Procjena kritičnog intervala sljeđenja vozila na kružnim raskrsnicama

Vuk Bogdanović^a, Dunja Radović^{b*}

^a Univerzitet u Novom Sadu, Fakultet tehničkih nauka

^b Univerzitet u Istočnom Sarajevu, Saobraćajni fakultet Doboј

PODACI O RADU

DOI: 10.31075/PIS.66.02.02

Stručni rad

Primljen: 20.01.2020

Prihvaćen: 17.05.2020

Koresponding autor:

dunja.radovic@sf.ues.rs.ba

Ključne reči:

Ponašanje vozača

Kružne raskrsnice

Kritični interval sljeđenja

REZIME

Prema modelima koji se uobičajeno koriste u praksi, kapacitet kružnih raskrsnica zavisi od vrijednosti kritičnog intervala sljeđenja. Veličina kritičnog intervala sljeđenja zavisi od mnogobrojnih objektivnih faktora, prije svega od geometrijskih karakteristika raskrsnice. Međutim, dosadašnja istraživanja pokazala su da pored karakteristika raskrsnice, vrijednost kritičnog intervala sljeđenja zavisi i od mnogih drugih faktora, a prije svega od ponašanja vozača. Ponašanje vozača je rezultat djelovanja mnogobrojnih faktora koji zavise od uticaja lokalne sredine, navika, mentaliteta itd. Iz tog razloga, u mnogim modelima se preporučuje utvrđivanje veličine ovog parametra saobraćajnog toka u lokalnim istraživanjima. U okviru ovog rada predstavljeni su rezultati koji se odnose na vrijednost kritičnog intervala sljeđenja utvrđenog na osnovu istraživanja koja su sprovedena u Bosni i Hercegovini. Prezentovana vrijednost kritičnog intervala sljeđenja procijenjenog na osnovu 127 parova prihvaćenih i odbačenih intervala može poslužiti za objektivno utvrđivanje kapaciteta kružnih raskrsnica u našem regionu.

1. Uvod

Vozači na sporednim prilazima kružne raskrsnice, prije ulaska u zonu kruženja, procjenjuju vremenske praznine, odnosno intervale sljeđenja koji se javljaju u konfliktnom toku. Kada procijene da je vremenska praznina dovoljno velika i bezbjedna, donose odluku o ulasku u zonu kruženja. Minimalna vrijednost ovog vremenskog intervala, koji vozači prihvataju i koriste za realizaciju sporednog manevra, naziva se kritični interval sljeđenja.

Pored objektivnih faktora, vrijednost kritičnog intervala sljeđenja u velikoj mjeri zavisi od ponašanja vozača. Iako su radnje koje vozači vrše prilikom realizacije sporednog manevra gotovo identične, prihvatanje vremenskih intervala sljeđenja za realizaciju zavisi od odluke vozača. Iz tog razloga, veličina kritičnog intervala sljeđenja nije u svim sredinama i svim zemljama identična.

S obzirom na to da na ponašanje vozača, osim individualnih karakteristika i sposobnosti vozača, u velikoj mjeri utiče sredina, preporučuje se da se prilikom utvrđivanja veličine kritičnog intervala sljeđenja uzmu u obzir i lokalna mjerenja.

Motiv za istraživanje i analizu sprovedenu u ovom radu je veoma skroman broj radova u kojima su istraženi i proračunati parametri saobraćajnog toka u našem regionu. Ovakva istraživanja su potrebna kako bi se primjenom matematičkih modela utvrdila njihova objektivna vrijednost, radi primjene u postupcima za proračun kapaciteta i utvrđivanje nivoa usluge. Primjenom vrijednosti ovih parametara utvrđenih u drugačijim uslovima odvijanja saobraćaja može dovesti do izvođenja pogrešnih zaključaka i odluka u planovima i projektima.

2. Uticaj veličine kritičnog intervala sljeđenja na kapacitet kružne raskrsnice

Proračun kapaciteta kružnih nesignalisanih raskrsnica zasnovan je na teoriji vjerovatnoće, odnosno pretpostavci da će se u prioritetnom toku stvoriti dovoljno intervala u kojima će se izvršiti sporedni manevri. Postupak koji je pokazao najbolje rezultate u praksi sa najvećom tačnošću je onaj koji je dat u novijim verzijama HCM-a (HCM, 2010; HCM 2016).

Ovaj postupak je zasnovan na Harders-ovom modelu (Harders, 1968) prihvatljivih intervala sljeđenja, u kome prema definiciji figuriraju intervali sljeđenja koje će vozači prihvatiti za izvođenje sporednog manevra, čija se vrijednost nalazi između maksimalnih i minimalnih vrijednosti koje se realizuju u realnom saobraćajnom toku. Prema ovom modelu, kapacitet sporednih manevara na kružnoj raskrsnici računa se prema sljedećoj relaciji:

$$C_p = V_{c,x} \cdot \frac{e^{-V_{c,x} \cdot t_{c,x}/3600}}{1 - e^{-V_{c,x} \cdot t_{f,x}/3600}} \quad (1)$$

gdje su:

C_{px} – kapacitet sporednog prilaza "x" [voz/h];
 $V_{c,x}$ – konfliktni tok za sporedni prilaz "x" [voz/h];
 $t_{c,x}$ – kritični interval sljeđenja na prilazu "x" [s];
 $t_{f,x}$ – interval sljeđenja na sporednom prilazu "x" [s].

Prema (HCM, 2016) kapacitet na ulaznoj saobraćajnoj traci jednodirne kružne raskrsnice, za preporučene vrijednosti parametara kritičnog intervala sljeđenja od 4,98 [s] i vremena sljeđenja od 2,61 [s], računa se prema sljedećoj relaciji:

$$c_{e,pce} = 1380e^{(-1,02 \times 10^{-3})v_{c,pce}} \quad (2)$$

Slika 1. Prikaz jednodirne kružne raskrsnice, po jedna traka na ulazu i u kružnom toku *Izvor: HCM 6, Exhibit 22-2

Sličan postupak prema HCM-u predviđen je i za višetračne kružne raskrsnice. Kao što se na osnovu prezentovane metodologije može vidjeti, veličina kritičnog intervala sljeđenja, pored veličine konfliktnog toka i intervala sljeđenja na sporednom prilazu, presudno utiče na veličinu kapaciteta prilaza kružnih raskrsnica.

3. Pregled literature

Prema Gartner i dr., (2002) na svim tipovima nesignalisanih raskrsnica, u koje spadaju i kružne raskrsnice, vozači nisu kontrolisani, odnosno oni sami moraju donijeti odluku kada je bezbjedno da započnu sporedni manevr i uđu u središte raskrsnice. Vozač koji pokušava da stupi u raskrsnicu sa sporednog prilaza mora poštovati prioritet, odnosno ustupiti prvenstvo prolaza vozačima u prioritetnom toku.

Ovaj proces je poznat kao proces prihvatanja intervala. Intervali se odnose na saobraćajne interakcije između vozila na sporednom toku koja pokušavaju da stupe u glavni tok i vozila u glavnom toku – zoni kruženja. Može se zaključiti da su intervali direktno povezani sa uslovima u saobraćajnom toku i da su iz tog razloga svrsishodni za analize i proračune koji se odnose na raskrsnice. Raff, (1950) je definisao interval sljeđenja vozila kao interval koji protekne između prolaska dva uzastopna vozila preko posmatranog presjeka. Prema Kuzović i Bogdanović, (2010) interval sljeđenja vozila, kao jedan od osnovnih parametara saobraćajnog toka, predstavlja vrijeme između prolaska čela dva uzastopna vozila, u jednom smjeru za jednosmjerne saobraćajnice, odnosno u oba smjera za dvosmjerne saobraćajnice, kroz zamišljeni presjek posmatranog odsjeka puta. Kritični vremenski interval sljeđenja definiše se kao minimalno potrebna veličina intervala sljeđenja u glavnom toku koja omogućava jednom vozilu iz sporednog toka prolazak kroz središte raskrsnice. Kritični interval sljeđenja se najčešće obilježava sa t_c , ali se u literaturi može naći i oznaka t_g . Prema Brilon i dr., (1999) kritični interval sljeđenja podrazumijeva minimalni interval sljeđenja između vozila u glavnom toku koji je vozač iz sporednog toka spreman prihvatiti kako bi stupio u zonu kruženja. Prema Tian i dr., (1999) kritični interval sljeđenja je jedan od glavnih parametara za modele zasnovane na prihvatanju vremenskih intervala između vozila.

Prema Macioszek, (2017) kritični interval sljeđenja nije konstantna veličina i ima različite vrijednosti za pojedinačne vozače, ali i različite vrijednosti za iste vozače u pojedinim trenucima ili različitim saobraćajnim situacijama. Vrijednosti intervala sljeđenja zavise od karakteristika vozača, vozila, uslova kretanja i geometrijskih karakteristika raskrsnice. Zbog varijabilnosti ovih parametara može se zaključiti da je proces prihvatanja intervala sljeđenja stohastičke, odnosno slučajne prirode. Stoga, ovi parametri se mogu smatrati slučajnim promjenljivim.

Ako vozilo iz sporednog toka uđe u raskrsnicu prije nego što vozilo iz glavnog toka stigne do potencijalne konfliktne tačke, onda je u pitanju prihvaćen interval, a ako vozilo iz sporednog toka čeka dok vozilo iz glavnog toka prođe prije nego što uđe u raskrsnicu onda je u pitanju odbijen interval pristizanja (Raff, 1950). Interval pristizanja je ustvari prvi interval sa kojim se suočava vozač sa sporednog toka.

Akcent istraživanja (Krishna, 2015) bio je na utvrđivanju vrijednosti parametra koji određuje ponašanje vozača, odnosno kritičnom intervalu sljeđenja. Istraživanje je sprovedeno na kružnim raskrsnicama koje se nalaze u različitim oblastima Indije. Kritični interval sljeđenja je procjenjivan primjenom tri metode i to: metoda koju je razvio Raff, Ning Wu i metoda maksimalne vjerodostojnosti. U radu je dokazano da je metoda koju je razvio Ning Wu (Equilibrium of probabilities) najprikladnija za uslove saobraćaja u Indiji.

Vrijednosti dobijene za kritični interval sljeđenja variraju od 0,9 do 2,35 [s]. Ove vrijednosti ukazuju na veoma agresivan stil vožnje vozača u Indiji. Sem toga, rezultati su pokazali da se ponašanje vozača mijenja u zavisnosti od sastava saobraćajnog toka, odnosno zabilježeno je da su intervali sljeđenja bili veći kada je i broj teretnih vozila bio veći. Dakle, na kritični interval sljeđenja utiče broj i kategorija vozila koja stupaju u kružni tok.

U radu (Xu i Tian, 2008) su prikazani rezultati koji se odnose na proračun kritičnog intervala sljeđenja na sedam jednotračnih i tri višetračne kružne raskrsnice u Kaliforniji. Rezultati su pokazali da vrijednosti kritičnog intervala sljeđenja odgovaraju vrijednostima preporučenim u (NCHRP 3-65), što znači da statistička analiza nije pokazala značajnu razliku u vrijednostima ovog intervala između Kalifornije i drugih država SAD-a. Vrijednost kritičnog intervala sljeđenja na jednotračnim kružnim raskrsnicama varira između 4,5 i 5,3 [s], sa srednjom vrednošću od 4,9 [s]. Na višetračnim kružnim raskrsnicama kritični interval sljeđenja varira između 4,4 i 5,1 [s], prosječno 4,8 [s] za lijevu traku, i 4,0 i 4,8 [s], prosječno 4,4 [s] za desnu traku. Xu i Tian, (2008) su utvrdili da su broj vozila u kružnom dijelu raskrsnice i brzina glavni faktori koji utiču na kritični interval sljeđenja. Oni su ustanovili da sa povećanjem broja vozila u glavnom toku i/ili brzine kritični interval sljeđenja ima tendenciju da se smanjuje.

Gazzari i dr., (2012) su u svom radu istraživali da li su preporučene vrijednosti kritičnog intervala sljeđenja u (HCM, 2010) pogodne i za Italiju. Istraživanje je sprovedeno na sedam kružnih raskrsnica u sjevernoj Toskani. U cilju što bolje provjere eksperimentalno dobijenih vrijednosti primijenjene su tri različite metode za procjenu kritičnog intervala sljeđenja. Prva primijenjena metoda je veoma popularna metoda maksimalne vjerodostojnosti. Druga je statistička metoda zasnovana na medijani posmatranog uzorka. Treća metoda je grafička, poznata kao Raff-ova metoda. Sve tri metode zahtijevaju podatke o prihvaćenim i maksimalnim odbačenim intervalima za svakog vozača.

Rezultati su pokazali da je vrijednost kritičnog intervala sljeđenja značajno manja u odnosu na one vrijednosti dobijene u nekim međunarodnim studijama. Detaljnije, metodom maksimalne vjerodostojnosti je dobijena vrijednost kritičnog intervala sljeđenja za jednotračne kružne raskrsnice u iznosu od 3,86 [s], a za višetračne za lijevu traku 3,90 [s] i za desnu traku 3,69 [s]. Druga metoda koja se zasniva na medijani je jednostavnija i brža od metode maksimalne vjerodostojnosti, a rezultati dobijeni primjenom ove dvije metode su prilično slični. Primjenom Raff-ove metode dobijeni su malo drugačiji rezultati, tj. za jednotračne kružne raskrsnice kritični interval sljeđenja iznosi 3,50 [s], a za višetračne za lijevu traku 3,55 [s] i za desnu traku 3,38 [s].

U radu (Barry, 2012) prikazani su rezultati mjerenja sa 13 prilaza na šest jednotračnih kružnih raskrsnica u Džordžiji u trajanju od oko dva sata tokom vršnog perioda, a podaci sa tri kružne raskrsnice čine osnovu ovog rada. Kada su vozila koja napuštaju kružni tok, odnosno vozila na izlazu iz kružne raskrsnice isključena iz proračuna, ponderisana vrijednost kritičnog intervala sljeđenja je iznosila 4,17 [s]. Kada su vozila na izlazu iz kružne raskrsnice uključena u analizu, ponderisana vrijednost kritičnog intervala sljeđenja je iznosila 3,34 [s]. I u drugim istraživanjima je zabilježeno da kritični interval sljeđenja opada kada se vozila na izlazu iz kružne raskrsnice razmatraju u proračunu (Zheng i dr., 2011). Na ovaj način u radu (Barry, 2012) je utvrđeno da vozila na izlazu iz kružne raskrsnice u većini slučajeva imaju uticaj na performanse kružnih raskrsnica. Sa njihovim uključivanjem u analizu povećava se kapacitet koji je predviđen kalibrisanim modelom za proračun, odnosno modeli koji u proračun uključuju vozila na izlazu imaju kao posljedicu veći kapacitet u odnosu na modele koje ne uključuju u proračun ova vozila.

Analizom i proračunom u radu (Wei i Grenard, 2012) je pokazano da je vrijednost kritičnog intervala sljeđenja utvrđena na tri jednotračne kružne raskrsnice i prilagođena lokalnim uslovima u gradu Karmel u Indijani značajno manja od one preporučene u HCM-u 2010 i da iznosi 3,47 [s].

Troutbeck, (2014) je uporedio efikasnost metode maksimalne vjerodostojnosti (Maximum likelihood method) koju je on razvio i metode koju je razvio Ning Wu (Probability equilibrium method) za procjenu kritičnog intervala sljeđenja primjenom simulacije na 100 vozača, ponovljene 100 puta za svaku saobraćajnu sliku. Metodom maksimalne vjerodostojnosti su dobijene postojane i nepristrasne vrijednosti kritičnog intervala sljeđenja, dok je kod rezultata dobijenih drugom metodom zabilježena značajna pristrasnost koja zavisi od protoka vozila u prioritetnom toku. Obje metode su bile prihvatljivo postojane, iako je metoda maksimalne vjerodostojnosti bila bolja. U ovom radu je dat osvrt i na kritike na račun metode maksimalne vjerodostojnosti, ali je Troutbeck, (2014) dokazao da su one potpuno neosnovane. Autor tvrdi da i u situaciji da su vozači bili nedosljedni (tj. da su prihvatili interval manji od prethodno odbijenog), opet bi metoda maksimalne vjerodostojnosti bila najbolji izbor. Jedna od kritika je bila da pretpostavka prema kojoj kritični interval sljeđenja prati log-normalnu raspodjelu utiče na efikasnost metode. Međutim, u ovom radu je pokazano da ovo ne utiče bitno na efikasnost metode. Uporednom analizom dokazano je da se metodom maksimalne vjerodostojnosti mogu dobiti svrsishodne vrijednosti kritičnih intervala sljeđenja čak i na osnovu uzorka od 25 do 30 intervala prihvaćenih od strane vozača.

4. Metodologija istraživanja

Istraživanje je izvršeno na tri četvorokrake kružne raskrsnice sa po jednom saobraćajnom trakom na ulivu/izlivu i jednom saobraćajnom trakom u zoni kruženja u gradu Bijeljina, Republika Srpska, Bosna i Hercegovina. Istraživanje na ovom, elementarnom tipu kružne raskrsnice je vršeno da bi se u što većoj mjeri eliminisali uticaji geometrije prilaza na veličinu parametara saobraćajnog toka. U okviru istraživanja primijenjen je takozvani fotografski metod koji podrazumijeva analizu video snimaka realnog saobraćajnog toka. Ovim metodom isključena je mogućnost uticaja istraživanja na ponašanje vozača.

Predmet istraživanja su bile sljedeće tri raskrsnice:

- Raskrsnica ulica Neznanih junaka, Gavrila Principa, Svetog Save i Filipa Višnjića
- Raskrsnica ulica Neznanih junaka, Ive Andrića, Stefana Dečanskog i Sremske ulice
- Raskrsnica ulica Neznanih junaka, Kulina bana i Dušana Baranina

Zatim su video zapisi obrađeni primjenom softvera koji se koristi za reprodukciju i obradu video zapisa (Media Player Classic Home Cinema).

Prilikom utvrđivanja kritičnog intervala sljeđenja identifikovana su dva karakteristična slučaja. Prvi slučaj je onaj u kome vozači odbacuju bar jedan interval prije stupanja u kružni tok. Drugi karakteristični slučaj je kada su vozači odmah prihvatili interval i praktično bez zaustavljanja ušli u zonu kruženja. Drugi slučaj se uglavnom pojavljuje kada nema vozila u zoni kruženja, a tada interval sljeđenja u prioritetnom toku praktično nije niti prihvaćen niti odbačen. Iz tog razloga ovi intervali nisu relevantni za utvrđivanje kritičnog intervala sljeđenja. Zbog intenzivnih saobraćajnih tokova na prilazima najveći dio uzorka koji je snimljen pripada prvom slučaju.

Kako bi se izdvojili prihvaćeni i odbaćeni intervali, na raskrsnici su povučene dvije imaginarne linije, jedna na ulazu (ulivu) u kružni tok (A), a druga na mjestu potencijalnog konflikta između vozila u glavnom toku i vozila na sporednom toku (B), kao što je predstavljeno na narednoj slici (slika 2.).

Slika 2. Imaginarne konfliktne linije A i B

Kako bi se procijenio kritični interval sljeđenja, analizirana su dva karakteristična vremenska trenutka, T_1 kao početak intervala i T_2 kao kraj intervala.

Pored prihvaćenih i odbačenih intervala sljeđenja vozila, uzeti su u obzir i prihvaćeni i odbaćeni intervali pristizanja. Interval pristizanja se računa kao razlika ova dva karakteristična vremenska trenutka (T_2 i T_1).

Za svaki izračunati interval pristizanja provjerava se da li je on prihvaćen ili odbačen, u zavisnosti od toga da li je vozilo A stupilo u kružni tok ili ne.

Na narednoj slici je prikazana saobraćajna situacija u kojoj je interval pristizanja za vozilo C odbačen.

Slika 3. Odbačeni interval pristizanja

Nakon toga, pristupa se utvrđivanju intervala sljeđenja za vozilo B. Trenutak kada vozilo C dotakne imaginarnu liniju B predstavlja prvi vremenski trenutak T_1 za vozilo B. Nakon prolaska vozila C, vozilo A se uključilo u zonu kruženja.

Slika 4. Vremenski trenutak T_1

Trenutak kada vozilo B koje kruži u glavnom toku dotakne imaginarnu liniju B predstavlja drugi vremenski trenutak T_2 za vozilo A. Dakle, vozilo A je prihvatilo vremenski interval sljeđenja koji predstavlja razliku između vremenskih trenutaka T_2 i T_1 .

 Слика 5. Времeнски тренутак T_2

Nakon izdvojenih prihvaćenih i odbačenih intervala pristupilo se formiranju parova intervala, a jedan par čine prihvaćen i maksimalni odbačen interval. Maksimalni odbačen interval predstavlja interval koji ima najveću vrijednost od svih odbačenih intervala, pojedinačno za svakog vozača vozila sa sporednog toka. Ovako formirana baza podataka služi za utvrđivanje kritičnog intervala sljeđenja vozila.

Kao što je opisano u prethodnoj tački, zbog nemogućnosti direktnog mjerenja kritičnog intervala sljeđenja razvijene su brojne metode i procedure za njegovo procjenjivanje. Prema rezultatima dosadašnjih istraživanja, najpreciznija je metoda maksimalne vjerodostojnosti (Troutbeck, 1992).

U okviru analize prema ovoj metodi, koriste se sljedeći parametri za utvrđivanje kritičnog intervala sljeđenja (Tian i dr., 1999):

y_i - logaritam prihvaćenog intervala od strane i -tog vozača

x_i - logaritam najvećeg odbačenog intervala od strane i -tog vozača, $x_i=0$ ako nijedan interval nije odbačen

μ - sredina raspodjele logaritama pojedinačnih kritičnih intervala sljeđenja vozača

σ^2 - varijansa raspodjele logaritama pojedinačnih kritičnih intervala sljeđenja vozača

$f(\cdot)$ - funkcija gustine vjerovatnoće za normalnu raspodjelu

$F(\cdot)$ - kumulativna funkcija raspodjele za normalnu raspodjelu

Prosječna vrijednost kritičnog intervala sljeđenja t_c i varijansa s^2 mogu se izračunati na sljedeći način:

$$t_c = e^{\mu+0.5\sigma^2} \quad (3)$$

$$s^2 = t_c^2(e^{\sigma^2} - 1) \quad (4)$$

5. Rezultati istraživanja

Utvrđene vrijednosti karakterističnih vremenskih trenutaka kao rezultata lokalnih mjerenja unijete su u program Excel i na taj način je formirana baza podataka. U prvu kolonu upisivan je redni broj vozila, u drugu interval pristizanja koji je ili prihvaćen ili odbačen što je naznačeno komentarom u tabeli. U trećoj i četvrtoj koloni su upisivani prihvaćeni i odbaćeni intervali sljeđenja.

driver	lag	accepted gap	rejected gap
35		3.785	2.383
36		9.918	3.421
37			2.228
			3.488
			2.404
		8.871	3.089
38		4.424	2.755
39		7.945	3.837
40		4.403	
41		8.871	2.232
42	1.438		
			5.562
			3.204
			4.358
			3.421
			2.647
		6.236	2.800
43			3.649
			2.654
			3.058
		5.473	
44		4.247	
45			3.250
		6.805	

Слика 6. Izdvojeni dio tabele sa intervalima sljeđenja

U svrhu procjene kritičnog intervala sljeđenja vozila je, nakon izvršene selekcije, izdvojeno 127 parova prihvaćenih i odbačenih intervala. Selekcija je izvršena na taj način što su odbaćeni parovi u kojima je prihvaćeni interval manji od prethodno odbačenog intervala, zatim parovi u kojima su prihvaćeni intervali predugi jer ukazuju na situaciju kada u okviru istog intervala u glavnom toku uđe dva ili više vozila sa sporednog toka.

Pored toga, kao što je prethodno istaknuto, u obzir nisu uzeti intervali koji su prihvaćeni bez bar jednog prethodno odbijenog intervala. U skladu sa prihvaćenom metodologijom izračunata je $\ln$ funkcija, a zatim je u programu MINITAB utvrđeno da prihvaćeni i odbaćeni intervali sljeđenja prate *log-normalnu* raspodjelu.

Testiranje normalnosti raspodjele je izvršeno primjenom Anderson-Darling testa, a dobijene p vrijednosti koje su veće od 0,05 ukazuju na to da je riječ o normalnoj raspodjeli, a to je ilustrativno prikazano na slici 7. i slici 8.

Slika 7. Testiranje normalnosti raspodjele za prihvaćene intervale sljeđenja

Slika 8. Testiranje normalnosti raspodjele za odbačene intervale sljeđenja

Primjenom metode maksimalne vjerodostojnosti utvrđene su vrijednosti aritmetičke sredine i standardne devijacije. Uvrštavanjem aritmetičke sredine $\mu=1,385$ i standardne devijacije $\sigma=0,112342$ u formulu (3) dobija se prosječna vrijednost kritičnog intervala sljeđenja:

$$t_c = e^{1,385+0,5 \cdot (0,112342)^2} = 4,02 \text{ [s]}$$

6. Diskusija

HCM metoda se najčešće primjenjuje u svijetu, a ona je implementirana u praktično sve aplikativne softvere koji se primjenjuju u inženjerskoj praksi u postupcima operativne i planske analize. Iz tog razloga izvršena je uporedna analiza rezultata istraživanja veličine kritičnog intervala sljeđenja sa preporučenim vrednostima u priručniku HCM 2016. Vrijednost kritičnog intervala sljeđenja utvrđena u ovom radu od 4,02 [s] značajno se razlikuje od preporučene vrednosti ovog parametra u postupku (HCM, 2016), koja za istraživani tip raskrsnica iznosi 4,98 [s].

Na narednoj slici su predstavljene vrijednosti kritičnog intervala sljeđenja preporučene za kružne raskrsnice koje su rezultat istraživanja u BiH i vrijednosti koje preporučuje HCM.

Slika 9. Poređenje vrijednosti kritičnog intervala sljeđenja u BiH i priručniku HCM 2016

Ova razlika između vrijednosti preporučene u HCM-u i vrijednosti utvrđene istraživanjem ukazuje na činjenicu da je prilikom proračuna kapaciteta kružnih raskrsnica u našem regionu potrebno izvršiti kalibriranje ove metodologije. Ako se koristi manuelni metod proračuna treba koristiti izvorni Harders model sa vrijednostima kritičnog intervala koje su rezultat istraživanja. Ukoliko se koriste aplikativni softveri (Synhro, HCS, SIDRA i dr.) treba iskoristiti mogućnost i unijeti utvrđenu vrijednost kritičnog intervala, kao i vrijednosti drugih parametara saobraćajnog toka, ako su oni utvrđeni u lokalnim uslovima odvijanja saobraćaja.

7. Zaključak

Rezultati istraživanja koje je izvršeno za potrebe ovog rada pokazali su da postoji značajna razlika između vrijednosti kritičnog intervala sljeđenja u odnosu na vrijednosti preporučene u HCM-u, ali i u odnosu na druga slična istraživanja koja su realizovana u drugim zemljama. U skladu sa tim, radi preciznijeg proračuna kapaciteta kružnih raskrsnica u okviru operativnih i planskih analiza kružnih raskrsnica, potrebno je koristiti podatke koji odgovaraju lokalnim uslovima. Upotreba preporučenih vrijednosti parametara saobraćajnog toka u aplikativnim softverima može uticati na donošenje pogrešnih investicionih odluka. Zbog sličnog nasljeđa i okruženja, autori su mišljenja da se rezultati rada mogu primijeniti i u zemljama regiona, odnosno Jugoistočne Evrope.

Estimation of critical vehicle gap time at roundabouts

Vuk Bogdanović, Ph.D.

University of Novi Sad, Faculty of Technical Sciences

Dunja Radović,

University of Istočno Sarajevo, Faculty of Transport and Traffic Engineering Doboj

Abstract: According to the models which are commonly used in practice, the capacity of roundabouts depends on the value of critical headway. Critical headway size depends on numerous objective factors, primarily on geometric characteristics of the intersection. However, research so far have shown that beside characteristics of the intersection, value of critical headway depends on many other factors, primarily on driver behavior. Driver behavior is the result of the action of numerous factors that depend on the influence of local environment, habits, mentality, etc. For that very reason, determination of the value of this traffic flow parameter in local research is recommended in many models. Within this paper, the results related to the value of critical headway determined by research which are conducted in Bosnia and Herzegovina are presented. The presented value of critical headway estimated by 127 pairs of accepted and rejected headways can be used for objective determination of roundabout capacity in our region.

Keywords: driver behavior, roundabouts, critical tracking interval

Literatura

- [1] Highway Capacity Manual (December 2010). Washington D.C: Transportation Research Board of The National Research Council.
- [2] Highway Capacity Manual, VOLUME 4: Applications Guide, Chapter 33 Roundabouts: Supplemental (December 2010). Washington D.C: Transportation Research Board of The National Research Council.
- [3] Highway Capacity Manual Edition 6. (2016). Washington D.C: Transportation Research Board, The National Research Council.
- [4] Harders, J. (1968). Die Leistungsfähigkeit nicht signalregelter städtischer Verkehrsknoten [Capacity of unsignalized urban intersections]. Bonn: Bundesminister für Verkehr.
- [5] Gartner, N. H., Messer, C. J., & Rath, A. (2002). Traffic flow theory-A state-of-the-art report: revised monograph on traffic flow theory.
- [6] Raff, M. S. (1950). A volume warrant for urban stop signs.
- [7] Kuzović, Lj., & Bogdanović, V. (2010). Teorija saobraćajnog toka. *Fakultet tehničkih nauka, Novi Sad*, 104.
- [8] Brilon, W., Koenig, R., & Troutbeck, R. J. (1999). Useful estimation procedures for critical gaps. *Transportation Research Part A: Policy and Practice*, 33(3-4), 161-186.
- [9] Tian, Z., Vandehey, M., Robinson, B. W., Kittelson, W., Kyte, M., Troutbeck, R., ... & Wu, N. (1999). Implementing the maximum likelihood methodology to measure a driver's critical gap. *Transportation Research Part A: Policy and Practice*, 33(3-4), 187-197.
- [10] Macioszek, E. (2017). The comparison of models for critical headways estimation at roundabouts. In *Contemporary Challenges of Transport Systems and Traffic Engineering* (pp. 205-219). Springer, Cham.
- [11] Krishna, Y. (2015). Modelling Performance Parameters of Roundabouts Using Gap Acceptance Method for Indian Traffic Scenario (Doctoral dissertation).
- [12] Xu, F., & Tian, Z. Z. (2008). Driver behavior and gap-acceptance characteristics at roundabouts in California. *Transportation Research Record*, 2071(1), 117-124.
- [13] Kyte, M., Dixon, M., List, G., Flannery, A., & Rodegerdts, L. (2006). NCHRP 3-65: Applying Roundabouts in the United States. Final Report. Kittelson & Associates, Inc., Portland, Ore.
- [14] Gazzarri, A., Martello, M. T., Pratelli, A., & Souleyrette, R. R. (2012). Estimation of gap acceptance parameters for HCM 2010 roundabout capacity model applications. *XVIII Urban Transport: Urban Transport and the Environment in the 21st Century*, 128, 309-319.
- [15] Barry, C. D. (2012). *Calibration of the HCM 2010 roundabout capacity equations for Georgia conditions* (Doctoral dissertation, Georgia Institute of Technology).
- [16] Zheng, D., Chitturi, M., Bill, A., & Noyce, D. A. (2011). Comprehensive evaluation of Wisconsin roundabouts, Volume 1: Traffic operations. Madison, WI: Traffic Operations and Safety Laboratory.
- [17] Wei, T., & Grenard, J. L. (2012). Calibration and validation of Highway Capacity Manual 2010 capacity model for single-lane roundabouts. *Transportation research record*, 2286(1), 105-110.
- [18] Troutbeck, R. J. (2014). Estimating the mean critical gap. *Transportation Research Record*, 2461(1), 76-84.
- [19] Troutbeck, R. J. (1992). *Estimating the critical acceptance gap from traffic movements*. Queensland University of Technology.