulazne i izlazne vrijednosti unutar raskrižja. Cilj je usporediti umjereni model i statično usmjeravanje vozila za svaki pojedini privoz u odnosu na realne podatke, i u odnosu na model s idealnim uvjetima na ulazu i izlazu iz raskrižja.


Na slici 19 se može vidjeti GEH statistika za generacije od svake odrađene simulacije. Prilikom pokrenutog modula, generira se 8 novih rješenja za svaku simulaciju, od kojih se jedno odabire na temelju funkcije dobrote svog privoza: JS1, JS2, VK i AB, slika 20. Jedno to rješenje sadrži 12 koeficijenata koji su zapravo naša statična usmjeravanja vozila, koji mogu biti decimalne vrijednosti. VISSIM zbog svojih postavki za usmjeravanje vozila ne može imati velike

vrijednosti za statično usmjeravanje vozila, te će se koeficijenti uvijek zadržati na jedinicama, češće i manje od jedinica. Razlog velikih oscilacija GEH statistike je ispitivanje područja u potrazi za globalnim optimum gdje neki od koeficijenata usmjeravanja toka vozila (vidljivo na slici 21) može konvergirati prema većem broju i uzrokovati velik broj odbačenih vozila. Prilikom simulacija je vidljivo da svako novo rješenje daje različiti broj vozila koja izlaze iz raskrižja. Razlog tome je upravo česta konvergencija pojedinih koeficijenata usmjeravanja toka vozila ka vrijednostima koje uzrokuju zagušenja, te zbog prirode VISSIM-a rezultira odbačenim vozilima. Dalo bi se zaključiti u slučaju izlaza približno svih vozila iz raskrižja koja su ušla, da bi se trebao generirati model s umjerenim mikrosimulacijskim modelom prema GEH-u koji je približan nuli, ili barem unutar koeficijenta 5. Na sljedećem slučaju, kod korištenja približno istih ulaznih i izlaznih vrijednosti, biti će dokazano zašto to većinom nije moguće, te zašto u većini slučajeva mikrosimulacijski model ne može biti umjeren unutar zadovoljavajućih kriterija, koristeći iste koeficijente raspodjele tokova tijekom cijelog dana.


Za ovaj umjereni model najbolja rješenja prikazuju da GEH statistika ne zadovoljava, to jest da su 3 od 4 privoza oko koeficijenta 10, dok je privoz VK, jedini na koeficijentu 5. Vidljivo je da je model nepouzdan, te da se ne bi trebao koristiti kao vjerodostojan prikaz stvarne prometne situacije. Na slici 22 je rješenje za svaki pojedini statični usmjeritelj vozila za pojedini privoz, ali zbog neprihvatljive GEH statistike se ne bi uopće trebao uzeti u obzir kao rješenje.




Slika 19: GEH statistika svih ispitanih rješenja po pojedinom privozu za period od cijelog dana (neumjereni broj vozila koja ulaze u raskrižje)



Slika 20: Najbolje vrijednosti funkcije dobrote za period od cijelog dana (neumjereni broj vozila koja ulaze u raskrižje)



Slika 21: Pojedinačna vrijednost gena za svako rješenje, za period od cijelog dana (neumjereni broj vozila koja ulaze u raskrižje)




Slika 22: Najbolji rezultati gena za period od cijelog dana (neumjereni broj vozila koja ulaze u raskrižje)


6.3.3. Umjeravanje dnevnog perioda koristeći umjerene vrijednosti ulaznih tokova

Prilikom umjeravanja mikrosimulacijskog modela s približnim obujmom vozila na ulazu i izlazu iz raskrižja, tablica 2 je podešena u odnosu na tablicu 1 na način da je broj ulaznih vozila za svaki pojedini vremenski interval, pomnožen za koeficijent koji je izračunat na temelju omjera ulaznog broja vozila u odnosu na broj izlaznog broja vozila, za svaki interval pojedinačno. To je vidljivo u tablici 3, te su te vrijednosti podešene unutar novog VISSIM modela s novim ulaznim vrijednostima broja vozila koji ulaze u raskrižje. Umjeravanje, koje je pokrenuto, koristilo je gotovo isti VISSIM mikrosimulacijski model, osim broja vozila koja ulaze u raskrižje. Pokrenuto umjeravanje je trajalo nekoliko dana, zbog podešene zasićenosti od 25, što znači da prilikom generiranja populacije, u slučaju da se pojavi najbolje rješenje više puta, do 25 uzima to kao najbolje rješenje. Cilj je bio dugo pretraživanje za sljedećim optimumom u slučaju da pretraživanje stane. To se dogodilo što je i vidljivo na slici 24, gdje u potrazi za najboljim rješenjem, funkcija dobrote konstantno pronalazi isto rješenje, te se zadržava u istom optimumu. Kod GEH statistike je bolja u odnosu na mikrosimulacijski model s neumjerenim ulaznim vrijednostima na slici 23, ali opet generira nezadovoljavajuću GEH statistku, te neprihvatljiva rješenja kao što je prikazano na slici 25. Razlog tomu može biti i nedovoljno dobro podešeni operatori koji se koriste prilikom implementacije genetskom algoritma, ali i korištenje GEH


statistike kao kumulativne funkcije dobrote za 4 pojedinačna privoza, za period od 24 sata. To je očiti razlog za najveće odstupanje od vjerodostojnog modela. Uzimajući u obzir tako velik broj privoza, te njihovih skretanja kao mogućih rješenja, na velik broj auta generira preveliku GEH statistiku za svaki privoz. Odstupanja ulaznog zbroja vozila po svakom privozu koja se mogu događati prilikom svakog intervala u odnosu na izlazni zbroj vozila i obratno, isto čini veliku razliku, te samim time generira model koji ne zadovoljava kriterije vjerodostojnog mikrosimulacijskog modela. Generiranje prihvatljivog umjerenog simulacijskog modela za period od cijelog dana bi bio izvediv za raskrižje s manjim brojem vozila tijekom dana, manjim brojem privoza i skretanja unutar raskrižja, te koeficijentima raspodjele tokova privoza koji su različiti za svaki pojedini sat tijekom dana. Osim toga za najbolje rješenje omjer zbroja ulaznih i izlaznih vozila iz raskrižja za pojedini vremenski interval bi trebao biti što manji.




Slika 23: GEH statistika svih ispitanih rješenja po pojedinom privozu za period od cijelog dana (umjereni broj vozila koja ulaze u raskrižje)



Slika 24: Funkcija dobrote za period od cijelog dana (umjereni broj vozila koja ulaze u raskrižje)



Slika 25: Pojedinačna vrijednost gena za svako rješenje, za period od cijelog dana (umjereni broj vozila koja ulaze u raskrižje)



Slika 26: Najbolji rezultati gena za period od cijelog dana (umjereni broj vozila koja ulaze u raskrižje)

7. Zaključak

Mikroskopski prometni modeli koji su korišteni u ovom diplomskom radu su dokazali da prilikom upotrebe na raskrižju koje ima i do 50.000 vozila dnevno ne može ispuniti zahtjeve na temelju početnih postavki i ručnih umjeravanja. Da bi se generirao vjerodostojan mikroskopski prometni model na temelju kojeg bi se mogli donositi zaključci o budućim strategija na dijelovima prometne infrastrukture, potrebno je postojeći prometni model umjeriti na način da parametri koji su ključni za funkciju koja se istražuje, budu približni vrijednostima sa terena. To je teško postići, s obzirom da je uvijek prisutan ljudski faktor, odstupanje ili čak krivo definirane vrijednosti za ispunjavanje određenog zahtjeva. Da bi se parametri umjerali prvo se mora definirati, koje su vrijednosti ključne za ispunjavanje određenog zahtjeva, prikupljanje podataka ključnih za definiranje tih vrijednosti, te umjeravanje na temelju određenih parametara i prikupljenih podataka. Zbog stohastičnosti prometnog sustava, teško je prikupiti autentične podatke da mogu prikazati stvarne vrijednosti sa terena, na osnovu čega se uvijek uzima u obzir prisutnost greške prilikom prikupljanja. Inteligentni transportni sustavi kao odgovorni sustavi za prikupljanje jedno dijelov podataka tih parametara nisu savršeni, i za period od cijelog dana, nije realno očekivati sto postotnu točnost. Usporedbom s ostalim prikupljenim podacima na terenu, lako se dolazi do zaključka o kolikoj se grešci radi. U ovom diplomskom radu su se tražili koeficijenti statičnog usmjeravanja vozila, što zapravo predstavlja skretanja za svaki pojedini privoz unutar raskrižja. Unutar raskrižja su četiri privoza, sa tri skretanja za svaki privoz, što čini ukupno dvanaest skretanja ili rješenja koja se traže, te kumulativno velik broj parametara, za svaki privoz, skretanje i interval pojedinačno. Uzimajući u obzir da se umjerava mikroskopski prometni model za period od 24 sata, gotovo je nemoguće očekivati na velik broj rješenja, s velikim brojem parametara, kreirati prihvatljiv prometni model.

Primjena genetskog algoritma u svrhu umjeravanja prometnog modela je bio logičan izbor zbog stohastične prirode cjelokupnog sustava. Osim podataka sa terena, trebalo je podesiti sami GA u svrhu za koju je predviđen, te je za period od 24 sata odabran elitizam, sa barem jednom slučajnom mutacijom po rješenju, te dvije točke prekida kod križanja sa turnirskom selekcijom prema unaprijed definiranom PyGAD modulu. Utvrđivanje funkcije dobrote se koristila GEH statistika koja predstavlja omjer između modela i realne situacije u prometu. Svaki privoz je

imao svoj GEH koeficijent, što je prihvatljivo za ukupno 4 privoza za interval od jednog sata. Prilikom implementacije funkcije dobrote za period od cijelog dana gdje postoji GEH statistika za svaki sat u danu, što znači ukupno 24 GEH koeficijenta za pojedini privoz, dolazi se do vrijednosti koju je teško umjeriti, za svako pojedino skretanje, u period od 24 sata. Iz tog razloga se prije implementacije i inicijalizacije umjeravanja dnevne mikrosimulacije, provjerio mikroskopski prometni model u intervalu od 3600 sekundi sa umjerenim ulaznim brojem vozila koja ulaze u raskrižje, radi lakše konvergencije prema globalnom optimumu. Kod umjeravanja se u vrlo kratkom periodu prometni model konvergirao prema optimumu koji je bio prihvatljiv za sva 4 privoza, gdje je samo jedan privoz bio oko GEH koeficijenta 5, što se smatra granicom prihvatljivosti, dok su ostali bili bliže koeficijentu 0. Time se dokazalo da je mikrosimulacija, sa pripadajućim parametrima i vrijednostima ispravno postavljena, te da modul genetskog algoritma ispravno optimizira, to jest umjerava mikroskopski prometni model ka optimumu.

Kod umjerenog modela u trajanju od jednog sata, prikazano je umjeravanje putem kumulativne GEH statistike, koja je prikazana kao funkcija dobrote kada se jedan podijeli sa tom vrijednosti. Postupnim povećavanjem funkcije dobrote se model paralelno sa tom vrijednošću približavao globalnom optimumu. Kod umjeravanja prometnog modela u trajanju od cijelog dana, GEH statistika se povećava za 24 koeficijenta, po privozu, što je kumulativno velik koeficijent, a samim time funkcija dobrote, zbog pretraživanja područja, će izrazito oscilirati, te zbog elitizma će nastojati sačuvati najbolja rješenja, ali opet ne previše odstupati od optimuma. To je i vidljivo kod GEH statistike, koja je prihvatljiva za privoze koji su imali manji broj vozila tokom cijelog dana, a za ostale privoze neprihvatljiva što je vidljivo na grafovima GEH statistike.

Zaključak se temelji na empirijskom istraživanju, više umjerenih simulacija, od kojih je većina imala neprihvatljivu GEH statistiku, točnije oko 10. Razlozi za to su jasni: velik broj vozila kroz period od cijelog dana, veliki nesrazmjer između privoza na temelju ulaznog i izlaznog broja vozila po privozu za period od jednog sata, broj odbačenih vozila u slučaju odabira prevelikog statičnog usmjeravanja vozila za pojedina skretanja, prevelika ovisnost pojedinih skretanja, čime se lako ostane o lokalnom optimumu... Teško se dolazi do zaključka da li uopće postoji bolje rješenje, te da li je smisleno nastaviti dalje s umjeravanjem. Na osnovu toga se postavila točka zasićenja, u čijem se slučaju više puta generirano isto najbolje rješenje, prihvaća kao najbolje rješenje tog umjeravanja. Iz toga proizlazi da na temelju navedenih razloga, nema smisla raditi umjeravanje modela za ciklus od cijelog dana, osim ako je većina prethodno navedenih razloga neprimjetna. Smislenije je raditi mikroskopske prometne modele u periodu od jednog sata,

pa čak i par sati, prvenstveno za analizu ponašanja prometnog sustava za vrijeme vršnog sata. Genetski algoritam se pokazao kao prihvatljivo rješenje za umjeravanje prometnih modela, pa čak i za period od cijelog dana, iako nije dao vjerodostojan mikrosimulacijski model. Razlog tome su drugi čimbenici, te prilikom umjeravanja vremenski kraćih simulacijskih modela se dokazao kao logičan izbor, s čime se zaključuje da je upotreba genetskog algoritma opravdana u ovom diplomskom radu.

Popis literature

- [1] Bošnjak, I. *Inteligentni transportni sustavi I*. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2006.
- [2] Dowling, R., Skabardonis, A., Halkias, J., McHale, G., Zammit, G. *Guidelines for Calibration of Microsimulation Models Framework and Applications*. SAGE Journals, 2004.
- [3] Cunha A.L., Bessa J.E., Setti J.R. *Genetic Algorithm for the Calibration of Vehicle Performance Models of Microscopic Traffic Simulators*. Lopes L.S., Lau N., Mariano P., Rocha L.M. (eds) Progress in Artificial Intelligence. EPIA 2009. Lecture Notes in Computer Science, vol 5816. Springer, Berlin, Heidelberg., 2009.
- [4] TRB. *Highway Capacity Manual*. Transport research board, Washington DC, USA, 2016.
- [5] Byungkyu (Brian) Park and Hongtu (Maggie) Q. *Development and Evaluation of a Procedure for the Calibration of Simulation Model*. Transportation Research Record Journal of the Transportation Research Board 1934(1934):208-217, DOI:10.3141/1934-22, January 2005.
- [6] Byungkyu (Brian) Park and J. D. Schneeberger. *Microscopic Simulation Model Calibration and Validation*. Transportation Research Record Journal of the Transportation Research Board, January 1, 2003.
- [7] Byungkyu (Brian) Park, Jongsun Won, and Ilsoo Yun. Application of microscopic simulation model calibration and validation procedure: Case study of coordinated actuated signal system. *Transportation Research Record*, 1978(1):113–122, 2006.
- [8] Tomer Toledo, Moshe E. Ben-Akiva, Deepak Darda, Mithilesh Jha, and Haris N. Koutsopoulos. Calibration of microscopic traffic simulation models with aggregate data. *Transportation Research Record*, 1876(1):10–19, 2004.
- [9] Jingtao Ma, Hu Dong, and H. Michael Zhang. Calibration of microsimulation with heuristic optimization methods. *Transportation Research Record*, 1999(1):208–217, 2007.

- [10] Ivan Petrović, Mato Baotić, Nedjeljko Perić. *Inteligentni sustavi upravljanja: Neuronske mreže, evolucijski i genetički algoritmi*. Fakultet elektrotehnike i računarstva, Zagreb, Ak. god. 2011/2012.
- [11] Gold, H., Ivanjko, E. *Umjetna inteligencija - predavanja - Genetski algoritam*. Fakultet prometnih znanosti, Zagreb, 2019.
- [12] George F. Luger. *Artificial Intelligence - Structures and Strategies for Complex Problem Solving, sixth edition*. Pearson - Addison Wesley, 2009.
- [13] Mitchell Melanie. *An Introduction to Genetic Algorithms*. A Bradford Book The MIT Press, Cambridge, Massachusetts • London, England, Fifth printing, 1999.
- [14] Ahmed Fawzy Gad. Pygad: An intuitive genetic algorithm python library, 2021.
- [15] Pygad module. <https://pygad.readthedocs.io/en/latest/index.html>. pristupljeno: Kolovoz, 2021.
- [16] Olga Feldman. The GEH measure and quality of the highway assignment models. Affiliation: Transport for London, Windsor House, 42-50 Victoria Street, London, UK, 2012.
- [17] COM technical overview. <https://docs.microsoft.com/en-us/windows/win32/com/com-technical-overview>. pristupljeno: Kolovoz, 2021.

Popis ilustracija

1	Primjer 3D vizualizacije mikrosimulacije	5
2	Pristup umjeravanja prometnog mikroskopskog modela, [5]	8
3	Područje reducirane brzine prilikom skretanja u raskrižju	10
4	Željena distribucija brzine	10
5	Osnovni ciklus genetskog algoritma, Izvor: https://www.diagrameditor.com/	12
6	Vrste selekcija genetskog algoritma, Izvor: https://www.diagrameditor.com/	14
7	Križanje s n-točaka prekida, [11]	15
8	Primjer jednostavne mutacije gena, Izvor: [11]	16
9	Statično usmjeravanje vozila unutar raskrižja s pripadajućim kraticama	18
10	Ciklus genetskog algoritma prema PyGAD modulu, [15]	19
11	Prikaz raskrižja na karti sa pripadajućim ulicama, Izvor: https://www.openstreetmap.org/edit##map=17/41.98817/21.46190	22
12	Prikaz raskrižja na karti grada Skopja, Izvor: https://www.openstreetmap.org/edit##map=13/41.9988/21.4480	23
13	Prikaz COM sučelja	24
14	Prikaz izrađenog VISSIM modela raskrižja u Skopju	26
15	Fiksni signalni plan za raskrižje Jane Sandanski, Vasko Karangelski i ASNOM Bulevard	27
16	GEH statistika svih ispitanih rješenja po pojedinom privozu za period od jednog sata, (umjereni broj vozila koja ulaze u raskrižje)	29
17	Najbolje vrijednosti funkcije dobrote za period od jednog sata, (umjereni broj vozila koja ulaze u raskrižje)	29
18	Pojedinačna vrijednost gena za svako rješenje, za period od jednog sata, (umjereni broj vozila koja ulaze u raskrižje)	30
19	GEH statistika svih ispitanih rješenja po pojedinom privozu za period od cijelog dana (neumjereni broj vozila koja ulaze u raskrižje)	31
20	Najbolje vrijednosti funkcije dobrote za period od cijelog dana (neumjereni broj vozila koja ulaze u raskrižje)	32

21	Pojedinačna vrijednost gena za svako rješenje, za period od cijelog dana (neumjereni broj vozila koja ulaze u raskrižje)	32
22	Najbolji rezultati gena za period od cijelog dana (neumjereni broj vozila koja ulaze u raskrižje)	33
23	GEH statistika svih ispitanih rješenja po pojedinom privozu za period od cijelog dana (umjereni broj vozila koja ulaze u raskrižje)	34
24	Funkcija dobrote za period od cijelog dana (umjereni broj vozila koja ulaze u raskrižje)	35
25	Pojedinačna vrijednost gena za svako rješenje, za period od cijelog dana (umjereni broj vozila koja ulaze u raskrižje)	35
26	Najbolji rezultati gena za period od cijelog dana (umjereni broj vozila koja ulaze u raskrižje)	36

Popis tablica

1	Tablica vrijednosti tokova ulaznih privoza iz raskrižja Jane Sandanski, ASNOM Bulevard i Vasko Karangelski za period od jednog dana	24
2	Tablica vrijednosti tokova izlaznih privoza iz raskrižja Jane Sandanski, ASNOM Bulevard i Vasko Karangelski za period od jednog dana	25
3	Tablica umjerenog broja vozila koja ulaze u raskrižje u odnosu na tablicu 1 . . .	28



Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj _____ diplomski rad
isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na
objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz
necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj
visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu _____ diplomskog rada
pod naslovom **UMJERAVANJE MIKROSKOPSKOG PROMETNOG MODELA**

PRIMJENOM GENETSKOG ALGORITMA

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom
repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, _____ 16.9.2021 _____

Student/ica:

(potpis)