ISSN 0554-6397
UDK: 656.1.021;625.739
004.9
PRETHODNO PRIOPĆENJE
(*Preliminary communication*)
Primljeno (*Received*): 22.12.2014.

Sanja Šurdonja, mag.ing.aedif.
E-mail: sanja.surdonja@gradri.uniri.hr
Daniela Nežić, mag.ing.aedif.
E-mail: danielanezic1@gmail.com
Prof.dr.sc. **Aleksandra Deluka-Tibljaš**
E-mail: aleksandra.deluka.tibljas@gradri.uniri.hr
Građevinski fakultet Sveučilišta u Rijeci, Radmile Matejčić 3, 51000 Rijeka

Mikrosimulacijski model proračuna kapaciteta kružnog raskrižja

Sažetak

Računalni programi namijenjeni prometnim mikrosimulacijama stekli su značajnu popularnost i široku primjenu, kako u praktičnoj primjeni, tako i u istraživanjima. Broj prometnih simulacijskih modela značajno se povećao, a samo do kraja prošloga stoljeća bilo je dostupno više od 50 simulacijskih modela. Njihova je prednost mogućnost predviđanja prometnog ponašanja u svakodnevnim, ali i izvanrednim situacijama. Za razliku od klasičnih analitičkih metoda analiza prometa, simulacijski modeli mogu prikazati i dinamiku prometnih sustava, a 2D ili 3D animacije su, kao rezultat njihovog modeliranja, znatno razumljivije nestručnoj javnosti.
Cilj ovoga rada je ukratko opisati osnovne postavke mikrosimulacijskih računalnih programa. Detaljnije će biti opisan računalni program AIMSUN te prikazan postupak izrade AIMSUN (Advanced Interactive Microscopic Simulator for Urban and non-urban Networks) mikrosimulacijskog modela za primjer kružnog raskrižja u Radničkoj ulici u Rijeci.
Budući da se prometni simulacijski računalni programi obično koriste za procjene značajki prometnih tokova, poput prosječnog vremena putovanja, kapaciteta prometnica ili prosječnih brzina vozila, modeli se temelje na podešavanju ulaznih parametara kako bi se postiglo razumno podudaranje između rezultata modela i podataka s terena. Taj se postupak zove kalibracija, a ona je nužna za dokazivanje vjerodostojnosti simulacijskog modela, odnosno validacije modela. Za kalibraciju i validaciju planiranog simulacijskog modela u ovom su slučaju dobiveni rezultati uspoređeni s rezultatima dobivenih drugim analitičkim metodama proračuna (Austrijskom metodom) i računalnim programom SIDRA INTERSECTION (Signalised & Unsignalised Intersection Design and Research Aid) koji se bazira na australskoj metodi proračuna kapaciteta kružnih raskrižja.

Ključne riječi: simuliranje prometa, kružno raskrižje, mikrosimulacijski model, kalibracija, validacija

1. Uvod

Kružna se raskrižja implementiraju na mjestima postojećih semaforiziranih ili nesemaforiziranih raskrižja ili kao nova rješenja unutar prometne mreže. Povećanje sigurnosti i kapaciteta su razlozi koji uobičajeno motiviraju za primjenu kružnih raskrižja, ali to nikako ne mogu biti i jedini kriteriji pri prosudbi opravdanosti primjene toga tipa raskrižja umjesto nekog od standardnih tipova. Nova regulativa vezana uz projektiranje kružnih raskrižja u Republici Hrvatskoj tako predviđa provjeru opravdanosti primjene prometnog rješenja s kružnim raskrižjem, pri čemu se, osim kriterija propusne moći i sigurnosti, navodi i čitav niz drugih bitnih kriterija: urbanistički, funkcionalni kriterij, prostorno-urbanistički kriterij, prometni kriterij (kriterij prometnog toka), projektno-tehnički kriteriji, kriteriji prometne sigurnosti, kriterij propusne moći, okolišni kriterij, ekonomski kriteriji [1, 28] Kriterij propusne moći često se nameće kao jedan od važnijih, posebice u urbanim prostorima koji ne omogućuju uvijek primjenu optimalnog polumjera kružnog raskrižja, kako bi se postigao željeni/zahtijevani kapacitet raskrižja, a istodobno imaju najveća prometna opterećenja. [16, 539]

Za poboljšanje kvalitete prometnih tokova uobičajeno postoje različita rješenja koja je u postupku odabira optimalnog potrebno usporediti. U svijetu su razvijeni različiti modeli za analizu funkcioniranja i ocjenu učinkovitosti pojedinih dijelova cestovnoga prometnog sustava. Razlikuju se empirijski, analitički i simulacijski modeli. Empirijski i analitički modeli su uglavnom deterministički, odnosno ne sadrže slučajne varijable, i za njih ulazni podaci uvijek daju isti rezultat. S druge strane, simulacijski modeli su uglavnom stohastičke prirode, tj. za modeliranje prometnog toka koriste se i slučajnim varijablama.[2, 540]

Simulacijski modeli vjernije prikazuju stvarne procese, poput vremena dolaska vozila na raskrižje, brzine ili značajki pojedinog vozila, osobina vozača, itd. Rezultati se dobivaju „mjerenjem“ iz simulacije prometnog toka koja je svaki put drugačija upravo zbog slučajnih varijabli koje se generiraju na temelju definiranih razdioba vjerojatnosti.

Kako bi simulacijski model bio vjerodostojan i davao rezultate što sličnije stvarnima, potrebno je prvo prikupiti što više podataka s terena jer kvaliteta rezultata ovisi o kvaliteti ulaznih parametara. Što je veća razina detalja kojom opisujemo prometnu mrežu, to je model bolji, ali je tada i njegova izrada složenija i dugotrajnija.

Podaci o prometnoj mreži uključuju podatke o prometnicama (položaj, duljine, broj traka, ograničenja brzine, prometna signalizacija) te podatke o čvorištima (dozvoljena skretanja, rad semafora, prednosti prolaska). Uz njih, potrebni su i podaci o prometu, od značajki motornih vozila (dimenzija, sposobnosti akceleracije i deceleracije, količine ispušnih plinova, potrošnja goriva) do brojnih parametara koji opisuju ponašanje vozača (razmak održavan s prethodnim vozilom, poštivanje prometnih pravila, vrijeme reakcije) te jednako važnih, količina i smjerova kretanja prometa.

Nakon unosa svih potrebnih podataka, model je potrebno kalibrirati i validirati. Kalibracija se može definirati kao proces podešavanja ulaznih podataka i parametara u modelu kako bi se postiglo podudaranje rezultata simulacije i stvarnog stanja. Kali-

bracija je nužna kako bi rezultati dobiveni simulacijom bili pouzdani te kako bi se na temelju njih mogli donositi zaključci i poduzimati mjere poboljšanja prometa. Validacija je usporedba izlaznih podataka simulacijskog modela s rezultatima dobivenima neovisno o kalibracijskom postupku.

Cilj ovog rada je dati kratki pregled osnovnih postavki mikrosimulacijskih računalnih programa te usporediti rezultate jednog takvog mikrosimulacijskog modela s rezultatima dobivenim regulativom preporučenim analitičkim metodama i računalnim programom. Detaljnije se u radu opisuje jedan od tržišno dostupnih računalnih programa za simulaciju prometa AIMSUN (Advanced Interactive Microscopic Simulator for Urban and non-urban Networks). Prikazan je primjer primjene tog programa na simulaciju prometa na kružnom raskrižju u Rijeci. Kako bi se model kalibrirao i validirao, dobiveni rezultati su uspoređeni s rezultatima dobivenim Austrijskom metodom proračuna kapaciteta raskrižja te s rezultatima dobivenim računalnim programom temeljenim na deterministčkim metodama - SIDRA INTERSECTION (Signalised & Unsignalised Intersection Design and Research Aid).

2. Općenito o simulacijskim modelima

Simulacija je imitiranje stvarnog objekta, stanja ili procesa. Procesom simulacije želi se stvoriti prikaz određenih ključnih značajki ili ponašanja fizičkog ili apstraktnog sustava. Računalna simulacija je računalni program koji simulira model određenog realnog sustava na računalu ili mreži računala. Simulator prometa predstavlja modeliranje prometnih sustava korištenjem računalnih programa s ciljem boljeg planiranja, dizajniranja i upravljanja tim sustavima. [8, 2]

Sustavno se istraživanje prometa, u svijetu, počelo provoditi prije pedesetak godina, a bilo je potaknuto napretkom tehnologije te naglim porastom broja prijevoznih sredstava što je uzrokovalo daljnji razvoj gradova kao i značajna ulaganja u prometne infrastrukturne građevine. Prvi počeci planiranja temeljili su se na jednostavnom ekspandiranju dotadašnjih stopa rasta prometa i shematskom prikazu prostorne razdiobe putovanja u obliku tabelarnih prikaza s izvorištima i odredištima putovanja. Početke ozbiljnijeg pristupa prometnom planiranju predstavlja otkriće veze između namjene površina i putovanja. Bilježenje i proučavanje navedenih povezanosti omogućilo je razumijevanje prometnih kretanja.

Digitalna računala su, zahvaljujući njihovoj velikoj moći obrade podataka i brzini rada, dala značajan poticaj razvoju modeliranja i simuliranja na svim inženjerskim područjima pa tako i u području projektiranja i analize prometnih sustava. Tijekom vremena u svijetu su razvijeni, a i dalje se razvijaju, različiti modeli koji se upotrebljavaju za analizu i procjenu učinkovitosti cestovnih prometnih sustava. Uporaba takvih simulacijskih modela u istraživanjima, ali i stručnoj primjeni, nudi mogućnost usporedbe projektnih rješenja, njihovog ocjenjivanja i sagledavanja posljedica njihove implementacije prije nego što se eventualni nedostaci odraze na terenu. Njihov je

zadatak kontrola ili modeliranje prometa na način da se odgode, smanje ili čak uklone prometna zagušenja. Kako bi simulacija što realnije prikazala cestovni prometni sustav, potrebno je podesiti, odnosno, modelirati njezine elemente: prometnice i čvorišta prema odgovarajućoj geometriji prometnog sustava, zatim, način kontrole prometa, vrste i karakteristike vozila i osobine vozača. Iz međusobne interakcije tih elemenata, kao rezultat, proizlaze prometne simulacije.[3, 115]

Razvijeni prometni modeli omogućuju, ne samo simulacije budućih prometnih gustoća i prosječnih brzina, već i predviđanja ponašanja prometa u iznimnim situacijama prije nego se one dogode. Primjerice, simulacija blokirane prometnice može pomoći prometnim operaterima unaprijed utvrditi koje kontrolne mjere poduzeti kada do takve situacije dođe.

Primjena prometnih simulacija je raznolika i njima je moguće odrediti: stanje prometa u široj mreži, prometnu opterećenost prometnica, broj vozila u mreži, optimalan sustav javnog prijevoza, utjecaj izgradnje nove infrastrukture na postojeće prometnice, isplativost novih prometnica u mreži, moguća rasterećenja prometne mreže (lokacije i intenzitete) zbog izgradnje novih prometnica, predvidjeti stanje prometa u gradu u nadolazećem razdoblju (pomoću vremenskih scenarija temeljenih na prirodnom prirastu prometa), količine emisija u zrak generiranih prometom, stanje semaforizacije na širem području, vidjeti i provjeriti stanje na raskrižjima i naći najbolje rješenje u odnosu na širi kontekst prostora.

2.1. Klasifikacija simulacijskih modela

Temeljni postupak za prostorno-prometno planiranje obuhvaća planiranje prometne mreže unutar zadanog prostora i utvrđivanje interakcije između prijevozne potražnje i društveno-gospodarskih karakteristika zajednice. Ipak, ne postoji univerzalna, ispravna metoda prometnog planiranja jer ni ciljevi prometnih analiza nisu uvijek jednaki. Planiranje se može obaviti za područja različitih veličina i namjena. Velik je broj razvijenih modela koji mogu simulirati prometni sustav, a mogu se grupirati prema načinu na koji se predstavlja vrijeme i prostor, prema razini detalja i prema vrsti procesa.[7, 7-8][12, 10]

Ovisno o tomu je li vrijeme u kojem se promatra razvoj stanja sustava kontinuirana ili diskretna varijabla, jedna od podjela simulacijskih modela je na kontinuirane i diskretne. Kontinuirani simulacijski modeli definiraju promjene u sustavu kontinuirano kroz vrijeme kao odgovor stalnim podražajima, dok diskretni modeli proračunavaju stanje sustava kroz određene vremenske presjeke. S obzirom na to da li su ti vremenski presjeci vezani uz određeni vremenski korak ili, pak, uz određeni događaj, diskretni modeli mogu se dalje podijeliti u dvije podkategorije:

- modeli diskretnog vremena i
- modeli diskretnog događaja.

Kod modela diskretnog vremena, promjene stanja sustava proračunavaju se za svaki vremenski korak Δt čija je veličina jasno definirana. Najčešće korištena veličina vremenskog koraka je jedna sekunda ili jedna desetinka sekunde, iako može biti i bilo koja druga vrijednost. To znači da se sve veličine vezane uz funkcioniranje sustava kao i odgovarajući statistički podaci računaju za sukcesivne vremenske korake. Za razliku od ovakvog vremenskog «skeniranja» stanja sustava, u modelima diskretnog događaja, prometna situacija, tj. nova vrijednost varijabli u sustavu, proračunava se nakon ostvarivanja određenog događaja koji utječe na prometni tok (npr. promjena svjetla na semaforskom uređaju). [5, 105-107]

Prema razini detalja kojom se promatrani prometni tok opisuje, simulacijski se modeli dijele na: mikrosimulacije, makrosimulacije i mezosimulacije.

Mikrosimulacijski modeli su najkompleksniji jer se takvi modeli zasnivaju na proučavanju individualne jedinice (vozila, pješaka) i zahtijevaju veliki broj ulaznih podataka kako bi model mogao biti vjerodostojan. Prometno kretanje opisano je na temelju karakteristika i ponašanja svakog individualnog vozila, a njihovu međusobnu interakciju kontroliraju teorije „slijeda vozila“, „promjene prometnog traka“ i teorije „prihvaćanja vremenskih praznina“. Iako su mikroskopski modeli precizniji, njihov razvoj je znatno složeniji i skuplji od razvoja makroskopskih modela. [5, 105-107]

Makrosimulacije su, za razliku od toga, namijenjene proučavanju prometnih tokova, općenitijih procesa gdje nije bitno pojedino vozilo ili pješak već ukupan broj jedinica koji je prošao nekom prometnom dionicom. U modelu ne postoje individualna vozila već samo agregati kao što su razina toka, gustoća i brzina. Individualni manevri kretanja, poput promjene trake, ne mogu se modelirati. Za takve je modele potrebna manja razina detalja, što ih čini pogodnima za rad na većim područjima. [5, 105-107]

Mezoskopski modeli su kombinacija mikro i makro pristupa. Vozila se opisuju individualnim značajkama (mikropristupom) dok se njihovo kretanje i interakcija modelira prema agregiranim podacima. Promet je predstavljen kao niz malih skupina vozila, a donošenje odluke o promjeni trake temelji se na relativnim gustoćama vozila u pojedinim trakama i u razlikama brzina vozila. [5, 105-107][9]

Treća moguća podjela simulacijskih modela je prema svojstvima varijabli kojima definiramo procese i elemente u modelu, a prema njoj razlikujemo:

- determinističke modele i
- stohastičke modele.

Deterministički model nema slučajnih varijabli. Sve su interakcije točno određene i konstantnih vrijednosti. Takav deterministički pristup se obično koristi kod makroskopskih modela.

Stohastički modeli sadrže jednu ili više slučajnih varijabli koje utječu na vrijednost određenog parametra (npr. vrijeme slijeda vozila ovisno o tipu vozila i vozača) ili izvršenje neke radnje kao odgovor na danu prometnu situaciju (npr. prihvaćanje vremenske praznine kod skretanja). Stohastičke metode uglavnom se koriste kod mikroskopskih simulacija koje opisuju prometni tok na razini pojedinog vozila. Kod

mikrosimulacija, većina varijabli koje definiraju način održavanja prometa, promjenjivih su slučajnih vrijednosti i zbog toga stohastički model može realno opisati stvarnu prometnu situaciju.[5, 105-107]

2.2. Mikrosimulacije

Mikrosimulacija se može razlikovati od drugih vrsta računalnog modeliranja jer promatra interakciju individualnih „jedinica", kao što su ljudi ili vozila. Za takav složeni simulacijski model potreban je vrlo veliki broj ulaznih podataka, a može razlikovati i pratiti pojedine automobile i njihove vozače.

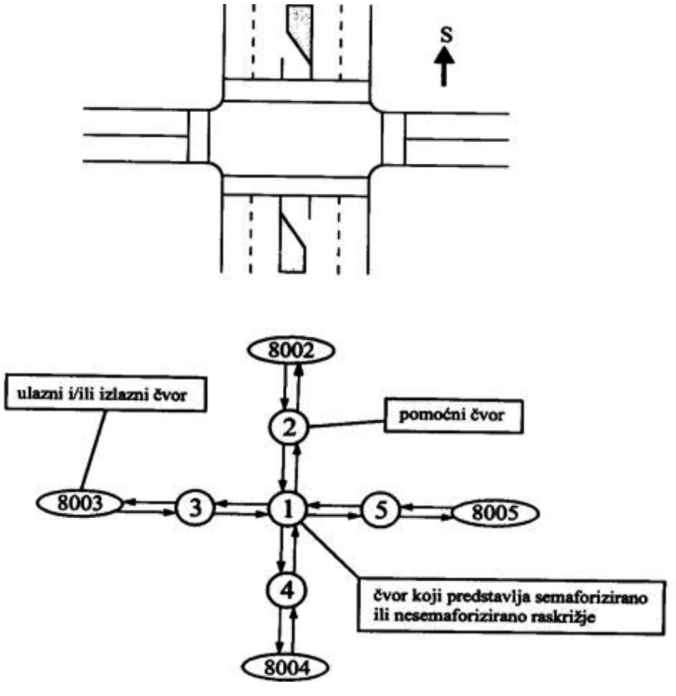

Slika 1. Segmenti prometne mreže u simulacijskom modelu [2, 542]

Prometna mreža definirana je pomoću veza (prometnica), koje predstavljaju pojedine dionice te pomoću čvorova, kojima se definiraju raskrižja ili točke na mreži gdje postoje promjene određenih atributa (geometrije, toka prometa i slično). Prometnica može biti sastavljena od jednog ili više segmenata, kao što je prikazano na Slici 1. Čvorovi na rubovima promatrane prometne mreže (ulazni čvorovi) su točke kroz koje vozila ulaze i izlaze iz simulacije. Vrijeme između pojave dvaju uzastopnih vozila regulira se određenim razdiobama, ovisno o simulacijskom modelu kojeg koristimo. [2, 540-541]

Ponašanje vozača opisano je velikim skupom „if-then“ (u prijevodu „ako-onda“) pravila i podešavanjem velikog broja parametara. Primjerice, vrijeme reakcije i vrijeme kretanja vozila iz stanja mirovanja su dva, vrlo bitna parametra koja snažno utječu na kretanje vozila i kapacitet prometne mreže. Iz ponašanja i karakteristika vozila, za svaki se vremenski korak simulacije računaju položaj, brzina i ubrzanje vozila. Jezgra svake simulacije prometnih tokova su modeli koji „upravljaju“ kretanjem i prestrojavanjem vozila:

- Model slijeda vozila (eng. car-following model) koristi jednadžbu slijeda vozila uz primjenu jednadžbi jednolikog ubrzanog kretanja. Na taj se način može za svako vozilo odrediti položaj, brzina i ubrzanje u svakom vremenskom trenutku čime se definira trajektorija vozila. Trajektorija vodećeg vozila ovisi o graničnim vrijednostima parametara (brzine, ubrzanja i usporenja) te o njoj ovise trajektorije vozila koji ga slijede.
- Model promjene prometnog traka (eng. lane-changing model) utvrđuje motiviranost vozača za promjenom traka te postojanje mogućnosti da se ono i izvrši. Prvo je razvijen model izbora traka na višetračnim cestama pri čemu se razlikuje izbor promjene prometne trake u želji da se prestigne sporo vozilo (slobodan izbor) od izbora odgovarajućeg traka radi skretanja na čvorištima (nužan izbor).[6, 121]

Visoka preciznost simuliranja prometnog ponašanja je prednost, ali u isto vrijeme i slabost. Kako bi se postigla takva razina preciznosti, mikrosimulacijski modeli zahtijevaju znatne količine podataka o geometriji prometnica, kontroli prometa, prometnim kretanjima i ponašanju vozača. Unos tolike količine podataka ograničava korisnika na modeliranje manjih prometnih mreža za razliku od onih modeliranih makro ili mezosimulacijama. Potrebna razina detalja, također, može uzrokovati dugo vrijeme čekanja da izvođenjem simulacije dobijemo izlazne podatke (rezultate). Unatoč sitnim nedostacima, mikrosimulacijski modeli postaju sve popularniji za razvoj Inteligentnih Transportnih Sustava (ITS), zato jer promet ne tretiraju kao homogene tokove nepromjenjivih karakteristika već zahtijevaju i svoje rezultate temelje na međusobnoj interakciji pojedinih jedinica, vozila, čije se ponašanje mijenja kroz simulaciju u odnosu na promjene u prometnoj mreži. [13, 18]

3. Računalni programi za simuliranje prometnih sustava

Potrebe različitih korisnika mikrosimulacijskih modela mogu se razlikovati. Svaki mikrosimulacijski alat ima svoje prednosti i mane pa je odabir prikladnog računalnog programa za provedbu simulacijskog postupka, također, bitan. Primjerice, ponašanje vozača koji se približavaju kružnom raskrižju razlikuje se od ponašanja pri prolazu drugim vrstama raskrižja. U skladu s tim, model koji želi simulirati promet na kružnom raskrižju mora sadržavati parametre za podešavanje odgovarajućeg ponašanja vozača, koje karakteriziraju postupci poput:

- smanjenja brzine,
- prestrojavanja vozila u odgovarajuću traku na ulazu u raskrižje ili kružnom kolničkom traku, prema željenom izlaznom privozu (u slučaju višetračnog kružnog raskrižja i/ili ulaznog privoza),
- davanja prednosti prolaska vozilima unutar kružnog raskrižja, osim ako oznake na kolniku sugeriraju drugačije,
- obraćanja pozornosti na pješake te vozila unutar kružnog raskrižja, posebice bicikliste i motocikliste,
- ostavljanja dovoljno prostora dugim, odnosno velikim motornim vozilima zbog drukčije putanje ili mogućeg otežanog prolaska kružnim raskrižjem (naprimjer, mini kružna raskrižja s provoznim središnjim otokom).

Broj prometnih simulacijskih modela značajno se povećao, a samo do kraja prošloga stoljeća bilo je dostupno više od 50 simulacijskih modela. Godine 1999. provedena je analiza postojećih modela i simulacijskih alata s ciljem prikupljanja podataka, informiranja korisnika i maksimiziranjem iskoristivosti mikrosimulacijskih paketa. Recenzijom se, također, htjelo pronaći i ukazati na postojeće nedostatke mikrosimulacijskih alata. Projektom „SMARTEST“, kojeg je provelo Sveučilište u Leedsu 2000. g., identificirano je 57, a detaljnije analizirano 33 mikrosimulacijska alata. [10, 3]

Zbog velikog broja takvih modela, ali i pojednostavljenja odabira odgovarajućeg računalnog programa za pojedini slučaj, potrebno je razumjeti njihov način rada i glavne razlike između njih.

Među najpoznatijim mikrosimulacijskim alatima su:

- AIMSUN (razvijen u Španjolskoj)
- CORSIM (SAD)
- PTV VISSIM (Njemačka)
- PARAMICS (Velika Britanija). [13, 20]

Tablica 1. Pregled funkcionalnosti najčešće korištenih mikrosimulacijskih modela [13, 38]

ZNAČAJKE PROGRAMA	AIMSUN	CORSIM	VISSIM	PARAMICS
Model vremenskih praznina	√	√	√	√
Model promjene prometnog traka	√	√	√	√
Model slijeda vozila	√	√	√	√
Podesiva brzina skretanja vozila	x	x	√	x
Vožnja kroz žuto svjetlo	√	√	√	√
Podesivo vrijeme reakcije	√	√	√	√
Podesive tehničke karakteristike vozila	√	√	√	√
Duljina preglednosti vozača	√	√	√	√
Prepuštanje prednosti	√	√	√	√
Utjecaj pješaka	√	√	√	√
Modeliranje uključivanja vozila u višetračne prometnice	√	√	√	√
Modeliranje količine neiskorištenih vremenskih praznina	√	√	√	√
Modeliranje parkiranja	√	√	√	√
Polukružno skretanje	√	√	√	√
Cestovni priključci	√	√	√	√

Podaci pokazuju da su programi vrlo kompatibilni s obzirom na osnovne mogućnosti koje pružaju. Razlike u mogućnostima tih modela očituju se u veličini mreže koja se može analizirati, mogućnosti stvaranja matrica putovanja i dinamičkog pripisivanja prometnog toka na mrežu, vizualizaciji u 2D ili 3D obliku i drugim specifičnim uvjetima koji mogu ili ne mogu biti modelirani (prijelaz preko željezničke pruge, čvorišta izvan ravnina i dr.). [2, 540-541]

U nastavku će biti prikazan primjer proračuna razine uslužnosti kružnog raskrižja uz pomoć računalnog programa AIMSUN.

4. Postupak simulacije prometa na kružnom raskrižju Pećine - Tower Centar u Rijeci

U postupku simulacije prometa na kružnom raskrižju Pećine korišten je mikrosimulacijski računalni program AIMSUN (Advanced Interactive Microscopic Simulator for Urban and non-urban Networks). Program je razvio Odjel za statistiku i operacijska istraživanja Katalonskog Politehničkog Sveučilišta, u Barceloni. Taj prometni mikrosimulacijski računalni program u stanju je, pomoću računalne platforme, reproducirati

različite, stvarne prometne mreže i uvjete koji na njima vladaju. [13, 20]

Verzija programa AIMSUN 6 primijenjena je u sklopu izrade diplomskog rada pod nazivom „Simuliranje prometa s primjerom izrade mikrosimulacijskog modela za kružno raskrižje“ studentice Danijele Nežić [13], a u svrhu provjere kapaciteta kružnog raskrižja na lokaciji Pećine-Tower Centar. Rad je dijelom izrađen na Sveučilištu u Lisabonu, Portugal.

4.1. Područje istraživanja

Kružno raskrižje Pećine-Tower centar odabrano je kao lokacija za koju će se obaviti simuliranje prometa pomoću računalnog programa AIMSUN. Raskrižje se nalazi u istočnom dijelu šireg centra grada Rijeke, u stambenoj četvrti Pećine. Od strogog centra udaljeno je oko 3 kilometra. Na Slici 2., prikazan je položaj raskrižja u odnosu na okolne sadržaje. Raskrižje je smješteno uz sam rub trgovačkog centra (1), između željezničke pruge (2) i Stanice za tehnički pregled Pećine (3) (Slika 2).

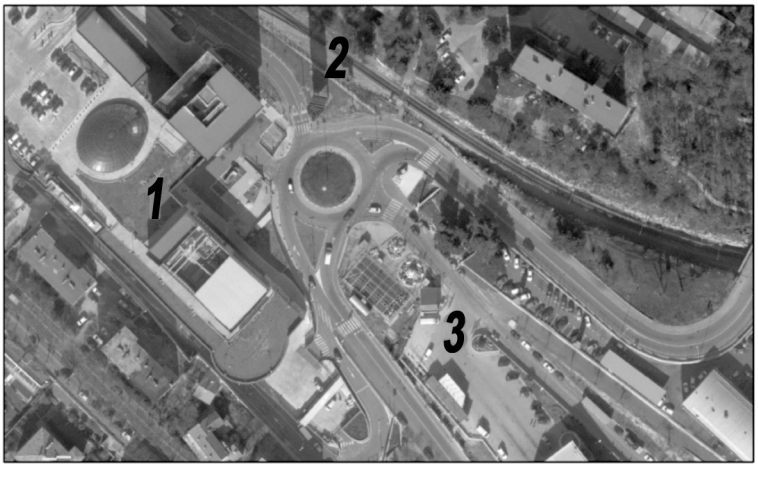

Slika 2. Lokacija kružnog raskrižja Pećine-Tower centar [13, 39]

Raskrižje je rekonstruirano u kružno, nedugo prije otvorenja „Tower Centra Rijeka“ 2006. godine, kako bi se, zbog izgradnje trgovačkog centra i kasnije planirane izgradnje izlaznog priključka s brze ceste D 404, poboljšao protok prometa i izbjegle gužve na raskrižju.

Lokacija raskrižja određena je brdovitim izgledom terena, a uski prostor između spomenuta 3 sadržaja u neposrednoj blizini, uvjetovao je nestandardnu geometriju raskrižja.

Križanje je to 4 privoza, a kao peti privoz može se smatrati jednosmjerna, ulazna cestu za Tower centar koja se odvaja od izlazne trake jednog od privoza (Radnička

Ulica) samo nekoliko desetaka metara nakon izlaza iz kružnog raskrižja. Kružno je raskrižje jednotračno, nesignalizirano, a prema veličini ubraja se u mala kružna raskrižja. Položaji i nazivi privoza prikazani su na Slici 3. Raskrižje nije u potpunosti izvedeno prema projektu pa dimenzije na terenu ne odgovaraju onima navedenima u projektnoj dokumentaciji. Podaci o plošnoj geometriji raskrižja iščitani su iz digitalnog ortofoto snimka grada Rijeke, dostupnog na stranicama grada Rijeke. Dobivene dimenzije zadovoljavajuće su za potrebe ovog ispitivanja. Kružno je raskrižje jednotračno, kao i svi privozi, osim dvotračnog izlaza iz trgovačkog centra. Širina prometnih traka je od 3.0 do 3.75 metara. Na širinu kružne kolničke trake od 5.0 metara nadodano je još 2.0 metra povoznog dijela za omogućavanje prolaza teškim vozilima s većim radijusom zakretanja. Vanjski radijus kružne kolničke trake je 17.0 metara. Kada se sa sjeveroistoka, Radničkom ulicom približavamo raskrižju, teren je u padu. Ako u raskrižje ulazimo Radničkom ulicom, ali s južne strane, tada se prema raskrižju penjemo.

privoz	Naziv privoza
1	Tehnički pregled Pećine
2	Radnička ulica sjever
3	Tower Centar izlaz
4	Tower Centar ulaz
5	Radnička ulica jug

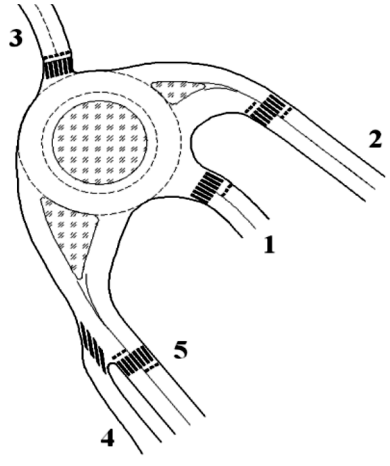

Slika 3. Položaj privoza kružnog raskrižja Pećine - Tower centar [13, 40]

Privozi Tehničkog servisa i Izlaza iz Tower centra su u ravnini. Na svim privozima nalaze se pješački prijelazi, a uz rub ceste postavljeni su pješački nogostupi širine od 1.5 do 2.5 metara. [13, 39-41]

4.2. Podaci o prometu

4.2.1. Podaci o prometu kružnim raskrižjem iz 2009. godine

Posljednji dostupni podaci o razinama uslužnosti prometa na kružnom raskrižju Pećine-Tower Centar su iz 2009. godine [11, 15]. Tada su, Grad Rijeka i Građevinski fakultet u Rijeci, proveli analiza čiji je cilj bio odrediti razine uslužnosti i utvrditi je li postojeće rješenje kružnog raskrižja zadovoljivo.

Tadašnje količine prometa prikazane su u Tablici 2., a razine uslužnosti dobivene Austrijskom metodom i iskazane stupnjem opterećenosti ulaza, u Tablici 3. Vidljivo je da su dobivena zasićenja po privozima značajno manja od granične vrijednosti od 90%.

Tablica 2. Količine prometa u popodnevnom vršnom satu 27.10.2009. (utorak) [11, 14]

Iz privoza	u privoz	MOT	OV	TV	ukupno vozila/sat	ukupno PAJ/sat
1	1	0	0	0	0	0
	2	1	65	1	67	67.5
	4	0	11	0	11	11
	5	3	22	1	26	25.5
2	1	0	2	0	2	2
	2	0	5	0	5	5
	4	0	82	0	82	82
	5	9	259	2	270	267.5
3	1	0	2	0	2	2
	2	1	154	1	156	156.5
	4	0	28	0	28	28
	5	2	94	2	98	99
5	1	2	25	0	27	26
	2	9	46	4	59	58.5
	4	5	128	0	133	130.5
	5	0	0	0	0	0

Tablica 3. Razine uslužnosti dobivene Austrijskom metodom, 2009. [11, 14]

		privoz 1	privoz 2	privoz 3	privoz 5
Prometno opterećenje izlaza	M_A [PAJ/h]	31	287	0	648
Prometno opterećenje ulaza	M_E [PAJ/h]	104	359	284	219
Opterećenje na kružnom voznom traku	M_K [PAJ/h]	353	170	529	165
Faktor geometrije ulaza	a [/]	0.26	0.06	0	0
Faktor broja voznih trakova u krugu	b [/]	1	1	1	1
Faktor broja trakova na ulazu	c [/]	1	1	0.65	1
Propusna moć ulaza	L [PAJ/h]	1179	1334	1030	1353
Stupanj opterećenosti ulaza	A [%]	**9**	**27**	**18**	**16**

4.2.2. Podaci o prometu kružnim raskrižjem iz 2013. Godine

Brojanje prometa na kružnom raskrižju Pećine-Tower centar provedeno je u utorak, 19.11.2013. godine. Promet na raskrižju sniman je videokamerom u jutarnjem i popodnevnom vršnom periodu u trajanju od sat vremena, a zatim je preko videosnimki obavljeno brojanje prometa.

Promet kroz raskrižje većim dijelom čine osobna vozila, ali zbog pristupa Stanici za tehnički pregled Pećine, preko jednog od privoza, kroz raskrižje prometuju i teška teretna vozila, kao i teretna vozila kojima se obavlja dostava u trgovački centar čija se ulazna i izlazna cesta priključuju na kružno raskrižje.

Za jutarnji vršni period odabrano je vrijeme od 7:15 do 8:15 sati. Tada je promet raskrižjem povećan zbog odlaska ljudi na posao, ali i zbog dostavnih vozila koja se kreću prema trgovačkom centru. Na dan snimanja, vrijeme je bilo oblačno i kišovito. Na raskrižju nije bilo izvanrednih situacija poput radova na prometnicama ili privremenih regulacija prometa.

Brojanje prometa u popodnevnom vršnom periodu, provedeno je od 15:30 do 16:30 sati, vremenu nesposredno nakon kraja radnog vremena. Vrijeme je i u popodnevnim satima bilo lagano kišovito. Također, u okolici raskrižja nije bilo izvanrednih situacija.

Rezultati brojanja prometa prikazani su u Tablicama 4 i 5. [13, 42-43]

Usporedbom podataka prometnih opterećenja vidljivo je da se broj vozila povećao u odnosu na podatke iz 2009. godine. Ipak, privozi nisu jednako opterećeni u jutarnjim i poslijepodnevnim satima. Ujutro, glavninu optererećenja čini promet Radničkom ulicom (privozi 2 i 5). U popodnevnim su satima količine prometa veće, ali i ravnomjernije raspoređene. Kao mjerodavan za daljnju izradu analize prometa, odabran je promet iz popodnevnog vršnog sata.

Tablica 4. Količine prometa u jutarnjem vršnom satu 19.11.2013. (utorak) [13, 43]

iz privoza	u privoz	MOT	OV	TV	TTV	TTV+P	ukupno vozila/sat	ukupno PAJ/sat
1	1	0	0	0	0	0	0	0
	2	0	8	0	0	0	8	8
	4	0	0	0	0	0	0	0
	5	0	2	0	0	0	2	2
2	1	0	52	6	0	0	58	61
	2	0	12	4	0	0	16	18
	4	2	58	8	0	0	68	71
	5	2	190	20	14	0	226	249
3	1	0	26	1	0	0	27	27.5
	2	0	56	6	8	0	70	81
	4	0	0	0	4	0	4	8
	5	0	18	4	0	0	22	24
5	1	2	6	2	0	0	10	10
	2	0	192	10	4	0	206	215
	4	0	8	0	0	0	8	8
	5	0	2	0	0	0	2	2

Pretpostavka je da će se većom gustoćom prometa u popodnevnom periodu dobiti realnija slika prometnog funkcioniranja predmetnog raskrižja. [13, 44]

Tablica 5. Količine prometa u popodnevnom vršnom satu 19.11.2013. (utorak) [13, 44]

iz privoza	u privoz	MOT	OV	TV	TTV	TTV+P	ukupno vozila/sat	ukupno PAJ/sat
1	1	0	0	0	0	0	0	0
	2	0	150	8	4	0	162	170
	4	0	32	0	0	0	32	32
	5	0	44	8	0	0	52	56
2	1	0	30	0	0	4	34	40
	2	0	60	2	0	0	62	63
	4	0	160	12	0	0	172	178
	5	0	120	6	6	0	132	141
3	1	0	8	0	0	0	8	8
	2	4	290	2	0	0	296	295
	4	0	20	0	0	0	20	20
	5	0	96	2	0	0	98	99
5	1	0	10	0	0	0	10	10
	2	2	158	6	0	0	166	168
	4	0	28	2	0	0	30	31
	5	0	2	0	0	0	2	2

4.3. Proračun kapaciteta kružnog raskrižja Pećine-Tower centar za podatke o prometu iz 2013.godine

4.3.1. Proračun kapaciteta kružnog raskrižja Austrijskom metodom

Smjernice za projektiranje i opremanje raskrižja kružnog oblika-rotora, iz 2002.g. [15, 13], za proračun propusne moći preporučuju dvije metode: austrijsku i australsku. Kod malih i srednjih kružnih raskrižja obično se koristi austrijska metoda. Ona je upotrijebljena i u ovom radu, za analizu razina uslužnosti kružnog raskrižja Pećine-Tower centar (Tablica 6), ali i kao pomoć za kalibriranje simulacijskog modela u AIMSUN-u. [13, 45]

Tablica 6. Razine uslužnosti dobivene Austrijskom metodom, 2013.g. [13, 47]

		privoz 1	privoz 2	privoz 3	privoz 5
Prometno opterećenje izlaza	M_A [PAJ/h]	58	696	0	298
Prometno opterećenje ulaza	M_E [PAJ/h]	258	422	422	211
Opterećenje na kružnom voznom traku	M_K [PAJ/h]	559	121	543	406
Faktor geometrije ulaza	a [/]	0.26	0.06	0	0
Faktor broja voznih trakova u krugu	b [/]	1	1	1	1
Faktor broja trakova na ulazu	c [/]	1	1	0.65	1
Propusna moć ulaza	L [PAJ/h]	990	1355	1017	1139
Stupanj opterećenosti ulaza	A [%]	**9**	**27**	**18**	**16**

4.3.2. Proračun kapaciteta kružnog raskrižja pomoću računalnog programa SIDRA INTERSECTION 5.1.

Razina uslužnosti određena je i pomoću računalnog programa SIDRA INTERSECTION 5.1. Uz podatke o prometu i geometriji, program u obzir uzima karakteristike vozila i ponašanje vozača te omogućava i unos podataka o količinama pješaka. Program nudi mogućnost analize različitih tipova raskrižja, a među njima i nesignalizirana kružna raskrižja. Nakon odabira kružnog tipa raskrižja i unosa podataka o geometriji, program generira tlocrtni izgled raskrižja. Unose se podaci o brzinama kretanja vozila, duljini vozila i razmaku koji vozači održavaju s prethodnim vozilom te podaci o pješacima na svakom privozu. Kao posljednje, program nudi nekoliko načina izražavanja razine uslužnosti te je za to raskrižje odabran delay (vremenski gubitak u odnosu na vrijeme idealnog prolaza kroz raskrižje, bez stajanja ili usporavanja). [13, 48]

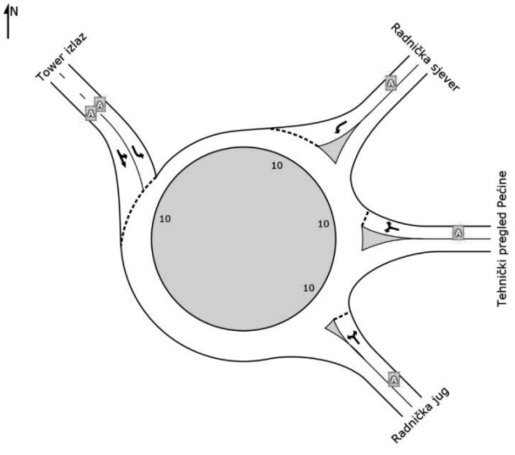

Slika 4. Tlocrtni izgled raskrižja u programu SIDRA INTERSECTION s dobivenim razinama uslužnosti [13, 49]

4.3.3. Izrada AIMSUN simulacijskog modela za kružno raskrižje Pećine-Tower centar

4.3.3.1. Postupak izrade modela

Prvi korak izrade simulacijskog modela bio je definiranje prometne mreže. Preko ortofoto snimaka grada Rijeke, iscrtana je približna geometrija raskrižja i ona je poslužila kao podloga za crtanje prometne mreže u AIMSUN-u. Za svaku dionicu (section) definirano je kakvu vrstu prometnice predstavlja. Za cijelu prometnu mrežu modela odabrana je kategorija gradske ceste (Urban Road), s ograničenjem brzine do 50 km/h i drugim parametrima.

Na prometnu mrežu nadodani su centroidi i „spojeni“ s mjestima ulaza i izlaza vozila ili pješaka (Slika 5). Centroidi pripadaju odgovarajućoj konfiguraciji centroida

i oblikuju izgled O/D matrice koja je potrebna za upisivanje količina prometa. Svakom centroidu pridružene se točke na prometnoj mreži koje su obilježene kao ulazne ili izlazne točke. Za svaki „dodani" ulaz, odnosno izlaz, u matricu putovanja dodaju se odredišta, odnosno destinacije između kojih se vozila ili, u ovom slučaju i pješaci, mogu kretati.[13, 49-51]

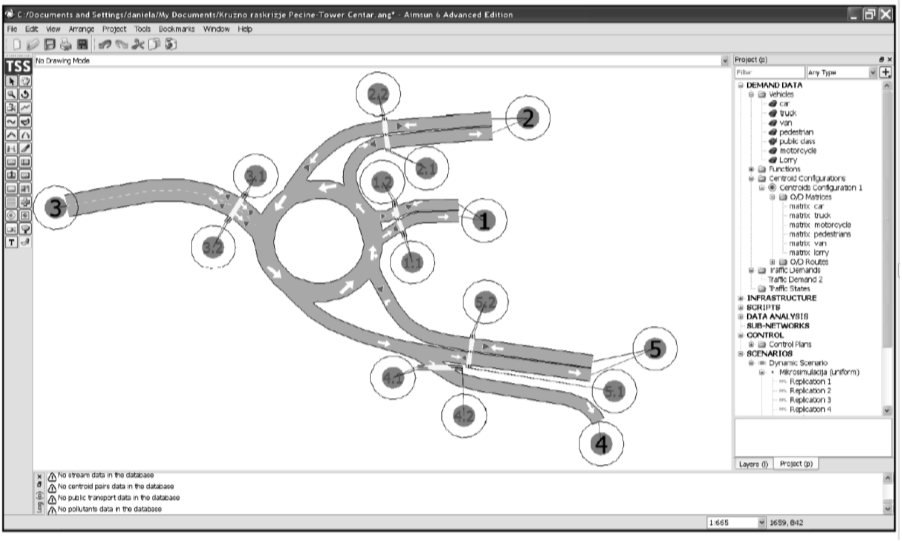

Slika 5. Centroidi nadodani na prometnu mrežu (AIMSUN) [13, 52]

Zatim su definirane kategorije vozila koje su korištene u simulacijama prometnog modela. Neke su kategorije već bile ponuđene programom te je bilo potrebno određene parametre samo prilagoditi prometnim uvjetima u raskrižju. Preostale su kategorije kreirane za potrebe ovog modela. Korištene kategorije vozila su: motocikli, osobna vozila, teretna vozila, teška teretna vozila, teška teretna vozila s poluprikolicom i pješaci. Svakoj matrici putovanja pridružena je određena kategorija vozila. To znači da je za svaku kategoriju vozila definirana zasebna matrica putovanja. Količine prometa dobivene su iz podataka u Tablici 4. [13, 52]

Posljednji korak je izrada dinamičkog scenarija u kojem se povezuje sve do tada definirano programom. Odabrana je simulacija na mikro razini. Za nju je bilo potrebno definirati kojim će teorijama slijeda vozila i promjene prometnog traka, AIMSUN modelirati ponašanje vozila u prometu. Za model slijeda vozila odabran je onaj koji u obzir uzima razmak održavan između vozila i procjenu usporavanja prethodnog vozila (preko srednje vrijednosti i faktora osjetljivosti, a). Definirani su i preostali parametri, poput brzine ulaska u kolonu (Queuing Up Speed), brzine izlaska iz kolone (Queue Leaving Speed), vremenskog koraka (Simulation Step), vremena reakcije (Reaction Time) i vremena reakcije u stanju mirovanja (Reaction Time at Stop). Među ponuđenim raspodjelama za generiranje vozila na ulaznim dionicama prometne mreže za čitavo je

raskrižje odabrana uniformna raspodjela. Budući da se radi o stohastičkom modelu čije slučajne varijable uzrokuju različite rezultate, za svaku pokrenutu simulaciju, konačni se rezultati dobivaju kao srednja vrijednost svih izvršenih simulacija. Broj simulacija je proizvoljan, određuje se prema kompleksnosti prometne mreže i samog modela, a preporuka je provesti barem 4 do 5 simulacija.[3, 115] Prometna mreža analiziranog simulacijskog modela prilično je jednostavna jer se radi o samo jednom raskrižju te je provedeno 6 simulacija. Naravno, prije dobivanja zadovoljavajućih rezultata, model je bilo potrebno kalibrirati. [13, 53]

4.3.3.2. Kalibracija modela

Osim numeričkih vrijednosti, rezultat svake provedene simulacije je i animacija koja prikazuje kretanje vozila kroz prometnu mrežu. Pregledavanjem svih šest snimki, temeljem vizualnog uočavanja, pokušalo se ustanoviti što je problem i kako ga kalibrirati. Primjerice, u početku su se zbog odabira eksponencijalne razdiobe vozila, na privozu 3 stvarali veliki zastoji i dugačke kolone vozila (Slika 6), što nije uočeno na raskrižju. Promjenom razdiobe koja definira ulazak vozila u prometnu mrežu, problem je riješen. Drugi problemi bili su uzrokovani nepravilno zadanim parametrima, poput prevelike brzine prolaska vozila kroz raskrižje zbog nedovoljnih ograničenja, i slično. [13, 53]

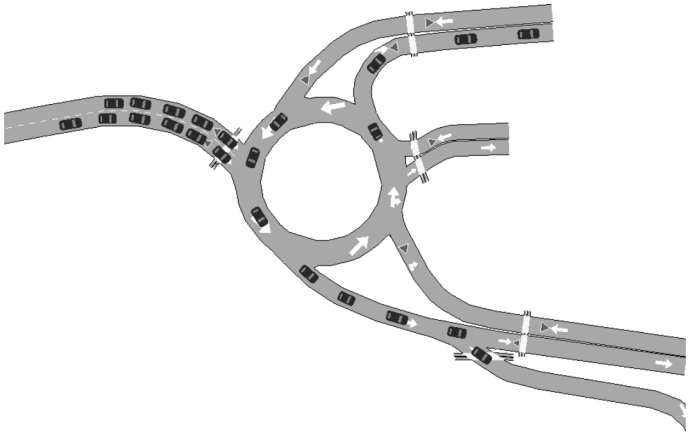

Slika 6. Prometni zastoji na privozu 3 (izlaz iz Towera) zbog neispravno kalibriranog modela [13, 54]

Rezultati modeliranja odabranih prometnih pokazatelja dobivenih kalibriranim AIMSUN prometnim modelom uspoređeni su s vrijednostima dobivenima opažanjem i mjerenjem na terenu te postojećim metodama analize operativnih karakteristika kružnih raskrižja (Austrijska metoda, SIDRA INTERSECTION). Kao dodatan čimbenik utvrđivanja vjerodostojnosti simulacijskog modela, usporedbe rezultata triju metoda provedene su i za dvostruko veće prometno opterećenje od zabilježenog.

Uspješnost postupka kalibracije potvrđena je usporedbom izmjerenih i modeliranih vrijednosti vremenskih gubitaka (delay time), nezavisnog prometnog pokazatelja koji nije korišten u postupku kalibracije mikrosimulacijskog prometnog modela. [13, 54]

4.3.3.3. Validacija i rezultati simulacijskog modela

Rezultati dobiveni AIMSUN simulacijskim modelom, za opis razine uslužnosti na razini cijele prometne mreže daju parametre prikazane u Tablici 7. Prikazane su srednje vrijednosti tih parametara iz svih šest provedenih simulacija, a odnose se na cijelo raskrižje. [13, 55]

Vremenski gubici dobiveni u AIMSUN-u su iz jedinice s/km pretvoreni u jedinice s/voz kako bi bilo moguće rezultate iz AIMSUN-a usporediti s rasponima prosječnih vremenskih gubitaka preporučenih metodom HCM2010.

Simulacijski model u AIMSUN-u definira propusnu moć kružnog raskrižja Pećine-Tower centar s kategorijom A. [13, 56]

Tablica 7. Rezultati analize uslužnosti cijelog raskrižja (AIMSUN) [13, 55]

	Naziv parametra	**Vrijednosti**	
Delay Time	Vremenski gubitak	69,11	[s/km]
Density	Gustoća prometa	29,58	[voz/km]
Flow	Protok	1544	[voz/h]
Harmonic Speed	Harmonijska brzina	10,47	[km/h]
Speed	Prosječna brzina	13,09	[km/h]
Stop Time	Vrijeme mirovanja	84,51	[s/km]
Stops	Broj zaustavljanja	8,09	[#/voz/km]
Total Distance Traveled	Ukupni put prevaljen	199,86	[km]
Total Travel Time	Ukupno vrijeme putovanja	14,83	[h]
Travel Time	Prosječno vrijeme putovanja	343,81	[s/km]

4.4. Proračun kapaciteta kružnog raskrižja Pećine-Tower centar za uvećano prometno opterećenje

S obzirom da je prometno opterećenje kroz raskrižje daleko ispod graničnih vrijednosti, htjelo se utvrditi bi li simulacijski model dao zadovoljavajuće rezultate i za veće prometno opterećenje. Kao i u prethodnom slučaju, na jednak je način u AIMSUN-u provedeno šest simulacija, ali za dvostruko veće prometno opterećenje u odnosu na Tablicu 4. S uvećanim podacima o prometu iz Tablice 4, proveden je i proračun kapaciteta raskrižja Austrijskom metodom i računalnim programom SIDRA INTERSECTION. [13, 58]

4.4.1. Austrijska metoda

Jednakim postupkom kao i u poglavlju 4.3.1., određena je propusna moć kružnog raskrižja za uvećano prometno opterećenje, a dobiveni rezultati prikazani su u Tablici 8. U ovom slučaju privozi 1 i 3 ne zadovoljavaju, prometno opterećenje na njima je neprihvatljivo i znatno veće od gornje granice od 90%. [13, 59-60]

Tablica 8. Razine uslužnosti dobivene Austrijskom metodom za povećano prometno opterećenje [13,59]

		privoz 1	privoz 2	privoz 3	privoz 5
Prometno opterećenje izlaza	M_A [PAJ/h]	116	1392	0	596
Prometno opterećenje ulaza	M_E [PAJ/h]	516	844	844	422
Opterećenje na kružnom voznom traku	M_K [PAJ/h]	1118	242	1086	812
Faktor geometrije ulaza	a [/]	0.26	0.06	0	0
Faktor broja voznih trakova u krugu	b [/]	1	1	1	1
Faktor broja trakova na ulazu	c [/]	1	1	0.65	1
Propusna moć ulaza	L [PAJ/h]	479	1211	535	778
Stupanj opterećenosti ulaza	A [%]	**108**	**70**	**103**	**54**

4.4.2. SIDRA INTERSECTION

Povećane količine prometa korištene su i kao ulazni podaci za analizu propusne moći kružnog raskrižja Pećine-Tower centar uz pomoć računalnog programa SIDRA INTERSECTION. Dobivene razine uslužnosti nisu zadovoljavajuće, a problem je, također, u privozima 1 i 3 s razinama uslužnosti F (Slika 7). [13, 60]

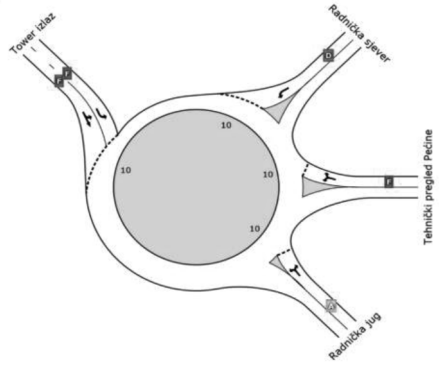

Slika 7. Dobivene razine uslužnosti za uvećano prometno opterećenje (SIDRA) [13, 60]

4.4.3. AIMSUN

U simulacijski model razvijen AIMSUN računalnim programom, ubačeni su uvećani podaci o prometu te su dobiveni numerički rezultati prikazani u Tablici 9. Oni se odnose na cijelo raskrižje i predstavljaju srednje vrijednosti parametara svih privoza. [13, 61]

Maksimalni vremenski gubitak, izražen u jedinici s/km ponovno je pretvoren u jedinicu s/voz i uspoređen s rasponima preporučenim metodom HCM2010 te je za povećano prometno opterećenje dobivena razina uslužnosti D.

Tablica 9. Rezultati analize uslužnosti cijelog raskrižja za dvostruko prometno opterećenje (AIMSUN) [13, 61]

	Naziv parametra	**Vrijednosti**	
Delay Time	Vremenski gubitak	318,74	[s/km]
Density	Gustoća prometa	82,39	[voz/km]
Flow	Protok	2312	[voz/h]
Harmonic Speed	Harmonijska brzina	5,85	[km/h]
Speed	Prosječna brzina	9,55	[km/h]
Stop Time	Vrijeme mirovanja	365,68	[s/km]
Stops	Broj zaustavljanja	16,14	[#/voz/km]
Total Distance Traveled	Ukupni put prevaljen	276,88	[km]
Total Travel Time	Ukupno vrijeme putovanja	40,16	[h]
Travel Time	Prosječno vrijeme putovanja	617,07	[s/km]

Takva razina uslužnosti odnosi se na cijelo raskrižje i predstavlja srednju vrijednost uslužnosti svih privoza, a to se može vidjeti i iz animacija dobivenih kao dinamički rezultat simulacijskog modela. Animacije jasno prikazuju da prometno zagušenje nije jednako na svim privozima. Ono se značajno razlikuje između privoza 1 i 3 s potpunim zagušenjem prometa, privoza 2 s prihvatljivim zastojima te privoza 5 gdje vozila prometuju nesmetano i gotovo bez zastoja. [13, 63]

5. Zaključak

Radom je dan osvrt na kružna raskrižja i simuliranje prometa, kao teorijskoj podlozi za uvod u izradu prometnog modela pomoću mikrosimulacijskog računalnog programa, AIMSUN-a.

AIMSUN stohastički prometni model, primijenjen je na kružnom raskrižju Pećine-Tower centar u Rijeci. Podaci o količinama i smjerovima kretanja prometa prikupljeni su snimanjem prometnih tokova na raskrižju, u jutarnjem i popodnevnom vršnom razdoblju u trajanju od sat vremena. Informacije o ponašanju vozača u prometu te karakteristike vožnje kroz raskrižje prikupljene su opažanjem na terenu i samim sudjelovanjem u prometu kroz kružno raskrižje.

Prikupljene informacije poslužile su kao ulazni podaci za prometni simulacijski model. Na temelju dobivenih rezultata simulacije, parametri unutar programa su podešavani kako bi se konačni kalibrirani rezultati u što većoj mjeri poklapali s rezultatima dobivenima neovisnim analizama: Austrijskom metodom i računalnim programom SIDRA INTERSECTION.

Uspoređivan je kapacitet raskrižja za stvarno prometno opterećenje dobiveno brojanjem na terenu te za pretpostavljeno dvostruko veće prometno opterećenje. Re-

zultati dobiveni AIMSUN mikrosimulacijskim modelom te računalnim programom SIDRA INTERSECTION izraženi su kroz prosječni vremenski gubitak vozila, a rezultati dobiveni Austrijskom metodom su izraženi stupnjem opterećenosti ulaza te su uspoređeni s razinama uslužnosti propisanim američkom metodom za analizu propusne moći HCM2010 (Highway Capacity Manual 2010), a koja se prema Pravilniku o osnovnim uvjetima kojima javne ceste izvan naselja i njihovi elementi moraju udovoljavati sa stajališta sigurnosti prometa preporučuje za primjenu u Hrvatskoj. Za stvarno, relativno malo, izmjereno prometno opterećenje sve tri metode su pokazale dobre razine uslužnosti: razina uslužnosti A, odnosno stupanj opterećenosti ulaza daleko ispod granične vrijednosti od 90% dok za dvostruko prometno opterećenje rezultati sve tri metode daju loše razine uslužnosti D-F, ovisno o privozima. Kako su analitičke metode poslužile za provjeru primijenjene simulacijske metode, može se zaključiti, s obzirom na stupanj podudarnosti rezultata, da je simulacijski model dovoljno dobro postavljen i da se uspjelo, na zadovoljavajućoj razini simulirati promet u kružnom raskrižju Pećine-Tower centar. Naravno da je model moguće dodatno kalibrirati te dobiti i bolju simulaciju prometa u kružnom raskrižju, ali su za to potrebne detaljnije informacije o prometnim karakteristikama na raskrižju te obavljanje ispitivanja kako bi se ustanovile idealne vrijednosti podesivih parametara unutar simulacijskog modela.

Literatura

1. Barišić, I. et al. (2014.), Regulativa za kružna raskrižja u Republici Hrvatskoj // Četvrti BiH kongres o cestama, str.28.
2. Breški, D. et al. (2006.), Analiza osjetljivosti parametara simulacijskog modela CORSIM, Građevinar, 58 (7), str. 539-548.
3. Breški, D. et al. (2010.), Primjena simulacijskih modela pri izradi prometne analize, Građevinar, 62 (2), str. 113-122.
4. Cvitanić, D. Prometna tehnika, Predavanja na Sveučilišnom diplomskom studiju, Split, Građevinsko-arhitektonski fakultet,
5. http://www.gradst.hr/Portals/9/PropertyAgent/1167/Files/2706/prometnatehnikazaweb3.pdf>
6. Cvitanić, D. Teorija prometnog toka, Predavanja na Sveučilišnom diplomskom studiju, Split, Građevinsko-arhitektonski fakultet,
7. http://www.gradst.h/Portals/9/docs/katedre/prometnice/teorijaprometnogtoka.pdf
8. Cvitanić, D. et al. (2007.) Primjena mikrosimulacijskih modela u postupku izbora elemenata gradske ulične mreže // Zbornik radova IV hrvatskog kongresa o cestama /Boris Raus (ur.).
9. Cavtat : VIA VITA, 2007. 121-122
10. Hoogendoorn, S. P. (2001), State of the art of Vehicular Traffic Flow Modelling, Journal of Systems and Control Engineering, Delft University of Technology,
11. http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.106.9913
12. Ivanac, V. (2010.), Simulator prometa, Diplomski rad, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu
13. Ivanac, V. (2011.), Transformacija realne prometne mreže u mrežu stanica staničnog automata, Istraživački seminar, Zagreb, Fakultet elektrotehnike i računarstva
14. https://www.fer.unizg.hr/_download/repository/Ivanac_Transformacija_realne_prometne_mreze_u_mrezu_stanica_stanicnog_automata%5B1%5D.pdf
15. ITS, University of Leeds, (2000.), Final Report for Publication: SMARTEST;http://www.its.leeds.ac.uk/projects/smartest/finrep.PDF
16. Legac, I. et al. (2010.), Korelacija oblikovnosti i sigurnosti u raskrižjima s kružnim tokom prometa - Analiza postojećih i potencijalnih lokacija za primjenu kružnih raskrižja na području grada

Rijeke, Sveučilište u Rijeci, Građevinski fakultet
17. Lieberman, E. i Rathi, A. K. (2001.), Traffic simulation, Transportation Research Board Special Report, http://www.tft.pdx.edu/docs.htm
18. Nežić, D. (2014), Simuliranje prometa s primjerom izrade mikrosimulacijskog modela za kružno raskrižje, Diplomski rad, Građevinski fakultet, Sveučilište u Rijeci
19. Smjernice za projektiranje kružnih raskrižja na državnim cestama, Naručitelj: Hrvatske ceste d.o.o. Zagreb, Izrađivač: Građevinski fakultet Sveučilišta u Rijeci, Rijeka, 2014.
20. Smjernice za projektiranje i opremanje raskrižja kružnog oblika – rotora, Naručitelj: Ministarstvo pomorstva, prometa i veza, Hrvatske ceste d.o.o. Zagreb, Izrađivač: Institut prometa i veza, Zagreb 2002.
21. Šurdonja, S. et al. (2013.), Optimization of roundabout design elements. // Tehnički vjesnik (Technical gazette). 20, 3; str. 533-539

Sanja Šurdonja, Daniela Nežić, Aleksandra Deluka-Tibljaš

The Roundabout Capacity Estimate Microsimulation Model

Abstract

Computer programs designed for traffic microsimulation have gained considerable popularity and widespread use, both in practical application as well as in research works. The number of traffic simulation models has increased significantly and until the end of the last century there were more then 50 simulation models available already. Their advantage is the ability to predict behaviour in everyday traffic, as well as in emergency situations. Unlike conventional analytical methods for traffic analysis, simulation models can also display the dynamics of traffic systems and 2D or 3D animations, as a result of their modeling, are much more understandable to incompetent population.
The aim of this paper is to briefly describe the basic settings of microsimulation computer programs. The AIMSUN computer program will be described in details and the process of making the AIMSUN (Advanced Interactive Microscopic Simulator for Urban and Non-Urban Networks) microsimulation model for roundabout in Radnička Street in Rijeka will be shown.
Since the traffic simulation computer programs are commonly used to estimate characteristics of traffic flow, such as the average travel time, the capacity of roads or the average speed of vehicles, models are based on adjusting the input parameters in order to reach a reasonable matching between model results and field data. This process is called calibration, and it is necessary in proving the authenticity of the simulation model and model validation. For the calibration and validation of the planned simulation model in this case, the obtained results were compared with those obtained by another analytical capacity method (Austrian method) and the SIDRA INTERSECTION (Signalised & Unsignalised Intersection Design and Research Aid) computer program which is based on the Australian calculation method for roundabout capacities.

Key words: traffic simulation, the Pećine-Tower Centar roundabout, Rijeka, microsimulation model, AIMSUN, SIDRA INTERSECTION