

UDK 625.71.001.4:656.11

Primljeno 3. 2. 2006.

Analiza osjetljivosti parametara simulacijskog modela CORSIM

Deana Breški, Dražen Cvitanić, Ivan Lovrić

Ključne riječi

simulacijski model CORSIM, parametri modela, prometni tok, analiza osjetljivost, semaforizirano raskrižje

Key words

CORSIM simulation model, model parameters, traffic flow, sensitivity analysis, traffic light intersections

Mots clés

modèle de simulation CORSIM, paramètres du modèle, écoulement du trafic, analyse de sensibilité, carrefour à feux

Ключевые слова

симуляционная модель CORSIM, параметры модели, поток движения, анализ чувствительности, светофоризированный перекресток

Schlüsselworte

Simuliermodell CORSIM, Modellparameter, Verkehrsstrom, Empfindlichkeitsanalyse, semaforisierte Kreuzung

D. Breški, D. Cvitanić, I. Lovrić

Pregledni rad

Analiza osjetljivosti parametara simulacijskog modela CORSIM

Ističe se važnost računala za simulaciju odvijanja prometnih tokova. Ukratko je opisan mikroskopski simulacijski model CORSIM te su prikazani rezultati analize osjetljivosti određenih ulaznih parametara koji se upotrebljavaju pri analizi učinkovitosti semaforiziranih raskrižja. Dobiveni rezultati upozoravaju na utjecaj pojedinog parametra na procjenu prosječnog zakašnjenja po vozilu te koji od njih je potrebno kalibrirati s obzirom na lokalne uvjete odvijanja prometnog toka.

D. Breški, D. Cvitanić, I. Lovrić

Subject review

Sensitivity analysis of the CORSIM simulation model parameters

The significance of computers in traffic flow simulation is emphasized. The microscopic simulation model CORSIM is briefly described, and results are given for sensitivity analysis of some input parameters used in studying efficiency of traffic light intersections. The results obtained show the influence individual parameters exert on the estimate of an average delay per vehicle, and indicate which parameter needs to be calibrated to take into account local traffic flow conditions.

D. Breški, D. Cvitanić, I. Lovrić

Ouvrage de syntèse

Analyse de sensibilité des paramètres du modèle de simulation CORSIM

L'accent est mis sur l'importance des ordinateurs dans la simulation de l'écoulement du trafic. Le modèle microscopique de simulation nommé CORSIM est décrit, et les résultats sont fournis pour l'analyse de sensibilité de quelques paramètres d'entrée utilisés dans l'étude d'efficacité de carrefours à feux. Les résultats obtenus montrent l'influence exercée par paramètres individuels sur l'estimation du retard moyen par véhicule, et indiquent quel paramètre doit être calibré pour prendre en compte les conditions locales de l'écoulement du trafic.

Д. Брешки, Д. Цвитанич, И. Ловрич

Обзорная работа

Анализ чувствительности параметров симуляционной модели CORSIM

В работе подчёркивается важность компьютера для симуляции развития потоков движения. Вкратце описана микроскопическая симуляционная модель CORSIM, а также показаны результаты анализа чувствительности определённых входных параметров, употребляемых при анализе эффективности светофоризированных перекрёстков. Полученные результаты предупреждают о влиянии отдельного параметра на оценку среднего опоздания по транспортному средству, а также о том, какой из них необходимо калибровать, принимая во внимание местные условия развития потока движения.

D. Breški, D. Cvitanić, I. Lovrić

Übersichtsarbeit

Analyse der Empfindlichkeit der Parameter des Simuliermodells CORSIM

Man betont die Wichtigkeit der Rechenanlage für die Simulierung der Abwicklung von Verkehrsströmen. In Kürze ist das mikroskopische Simuliermodell CORSIM beschrieben, und weiter werden die Ergebnisse der Analyse der Empfindlichkeit gewisser Eingangparameter dargestellt, die bei der Analyse der Wirksamkeit von semaforisierten Kreuzungen genützt werden. Die gewonnenen Ergebnisse weisen auf den Einfluss einzelner Parameter auf die Abschätzung der durchschnittlichen Verspätung je Fahrzeug hin, sowie welches davon kalibriert werden muss mit Hinblick auf die lokalen Bedingungen der Abwicklung der Verkehrsströme.

Autori: Mr. sc. **Deana Breški**, dipl. ing. građ.; doc. dr. sc. **Dražen Cvitanić**, dipl. ing. građ., Građevinsko-arhitektonski fakultet Sveučilišta u Splitu; mr. sc. **Ivan Lovrić**, dipl. ing. građ, Građevinski fakultet Sveučilišta u Mostaru

1 Uvod

Kvaliteta odvijanja prometnih tokova podrazumijeva slobodu kretanja, brzinu i vrijeme putovanja, prekide u prometu, udobnost i sigurnost vožnje te cijenu koštanja, a izražava se pojmom *razine uslužnosti*. Za poboljšanje kvalitete odvijanja prometnih tokova i time povećanja razine uslužnosti postoje raznovrsne mjere - od regulacijskih do manjih i većih građevinskih zahvata u prostoru. Postojanje različitih mogućih rješenja uvijek dovodi do pitanja koje je najpovoljnije. Kao posljedica potrebe za vrednovanjem pojedinog rješenja, tijekom vremena u svijetu su razvijeni, a i dalje se razvijaju, različiti modeli koji se upotrebljavaju za analizu funkcioniranja i ocjenu učinkovitosti pojedinih dijelova cestovnoga prometnog sustava.

Ovisno o načinu nastanka i temeljnim pretpostavkama na kojima su razvijeni, modeli se općenito mogu podijeliti na empirijske, analitičke i simulacijske. *Empirijski modeli* predviđaju ponašanje sustava ne temelju relacija dobivenih primjenom statističkih metoda, najčešće regresijskom analizom na većem uzorku terenskih podataka. *Analitički modeli* su razvijeni iz teoretskih razmatranja, a zatim su kalibrirani i vrednovani na temelju terenskih podataka. *Simulacijski se modeli* koriste algoritmima s pomoću kojih definiraju ponašanje prometnog toka na način da modeliraju kretanje svakoga individualnog vozila i njihovu međusobnu interakciju te se podaci i prometni pokazatelji potrebni za vrednovanje pojedinog rješenja "mjere" iz tako simuliranoga prometnog toka. Za razliku od empirijskih i analitičkih modela koji su uglavnom *deterministički*, što znači da ne sadrže slučajne varijable i da će za iste ulazne podatke dati uvijek isti izlazni rezultat, *simulacijski su modeli* uglavnom *stohastičke* prirode, tj. za modeliranje prometnog toka koriste se i slučajnim varijablama odnosno razdiobe vjerojatnosti.

U posljednjih tridesetak godina simulacija prometa pomoću računala postala je jedan od važnih "alata" koji omogućuje vrednovanje postojećih i/ili alternativnih projektnih rješenja, osobito zbog činjenice što je razvoj grafičkih sučelja omogućio dinamičku animaciju odvijanja prometa kojom se može pratiti stvaranje eventualnih prometnih zagušenja na promatranoj mreži i na taj način definirati potencijalna "uska grla" koja svojom propusnom moći neće zadovoljiti prometnu potražnju.

Ako se promatra gradsko područje, na kvalitetno odvijanje prometnih tokova velik utjecaj ima najpovoljnije projektiranje raskrižja (geometrije i načina regulacije) jer su upravo to lokacije gdje se stvaraju veći zastoji na uličnoj mreži. Pri analizi i ocjeni funkcioniranja *semaforiziranih* raskrižja, osim proračuna propusne moći te definiranja stupnja zasićenosti, tj. odnosa prometne potraž-

nje i propusne moći, rabe se i drugi prometni pokazatelji. Ovi su pokazatelji, odnosno *mjere efikasnosti* ili *učinkovitosti*: prosječno zakašnjenje, duljina repa, broj zaustavljanja, vrijeme putovanja, potrošnja goriva, emisija plinova i dr. Kao osnovna mjera za definiranje razine uslužnosti semaforiziranog raskrižja primjenjuje se vrijednost *prosječnog zakašnjenja* po vozilu i to za privoze pojedinačno i za raskrižje u cjelini.

Danas se u Hrvatskoj za procjenu zakašnjenja i drugih mjera efikasnosti semaforiziranih raskrižja uglavnom uzimaju analitički modeli razvijeni na dostignućima teorije repova (u prvom redu Highway Capacity Manual [1] (tj. HCM) dok je primjena simulacijskih modela još uvijek u začetku. Budući da korištenje računalnog simulacijom u svijetu ima sve veću ulogu u projektiranju i vrednovanju pojedinih rješenja, u ovome članku prikazane su osnovne karakteristike simulacijskih modela, zatim je sažeto opisan CORSIM, koji je jedan od najčešće upotrebljivanih i vrednovanih modela na području simulacije prometnih tokova, te je izvršena analiza osjetljivosti pojedinih parametara CORSIM-a relevantnih pri analizi semaforiziranih raskrižja.

2 Općenito o simulacijskim modelima

Upotreba simulacijskih modela na istraživačkom i stručnom području otvara mogućnost usporedbe varijantnih projektnih rješenja te provjeru i vrednovanje novih načina u vođenju prometa prije nego što se eventualni nedostaci novih rješenja odraze na terenu.

Za što realniju simulaciju cestovnoga prometnog sustava potrebno je adekvatno modelirati sve njegove elemente: dionice i čvorišta s pripadajućim geometrijskim karakteristikama, način kontrole prometa, vrste i mogućnosti vozila, osobine vozača i interakciju ovih elemenata koja rezultira određenom prometnom situacijom.

Ovisno o razini na kojoj se opisuje promatrani prometni tok, simulacije se dijele na *mikroskopske*, *makroskopske* i *mezoskopske* modele [2].

Mikroskopski modeli opisuju stanje sustava na temelju karakteristika i ponašanja svakoga individualnog vozila. Kod ovih se modela za modeliranje toka rabe relacije iz teorije slijeđenja vodećeg vozila i relacije iz teorije prihvaćanja vremenskih praznina kojima se definira ponašanje svakog vozila u određenoj prometnoj situaciji (moguće ubrzanje, usporavanje, promjenu traka, pretjecanje, skretanje, zaustavljanje itd.).

Makroskopski modeli prometni tok promatraju kao kontinuum i shodno tome koriste se agregiranim parametrima kao što su protok te prosječna brzina i gustoća toka. Kod ovih se modela često rabe jednadžbe analogne onima koje se primjenjuju pri opisima ponašanja toka fluida i fenomena udara valova. Individualni manevri kre-

tanja, kao što je na primjer promjena prometnog traka, obično nisu eksplicitno modelirani.


Određeni broj simulacija pripada kategoriji *mezoskopskih* modela koji pripadaju negdje između prethodno navedenih modela jer se pri proračunu stanja sustava koriste mikropristupom i makropristup. Kod ovih modela uglavnom se entiteti opisuju individualnim karakteristikama dakle mikropristupom, dok se njihovo kretanje i međudjelovanje modelira na agregiranim podacima.

Ovisno o svojstvima primijenjenih varijabli za definiranje pojedinih procesa i elemenata, simulacijski modeli mogu biti:

- *deterministički*
- *stohastički*

Deterministički modeli nemaju slučajnih varijabli, sve interakcije entiteta definirane su točno utvrđenim (determiniranim) matematičkim, statističkim ili logičkim relacijama gdje isti ulazni podaci daju uvijek isti izlazni rezultat.

Za razliku od njih, *stohastički* modeli sadrže procese koji uključuju komponentu slučajnosti odnosno ovi modeli koriste se jednom ili s više slučajnih varijabli za proračun stanja sustava. Postupci u stohastičkim modelima temelje se na metodi Monte Carlo koja podrazumijeva bilo koju tehniku statističkog uzorkovanja primijenjenu za aproksimiranje rješenja. Ovom se metodom generirani slučajni brojevi s uniformnom razdiobom na intervalu (0,1) rabe za dobivanje vrijednosti neke druge razdiobe s poznatom funkcijom raspodjele vjerojatnosti. Primjena metode Monte Carlo prikazana je na slici 1.



Slika 1 Primjena metode Monte Carlo

Uporaba uvijek drukčijeg niza slučajnih brojeva u pojedinoj simulaciji za posljedicu ima varijabilnost izlaznih rezultata što znači da za što točnije rješenje treba izvršiti veći broj simulacija i analizirati dobivene rezultate primjenom klasičnih statističkih metoda.

Način modeliranja pojedinih komponenata prometnog sustava i njihova međudjelovanja način proračuna te razina prikaza izlaznih rezultata, doveli su do razvoja raz-

ličitih simulacijskih modela koji danas postoje na tržištu, među kojima su najpoznatiji

- ♦ AIMSUN (razvijen u Španjolskoj)
- ♦ CORSIM (SAD)
- ♦ INTEGRATION (Kanada)
- ♦ PARAMICS (Velika Britanija)
- ♦ SIMTRAFFIC (SAD)
- ♦ VISSIM (Njemačka)
- ♦ WATSIM (SAD)

Razlike u mogućnostima ovih 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 razine i dr.).

3 CORSIM

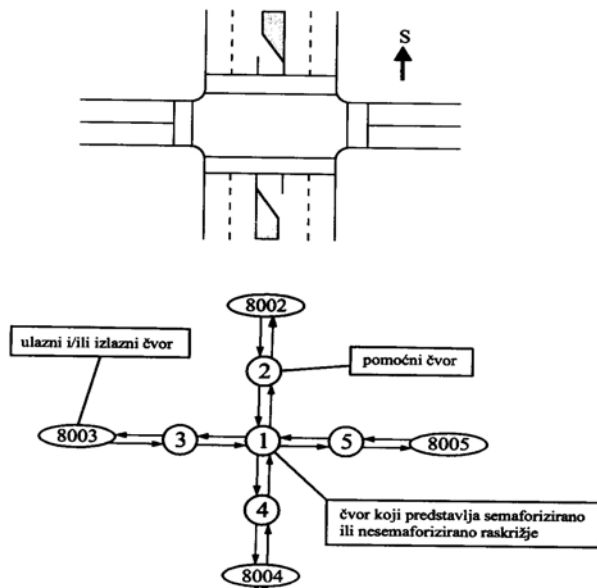
CORSIM (CORridor SIMulation) je mikrosimulacijska komponenta TSIS (Traffic Software Integrated System) integriranog sustava modela za simulaciju odvijanja prometnih tokova na mreži izvangradskih cesta i gradskih ulica [3].

TSIS predstavlja sučelje razvijeno kao podrška CORSIM-u, koje omogućuje jednostavan unos ulaznih podataka grafičkim editorom TRAFED, zatim simulaciju uporabom modela CORSIM te animaciju i vizualizaciju odvijanja prometnih tokova na mreži s pomoću output procesora TRAFVU.


CORSIM sadrži dva podmodela: NETSIM (*NETwork SIMulation*) za modeliranje prometnih tokova na gradskim ulicama i FRESIM (*FREeway SIMulation*) za simulaciju prometa na izvangradskim cestama i autocestama. Ovi se podmodeli mogu rabiti i kao integrirani paket.

CORSIM je mikroskopski model što omogućava praćenje kretanja pojedinog vozila i njegove interakcije s ostalim vozilima i okolinom. Za modeliranje karakteristika vozila i vozača te procesa donošenja odluka koristi se slučajnim varijablama, što ga svrstava u kategoriju stohastičkih modela. Promjene u sustavu (brzina vozila, ubrzanje, stanje svjetlosnog signala itd.) temelje se na diskretizaciji vremena i proračunavaju se za vremenski korak od 1 sekunde.

Prometna mreža definira se s pomoću veza (linkova) koji predstavljaju pojedine dionice i čvorova kojima se definiraju raskrižja i/ili točke na mreži gdje postoje promjene određenih atributa (geometrije, toka i sl.). Na slici 2. prikazano je jedno raskrižje konvertirano u dijagram čvorova i veza, dok je na slici 3. primjer oblikovanja mreže ulica.



Slika 2. Shematski prikaz raskrižja konvertiranog u dijagram čvorova i veza



Slika 3. Primjer prometne mreže konvertirane u dijagram čvorova i veza

Generacija vozila

Na početku simulacije promatrani je sustav "prazan", tj. nema vozila. Vozila se generiraju na ulaznim čvorovima na rubu analizirane prometne mreže, tako da je njihov broj definiran prema utvrđenom protoku, a vremena slijeda, to jest vremena između pojave vozila na mreži ravnaju se prema određenoj razdiobi. U CORSIM-u se razdioba vremena slijeda može birati između uniformne, normalne ili Erlangove razdiobe s parametrom slučajnosti od 1,0 do 4,0. Erlangova je razdioba s koeficijentom slučajnosti 1,0 negativna eksponencijalna razdioba. Ova razdioba vremena slijeda odgovara slučajnim dolascima vozila na mrežu koji se tada ravnaju prema Poissonovoj razdiobi.

Koristeći se kumulativnim izrazom za negativnu eksponencijalnu razdiobu $P(h > h_{min}) = e^{-qh}$ i metodu Monte Carlo, vrijeme h između dolazaka vozila proračunava se prema izrazu:

$$h_i = \frac{1}{q} [-\ln(1 - SB_i)] \tag{1}$$

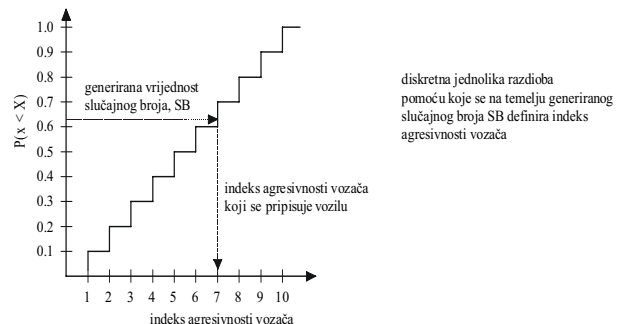
gdje je q definirani protok, SB_i slučajni broj s jednolikom razdiobom na intervalu (0,1), izraz $(1-SB_i)$ vjerojatnost $P(h > h_{min})$, dok je h_{min} minimalno mogući interval između vozila uvjetovan duljinom vozila [2]. Na ovaj način svakom generiranom slučajnom broju SB_i pridruženo je određeno vrijeme slijeda h_i , na temelju kojeg se na ulaznim točkama mreže generiraju vozila.

Generacija atributa vozila i vozača

Vozilo i vozača kao sastavne elemente svakoga prometnog sustava potrebno je definirati vlastitim atributima. Zbog različitih tipova i tehničkih mogućnosti vozila i različitih karakteristika pojedinih vozača, postoji mnogo kombinacija vozilo-vozač koje se mogu pojaviti u prometnom toku.

Relevantni atributi koji definiraju pojedino vozilo su vrsta (osobno, teretno, autobus,...) te pripadajuća fizička i operativna svojstva (duljina, okupiranost, maks. usporava i ubrzanost, itd.). Za opisivanje vozača definira se njegova agresivnost koja uvjetuje veličinu prihvatljive vremenske praznine, željenu brzinu slobodnog toka, način reakcije na neki podražaj i dr. Svaki od ovih atributa koji se primjenjuje u modelu kalibriran je na temelju određenih terenskih podataka u fazi razvoja modela i predstavljen je ili skalarnom veličinom, ili teoretskom probabilističkom razdiobom, ili određenom funkcionalnom ovisnosti između pojedinih atributa.

Na slici 4. prikazano je kako se generirani slučajni brojevi s uniformnom razdiobom na intervalu (0,1) rabe za definiranje agresivnosti vozača kao slučajnog događaja [2]. U CORSIM-u su vozači s obzirom na agresivnost podijeljeni na deset tipova, označenih indeksom od 1 do 10, gdje tip 1 predstavlja najmanje agresivnog vozača, a 10 najagresivnijeg. Svaki od ovih tipova vozača ima istu vjerojatnost pojavljivanja na mreži.



Slika 4. Način generiranja pojedinih atributa u simulacijskom modelu

U tablici 1. prikazana je zavisnost indeksa agresivnosti vozača i željene brzine slobodnog toka za pojedini tip vozača. Iz ovog je primjera vidljiv jedan od načina kako

se s pomoću jednog atributa vozača (u ovom slučaju agresivnosti) generira sljedeći atribut.

Tablica 1. Primjer generiranja željene brzine slobodnog toka ovisno o tipu vozača

Indeks agresivnosti vozača	Postotak kojim se množi vrijednost brzine slobodnog toka za promatranu dionicu
1	75
2	81
3	91
4	94
5	97
6	100
7	107
8	111
9	117
10	127

Budući da jezgru svake simulacije prometnih tokova sačinjavaju model slijeda vozila i model promjene prometnog traka, ovdje se kratko osvrćemo na princip modeliranja, dok se način proračuna i odgovarajuće relacije kojima se definira položaj vozila na mreži mogu naći u literaturi [3], [4] i [5] navedenoj na kraju ovog članka.

3.1 Modeliranje kretanja vozila

Osnovni princip na kojem se temelji logika slijeda vozila u CORSIM-u jest pomicanje vozila tako da se izbjegne kolizija, tj. nalijetanje na vozilo koje se nalazi ispred promatranog. Vremenski interval, tj. vremenski korak koji se rabi u CORSIM-u i za koji se proračunava stanje sustava je 1 sekunda. Za svaki vremenski korak prvo se izvrši pomicanje vodećeg vozila na nov položaj u mreži, a nakon toga se pomiče vozilo koje slijedi i to na takav položaj koji mu omogućava sigurno zaustavljanje bez sudara i u slučaju naglog kočenja vodećeg vozila. Da bi se izbjegla kolizija ovih vozila, potrebno je zadovoljiti sljedeću nejednadžbu [6]:

$$X_n^S - X_{n+1}^S \geq L \quad (2)$$

gdje je:

X_n^S - položaj zaustavljenoga vodećeg vozila

X_{n+1}^S - položaj zaustavljenog vozila koje ga slijedi

L - duljina vodećeg vozila

Uzimajući u obzir položaje vozila na početku vremenskog koraka, prijedni put za vrijeme reakcije vozača i duljinu zaustavljanja promatranih vozila te uvrštavajući ih u gornju nejednadžbu (2), definira se moguće ubrzanje vozila koje slijedi vozilo ispred sebe, a zatim se na temelju osnovnih jednadžbi ubranog gibanja određuje njegov položaj i brzina na kraju svakoga vremenskog koraka.

3.2 Model promjene prometnog traka

Model promjene prometnog traka utvrđuje motiviranost vozača za promjenom traka, a zatim i postojanje mogućnosti da se ova prometna radnja i izvrši. U CORSIM-u, a i u većini drugih simulacijskih modela, postoje dvije vrste promjena prometnog traka: *nužna* (mandatory) i *svojevoljna* (discretionary).

Nužnu promjenu traka obavlja vozilo koje želi izvršiti manevar skretanja na nekom od nadolazećih raskrižja, a ne nalazi se u prometnom traku predviđenom za taj manevar kretanja te je nužno da se pravodobno prestroji. Za razliku od nužne, svojevoljna promjena traka događa se u sljedećim slučajevima:

- kada vozač želi zaobići sporo vozilo i povećati svoju brzinu vožnje
- kad se želi priključiti kraćem repu vozila na privozu raskrižja
- kad želi zaobići zaustavljeno vozilo javnoga gradskog prijevoza.

Sve navedeno samo je želja vozača za kvalitetnijim uvjetima vožnje, a ne nužnost.


Model funkcionira tako da se za svako vozilo i u svakome vremenskom koraku definira motiviranost vozača za promjenom traka. Kod nužne promjene traka motiv vozača je odgovarajući prometni trak za skretanje, dok se pri svojevoljnoj promjeni traka motiviranost vozača kvantificira na temelju tzv. *neprihvatljive brzine* vožnje. Veličina neprihvatljive brzine ovisi o agresivnosti vozača i brzini slobodnog toka za promatranu dionicu.

U slučaju postojanja motiva za promjenom traka model dalje ispituje koji su kandidirajući prometni trakovi i postoji li mogućnost za promjenu traka koja se utvrđuje usporedbom postojećih i prihvatljivih vremenskih praznina u susjednim trakovima. U slučaju nemotiviranosti vozača za promjenom traka vozilo se pomiče duž aktualnog traka na temelju relacija iz modela slijeda vozila.

3.3 Mjere učinkovitosti kao izlazni podaci

Kako je već navedeno, pojam razine uslužnosti u analizi odvijanja prometnih tokova uveden je kao kvalitativna mjera koja opisuje uvjete odvijanja toka, a kod semaforiziranih raskrižja utvrđuje se na temelju prosječnog zakašnjenja po vozilu. Zbog mogućnosti da prate kretanje svakoga individualnog vozila, mikroskopski simulacijski modeli, pa tako i CORSIM, mogu utvrditi zakašnjenje vozila uspoređujući vrijeme putovanja ostvareno tijekom simulacije i idealno vrijeme putovanja koje bi vozilo ostvarilo krećući se brzinom slobodnog toka bez povremenih prekida toka. Stoga kod ovih modela nisu potrebne nikakve specifične formule za proračun zakaš-

njenja kao kod analitičkih modela, već se zakašnjenje izravno "mjeri" iz simulacije za sve uvjete odvijanja toka. Prikaz komponenata zakašnjenja definiranog kao *control delay* dan je na slici 5.




Slika 5. Prikaz komponenata zakašnjenja

Sa slike je vidljivo da se i u CORSIM-u zakašnjenje uzrokovano radom semaforškog uređaja (tzv. *control delay*) definira kao suma zakašnjenja usporenja d_s , zakašnjenja stajanja d_s i zakašnjenja ubrzanja d_a , isto kao i kod analitičkog modela HCM 2000 [1]. Utvrđivanjem vremena i pozicije kada vozilo počinje usporavati zbog blizine semaforiziranog raskrižja (t_1 i x_1) te trenutka i položaja (t_3 i x_3) kada ponovno dostiže svoju operativnu brzinu vožnje, veličina zakašnjenja za svako vozilo može se proračunati ovim izrazom:

$$d = (t_3 - t_1) - \frac{x_3 - x_1}{v} \quad (3)$$

gdje je v operativna brzina vožnje prije usporavanja. U uvjetima manjeg prometnog toka ova operativna brzina odgovara definiranoj brzini slobodnog toka za promatranu dionicu, dok je kod većeg prometnog opterećenja ona znatno manja od brzine slobodnog toka zbog interakcije s ostalim vozilima. Drugim riječima, vozilo ostvaruje zakašnjenje ne samo zbog utjecaja svjetlosne signalizacije, već i zbog većeg prometnog toka.

Nakon provedene simulacije osim podataka o zakašnjenju, CORSIM daje i niz drugih prometnih pokazatelja kao što su: prosječna i maksimalna duljina repa, prosječna brzina vožnje, postotak zaustavljenih vozila, broj zasićenih faza, emisija plinova, potrošnja goriva itd. Vrijeme trajanja simulacije definira korisnik. Budući da je CORSIM stohastički model koji upotrebljava slučajne varijable, za svaki će simulirani prometni tok, generiran na temelju slučajnih brojeva, dati drukčije rezultate. Zbog ove varijabilnosti rezultata potrebno je izvršiti veći broj simulacija i kao mjerodavni podatak koristiti se dobivenom srednjom vrijednosti. Na slici 6. je primjer grafičkog prikaza simulacije prometnog toka jednog dijela ulične mreže.




Slika 6. Grafički prikaz simulacije

4 Analiza osjetljivosti pojedinih ulaznih parametara

CORSIM se kao stohastički simulacijski model temelji na slučajnim uzorcima kombinacija vozilo-vozač, što za posljedicu ima varijabilnost izlaznih rezultata. Svrha analize osjetljivosti jest da se utvrdi koliko promjena vrijednosti pojedinog parametra utječe na mjere učinkovitosti, u ovome slučaju prosječno zakašnjenje po vozilu. Ovom analizom može se odrediti koji parametri znatno utječu na izlaznu vrijednost pa ih je potrebno kalibrirati s obzirom na lokalne uvjete odvijanja prometnog toka.

4.1 Utjecaj trajanja simulacije i stupnja zasićenosti na varijabilnost procjene zakašnjenja


Da bi se ispitao utjecaj trajanja simulacije na varijabilnost procjene zakašnjenja, kao test-model poslužilo je jedno četverokrako raskrižje. Provedeno je deset simulacija s različitim početnim slučajnim brojevima te je definirano razdoblje simulacije od 9000 sekunda s proračunom kumulativnih statističkih podataka svakih 300 sekunda.



Slika 7. Prikaz utjecaja trajanja perioda simulacije na varijabilnost rezultata

Na slici 7. prikazani su dobiveni rezultati zakašnjenja za svako od deset ponavljanja te dijagram srednjih vrijednosti u ovisnosti o trajanju simulacije. Ovdje se vidi da se povećanjem vremena simulacije smanjuje varijabilnost rezultata uzrokovana stohastičkom prirodom modela te postupno dolazi do stabilizacije vrijednosti. Kao

relativna mjera disperzije rezultata, na slici 8. prikazan je koeficijent varijacije za izvršenih deset simulacija. Koeficijent varijacije definiran je kao odnos standardne devijacije i srednje vrijednosti. Može se uočiti da za trajanje simulacije od 3600 sekunda i više, koeficijent varijacije ima vrijednost do 0,1, odnosno standardno odstupanje je manje od 10% u odnosu na srednju vrijednost.



Slika 8. Koeficijent varijacije za različito vrijeme trajanja simulacije

Veća varijabilnost rezultata pri manjem vremenskom trajanju simulacije očituje se i pri proračunu potrebnog broja ponavljanja za definiranu veličinu pogreške u odnosu na srednju vrijednost. Broj potrebnih ponavljanja za 95 %-tni interval povjerenja jest

$$n = \left(\frac{1,96 \sigma}{E} \right)^2 \quad (4)$$

gdje je:

n - potreban broj ponavljanja

1,96 - Z-vrijednost standardne normalne krivulje za interval povjerenja od 95%

σ - standardna devijacija dobivena na temelju provedenih simulacija


E - prihvatljiva pogreška u odnosu na srednju vrijednost procijenjene veličine

Tablica 2. Utjecaj trajanja simulacije na potreban broj ponavljanja


Trajanje simulacije	Sred. vrijednost	Std. Dev.	COV	n
300	22,39	3,71	0,17	11
900	25,29	4,62	0,18	13
1800	27,02	5,70	0,21	17
2700	26,30	3,90	0,15	8
3600	26,22	2,67	0,10	4
4500	26,15	1,80	0,07	2
5400	26,47	1,84	0,07	2
6300	26,75	2,50	0,09	3
7200	27,22	2,84	0,10	4
8100	27,11	2,83	0,10	4
9000	27,23	2,60	0,10	4

Prema izrazu (4) proveden je proračun potrebnih simulacija za promatrani primjer i različito trajanje simulacije te pogrešku od 10 % srednje vrijednosti ($E = 0,1 \times$ srednja vrijednost). Dobivene vrijednosti prikazane su u tablici 2. čime je potvrđena prethodno navedena činjenica da je kod kraćih simulacija potreban veći broj ponavljanja.

Međutim, broj potrebnih ponavljanja za određenu toleranciju pogreške koji je uzrokovan disperzijom izlaznih podataka nije samo posljedica trajanja simulacije, već znatan utjecaj na disperziju rezultata ima i stupanj zasićenosti promatranog privoza. Kako je već navedeno, stupanj zasićenosti jest odnos prometne potražnje i propusne moći promatranog privoza. Postupno povećavajući prometno opterećenje, simulirani su različiti uvjeti saturiranosti privoza te je na temelju 10 simulacija za svaki pretpostavljeni stupanj zasićenosti (upotrijebljene su vrijednosti od 0,1 do 1,4) dobivena srednja vrijednost prosječnog zakašnjenja. Pretpostavljena je duljina ciklusa od 60 sekunda s efektivnim zelenim vremenom u trajanju od 23 sekunde. Također je pretpostavljeno da nema teških teretnih vozila te da je raspodjela prometnog toka sljedeća: 15 % lijevo, 75% ravno i 15 % desno. Na slikama 9. i 10. prikazana je standardna devijacija i koeficijent varijacije procjene zakašnjenja s obzirom na stupanj zasićenosti.



Slika 9. Prikaz odnosa standardne devijacije procjene zakašnjenja i stupnja zasićenosti



Slika 10. Prikaz odnosa koeficijenta varijacije procjene zakašnjenja i stupnja zasićenosti

Kao što se može vidjeti, značajna varijabilnost procjene zakašnjenja izražena koeficijentom varijacije kao relativnom mjerom javlja se u području vrlo malih stupnjeva zasićenosti i u području gdje je stupanj zasićenosti blizu vrijednosti 1,0.

Disperzija procjene zakašnjenja u području malih stupnjeva zasićenosti može se protumačiti većom mogućnošću variranja vremena slijeda između uzastopnih vozila, što utječe na slučajnost dolaska vozila osobito što se tiče trenutka dolaska na crtu "stop" (da li za zelene ili crvene faze). Osim toga, imajući na umu da su vrijednosti prosječnog zakašnjenja u ovome području relativno male, i nevelika odstupanja (standardna devijacija) u omjeru sa srednjom vrijednosti zakašnjenja daju veliki koeficijent varijacije.

Povećanjem prometnog opterećenja smanjuje se prosječno vrijeme slijeda i manja je mogućnost varijacije vremena dolaska i odlaska vozila, pa je i smanjena varijabilnost rezultata za stupanj zasićenosti od 0,4 do 0,8. Za vrijednosti stupnja zasićenosti u području od 0,9 do 1,1 osnovni je uzrok varijabilnosti procjene zakašnjenja u zasićenim ciklusima koji se pojavljuju u takvim odnosima prometne potražnje i propusne moći privoza. Je li se pojavio zasićeni ciklus i koliko puta u toku simulacije znatno utječe na veličinu zakašnjenja što uzrokuje veću disperziju rezultata, a time i veći koeficijent varijacije. U uvjetima gdje je stupanj zasićenosti veći od 1,1 dolazi do ponovnog smanjenja varijabilnosti procjene zakašnjenja jer povećanje prometne potražnje uzrokuje veći broj zasićenih ciklusa sa stalnim stvaranjem repova koji ograničavaju slobodu kretanja vozila i ujednačavaju način odvijanja toka na promatranom privožu.

Za ovaj primjer s primijenjenim različitim stupnjem zasićenosti, izrazom (4) proračunan je potrebn broj simulacija za 95%-tni interval povjerenja i 10% odstupanja od srednje vrijednosti. Dobivene vrijednosti prikazane su u tablici 3. iz koje se vidi da je u području veće varijabilnosti rezultata, a to je za male stupnjeve zasićenosti i u području gdje prometna potražnja odgovara propus-

Tablica 3. Potreban broj simulacija s obzirom na stupanj zasićenosti analiziranog raskrižja

Stupanj zasićenosti	n
0,1	27
0,2	10
0,3	9
0,4	3
0,5	5
0,6	6
0,7	2
0,8	3
0,9	7
1,0	22
1,1	7
1,2	2
1,3	1
1,4	1


noj moći, potreban veći broj simulacija.

4.2 Utjecaj vrijednosti zasićenog vremena slijeda na procjenu zakašnjenja

I ovdje je kao test-model poslužilo isto raskrižje kao u prethodnom poglavlju. Za svako prometno opterećenje koje je sukcesivno povećavano izvršeno je po 10 simulacija. Za sve razine prometnog opterećenja mijenjala se i veličina zasićenog vremena slijeda te su primijenjene vrijednosti 1,8, 2,0

i 2,2 sekunde. Zasićeno je vrijeme slijeda vrijeme između uzastopnih odlazaka vozila sa crte "stop" kada postoji kontinuirana kolona u kretanju kroz raskrižje. Na slici 11. prikazane su dobivene srednje vrijednosti zakašnjenja za izvršenih deset simulacija za svako opterećenje i navedene veličine zasićenog vremena slijeda. S obzirom na to da se promjenom zasićenog vremena slijeda mijenja propusna moć promatrane grupe trakova, utjecaj ovog parametra prikazan je u ovisnosti o prometnom opterećenju te je na temelju dobivenih krivulja utvrđeno područje gdje vrijednost vremena slijeda značajno mijenja procjenu zakašnjenja.

Budući da CORSIM kao izlazni podatak eksplicitno ne daje podatak o propusnoj moći privoza ili pojedine grupe trakova, procjena propusne moći može se dobiti indirektnim načinom tako da se na uzvodnom čvoru od promatranog privoza definira takvo prometno opterećenje koje će za posljednju imati kontinuiranu, zasićenu kolonu vozila na čitavom analiziranom privožu. Broj vozila iz kontinuirane kolone koja prođu raskrižjem u promatranom vremenskom intervalu, a koji postoji kao izlazni podatak, najveći je obujam prometa za to razdoblje iz čega se ekspandiranjem ovog podatka na jedinicu od jednog sata dobiva procjena propusne moći u voz/h. Na ovaj je način procijenjena i propusna moć promatrane grupe trakova za svaki od tri slučaja zasićenog vremena slijeda.



Slika 11. Utjecaj zasićenog vremena slijeda na procjenu zakašnjenja

Na slici 11. naznačene su veličine stupnja zasićenosti (sz) u području gdje se uočava da dolazi do odstupanja između dobivenih krivulja zakašnjenja. Prema naznačenim vrijednostima može se zaključiti da u području gdje je stupanj zasićenosti < 0,9, primijenjena vrijednost zasićenog vremena slijeda nema znatnijeg utjecaja na veličinu procjene zakašnjenja. U uvjetima kada je odnos prometne potražnje i propusne moći > 0,9, a osobito u području gdje je ovaj odnos od 0,95 do 1,05 dolazi do znatnog odstupanja veličine zakašnjenja. Stoga je što točnija vrijednost zasićenog vremena slijeda nužna za dobru procjenu prosječnog zakašnjenja.

Što realnija vrijednost zasićenog vremena slijeda u prethodno navedenim uvjetima odvijanja toka važna je kad


se simulacija rabi za ocjenu funkcioniranja određenog raskrižja u postojećim uvjetima, dok je u slučaju *usporredbe* i *vrednovanja* određenih građevinskih i prometnih rješenja na nekom raskrižju, važno uspostaviti konzistentne uvjete za sva varijantna rješenja te je potrebno da se ovaj parametar drži konstantnim bez obzira koja će se vrijednost primijeniti.

4.3 Utjecaj vrijednosti brzine slobodnog toka i duljine privoza na procjenu zakašnjenja


Pri modeliranju raskrižja ili mreže, osim ostalih ulaznih podataka, potrebno je definirati brzinu slobodnog toka i duljinu privoza. Kod bliskih je raskrižja duljina privoza određena njihovim položajem na mreži dok se kod izoliranih i rubnih raskrižja ovaj parametar može različito definirati. Da bi se utvrdio utjecaj parametra brzine i duljine privoza na procjenu zakašnjenja, modelirano je jedno jednostavno hipotetsko četverokrako raskrižje. Krakovi su definirani kao dvotračni sa po jednim trakom za svaki smjer vožnje. Uzdužni nagib je 0%. Pretpostavljeno je da prometni tok sačinjavaju samo osobna vozila koja se kreću ravno kroz raskrižje te da nema pješakačkih tokova. Duljina ciklusa je 60 sekunda s efektivnim zelenim vremenom u trajanju od 30 s za promatrani privoz.

Da bi se provela parametarska analiza u prvom je slučaju primijenjena duljina privoza od 300 m, dok je u drugom analiziranom slučaju duljina privoza povećana na 900 m. Prometno opterećenje sukcesivno se povećavalo, tako da su simulirani uvjeti zasićenosti sustava u rasponu od 0,1 do 1,3 odnosa prometnog opterećenja (potražnje) i propusne moći. Vrijednost brzine slobodnog toka mijenjala se od 40 do 80 km/h, s povećanjem od 10 km/h za obje duljine privoza i sve uvjete zasićenosti. Za svaku kombinaciju prethodno navedenih parametara i uvjeta toka (2x13x5 kombinacija) izvršeno je po 10 simulacija u trajanju od 15 minuta.

Na slikama 12. i 13. prikazane su dobivene krivulje srednjih vrijednosti zakašnjenja za sve stupnjeve zasićenosti ovisno o primijenjenoj vrijednosti brzine slobodnog toka i duljini privoza.



Slika 12. Prikaz procjene zakašnjenja za duljinu privoza od 300 m



Slika 13. Prikaz procjene zakašnjenja za duljinu privoza od 900 m

Nakon analize dobivenih podataka može se zaključiti da primijenjena vrijednost brzine slobodnog toka ne utječe znatno na veličinu zakašnjenja, osobito kod kraće duljine privoza. U promatranom slučaju s duljim privozom razlika u procjeni zakašnjenja s obzirom na brzinu slobodnog toka javlja su u području gdje se prometno opterećenje približava propusnoj moći i u području većeg stupnja zasićenosti, dok za uvjete gdje je stupanj zasićenosti < 0,9 nema znatnijeg utjecaja.

Kada se uspoređuju dobivene vrijednosti za kraći i duži privoz, s predočenih se dijagrama može uočiti da se najveće razlike u procjeni zakašnjenja pojavljuju u saturiranim uvjetima. Ova se razlika može protumačiti jednostavnom činjenicom da duži privoz fizički može primiti više vozila u uvjetima zasićenog toka čije zakašnjenje ulazi u proračun ukupne vrijednosti, dok kod kraćeg privoza, zagušenog vozilima, ne može doći do generacije novih vozila pa tako njihovo zakašnjenje ne ulazi u proračun. Kao posljedica ovog pojavljuje se podcijenjena vrijednost zakašnjenja za kratke privoze u zasićenim uvjetima. Za dobivanje realnije vrijednosti prosječnog zakašnjenja bilo bi potrebno produžiti vrijeme simulacije dodatnim vremenskim razdobljem u kojem neće biti novog dotoka vozila, a omogućit će vozilima iz prethodnog intervala pristup na mrežu i s vremenom odlazak s raskrižja.

5 Zaključak

Stohastički mikroskopski simulacijski modeli kao što je CORSIM koristan su „alat“ za analizu funkcioniranja prometne mreže ili pojedinih njezinih dijelova, jer osim brojčanih podataka korisniku omogućuju i vizualizaciju odvijanja prometnog toka. Poznato je da je za što točnije rezultate potrebna kalibracija i validacija modela s obzirom na lokalne uvjete odvijanja prometnog toka. U ovom su članku prikazani rezultati analize osjetljivosti nekih od parametara koji se rabe pri analizi funkcioniranja semaforiziranih raskrižja. Na temelju dobivenih rezultata može se zaključiti sljedeće:

- Osnovna je karakteristika stohastičkih modela varijabilnost izlaznih rezultata, pa je utvrđeno da je najveća disperzija procjene zakašnjenja u području gdje je tok jednak propusnoj moći te u području vrlo ma-

lih odnosa prometne potražnje i propusne moći (stupanj zasićenosti $< 0,2$). Za smanjenje varijabilnosti rezultata potrebno je ili produžiti vrijeme trajanja simulacije, ili povećati broj simulacija.

- Analiziranjem utjecaja zasićenog vremena slijeda na zakašnjenje u CORSIM-u utvrđeno je da u području gdje je stupanj zasićenosti $< 0,9$ primijenjena vrijednost ovog parametra nema znatnijeg utjecaja, dok u području gdje je stupanj zasićenosti $> 0,9$ dolazi do znatnih odstupanja, jer različita zasićena vremena slijeda rezultiraju drukčijom procjenom propusne moći, pa je za takve uvjete toka potrebno utvrditi stvarno zasićeno vrijeme slijeda i kalibrirati model
- Ispitivanjem utjecaja primijenjenih vrijednosti duljine privoza i brzine slobodnog toka na procjenu zakašnjenja u CORSIM-u ustanovljeno je da definirana duljina privoza ne utječe znatno na zakašnjenje u nezasićenim uvjetima (stupanj zasićenosti $< 1,0$) dok u zasićenim uvjetima veća duljina privoza daje mnogo veća zakašnjenja jer u definiranom vremenu simulacije fizički može primiti više generiranih vozila čije zakašnjenje ulazi u proračun. Variranjem parametra brzine slobodnog toka uočeno je da primijenjena vrijednost nema utjecaja na zakašnjenje osobito kod kraćeg privoza, dok se u slučaju duljeg privoza odstupanja pojavljuju u uvjetima kad je prometna potražnja jednaka ili veća od propusne moći te je za takve uvjete odvijanja toka potrebno kalibrirati ovaj parametar
- Simulacijski su modeli vrlo upotrebljivi pri usporedbi varijanata građevinskih i/ili prometnih rješenja prije implementacije u prostor, jer se može simulirati isti prometni tok za svako od rješenja bez obzira na primijenjene vrijednosti pojedinih parametara te se usporedbom dobivenih prometnih pokazatelja može izabrati najpovoljnije.

LITERATURA

- [1] Transportation Research Board: *Highway Capacity Manual*, National Research Council, Washington, DC, 2000.
- [2] Transportation Research Board: *Traffic Flow Theory, A State-of-Art-Report*, ITS, Turner Fairbank Highway Research Center, www.tfhrc.gov/its/tft, 1997.
- [3] FHWA Office of Operations Research, Development and Technology, Federal Highway Administration, Turner-Fairbank Highway Research Center: *TSIS-Traffic Software Integrated System, Version 5.1*, ITT Industries, Inc., Systems Division, Colorado Springs, 2003.
- [4] Halati A., Lieu H., and Walker S.: "*CORSIM*" - *Corridor Traffic Simulation Model*, Proceedings ASCE Conference on Traffic Congestion and Safety in the 21st Century, Chicago, 1997., 570-576.
- [5] Breški, D.: *Usporedba analitičkih i simulacijskih modela za analizu funkcioniranja semaforiziranih raskrižja*, magistarski rad, Građevinsko-arhitektonski fakultet Sveučilišta u Splitu, Split, 2004.
- [6] Aycin, M.F., Benekohal, R.F.: Comparison of Car-Following Models for Simulation, Transportation Research Record, No.1678, TRB, National Research Council, Washington, D. C., 1999.