Pregled statističkih metoda za procjenu kritične vremenske praznine na kružnom raskrižju

Maslać, Danijela; Jurić, Zvonimir; Miletić, Kristina

Source / Izvornik: **Common Foundations 2018 - uniSTem: 6th Congress of Young Researchers in the Field of Civil Engineering and Related Sciences, 2018, 142 - 148**

Conference paper / Rad u zborniku

Publication status / Verzija rada: **Published version / Objavljena verzija rada (izdavačev PDF)**

https://doi.org/10.31534/CO/ZT.2018.20

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:123:802391

Rights / Prava: Attribution-NonCommercial-NoDerivatives 4.0 International/Imenovanje-Nekomercijalno-Bez prerada 4.0 međunarodna

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

FCEAG Repository - Repository of the Faculty of Civil Engineering, Architecture and Geodesy, University of Split





UDRUGA HRVATSKIH GRAĐEVINSKIH FAKULTETA
FAKULTET GRAĐEVINARSTVA, ARHITEKTURE I GEODEZIJE
ZT 2018

DOI: https://doi.org/10.31534/CO/ZT.2018.20

Pregled statističkih metoda za procjenu kritične vremenske praznine na kružnom raskrižju

Danijela Maslać[1], Zvonimir Jurić[2], Kristina Miletić[1]

(1) Građevinski fakultet Sveučilišta u Mostaru, Republika Bosna i Hercegovina, danijela.maslac@gf.sum.ba, kristina.miletic@gf.sum.ba

(2) Samostalni statističar/programer, Zagreb, zvonimirjuric@yahoo.com.

Sažetak

Za kalibraciju kružnog raskrižja ključni je parametar kritična vremenska praznina koja se ne može direktno mjeriti, već se statistički procjenjuje. U ovom će se radu prikazati odabrane, najčešće korištene statističke metode procjene. Upravo je procjena kritične vremenske praznine jedan od najzahtjevnijih zadataka znanosti analize prometnog toka kružnih raskrižja.

Ključne riječi: kritična vremenska praznina, statističke metode, kružna raskrižja

An overview of statistical methods for estimating critical gap at a roundabout

Abstract

The critical gap is an important parameter for capacity analysis at the roundabout. This parameter is stochastically distributed, and it cannot be obtained directly by field measurements. Here are presented some often use estimation methods.

Keywords: critical gap, estimation methods, roundabout

1. Uvod

Kružna raskrižja postaju sve popularnija rješenja, a posebice radi sigurnosti i općenito učinkovitosti raskrižja. U odnosu na klasična raskrižja imaju veći kapacitet, kraća su zadržavanja te je i manja potrošnja goriva. U svrhu opravdanosti izgradnje raskrižja nužna je analiza ključnog kriterija tj. kapaciteta. U svijetu postoji veliki broj modela kapaciteta kružnih raskrižja koji su uglavnom prilagođeni uvjetima zemlje iz koje potječu.
Stoga je za analizu kapaciteta kružnog raskrižja bitna kalibracija parametara u lokalnim uvjetima.
Kalibracija je proces prilagodbe ulaznih parametara prema stvarnim, realnim prometnim uvjetima na raskrižju čije su vrijednosti mjerljive, a u svrhu dobivanja realnijih podataka teoretskih modela prema stvarnim uvjetima odvijanja prometa na njima.
Primjerice, prema modelu HCM2010 [1], kapacitet kružnog raskrižja iznosi:

$$c = Ae^{-Bv_c} \qquad \text{(voz/h)} \tag{1}$$

gdje je:

$$A = \frac{3600}{t_f}$$

$$B = \frac{t_c - \frac{t_f}{2}}{3600}$$

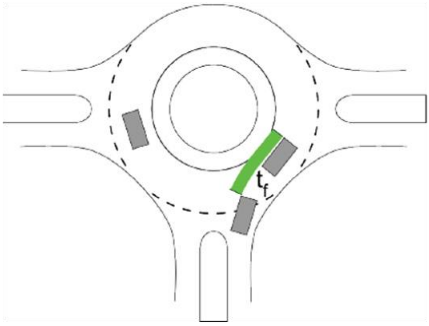
c - kapacitet privoza (traka) (voz/h),
v_c- opterećenje glavnog toka (voz/h),
t_f -vrijeme slijeda (s),
t_c-kritična vremenska praznina (s).

2. Parametri kalibracije

Dakle vrijeme slijeda *(t_f)* i kritična vremenska praznina *(t_c)* su nužni parametri kalibracije kružnog raskrižja. Vrijeme slijeda može se direktno mjeriti na terenu, dok se kritična vremenska praznina ne može direktno mjeriti, već se eksplicitno procjenjuje na terenu.

2.1. Vrijeme slijeda

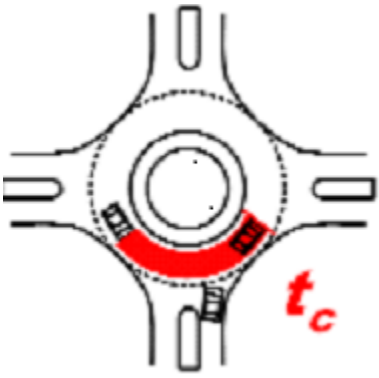
Vrijeme slijeda (t_f) je prosječan vremenski interval između odlaska dva uzastopna vozila iz sporednog privoza u konfliktni presjek prioritetnog toka u uvjetima kontinuirane kolone u sporednom privozu (Slika 1).



Slika 1. Vrijeme slijeda [3]

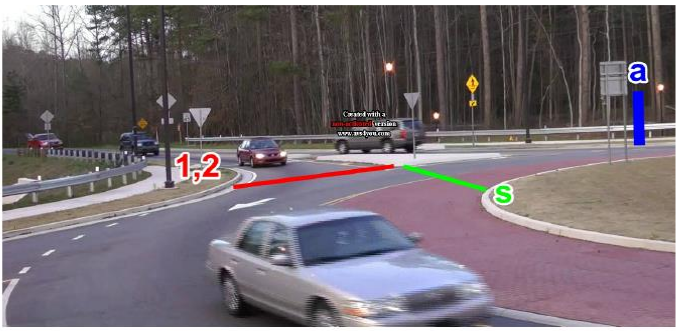
2.2. Kritična vremenska praznina

Kritična vremenska praznina (t_c) predstavlja minimalnu vremensku prazninu koju će vozilo sporednog toka prihvatiti za ulazak u glavni tok [2] (Slika 2). Ne može se eksplicitno mjeriti, te su za procjenu kritične vremenske praznine potrebni podaci o odbačenim i prihvaćenim vremenskim prazninama vozila sa sporednog toka.



Slika 2. Kritična vremenska praznina [3]

Prihvaćene i odbačene vremenske praznine mjere se direktno, najčešće s videosnimke, registrirajući ključne događaje, kao na Slici 3.



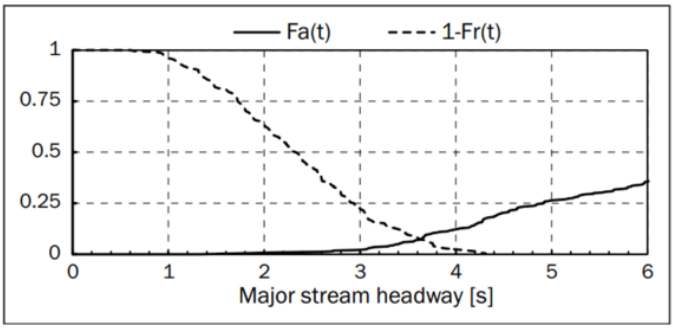
Slika 3. Ključni presjeci za registriranje [3]

Nadalje na temelju podataka o prihvaćenim i odbačenim vremenskim prazninama, odabranom statističkom metodom procjenjuje se kritična vremenska praznina.
U literaturi se spominje velik broj metoda, a neke od njih će se izložiti u nastavku ovog rada. Svaka od tih metoda daje različite vrijednosti parametra.

3. Metode procjene kritične vremenske praznine

3.1. Raff metoda

Raff metoda je neparametarska metoda procjene, dakle ne zahtijeva unaprijed definiranu razdiobu vremenskih praznina unutar glavnog toka, već izravno iz podataka o prihvaćenim i odbačenim vremenskim prazninama konstruira empirijske razdiobe pomoću kojih se traži rješenje.
Metoda je grafička i zasnovana je na Raffovoj definiciji [4],dakle kritičnu prazninu *(tc*) definira kao prazninu koja ima jednak broj prihvaćenih kraćih praznina i broj dužih odbačenih praznina. Kod ove metode koriste se dvije kumulativne krivulje raspodjele:
-**Fa(t)** je empirijska kumulativna funkcija distribucije za prihvaćene praznine,
-**Fr(t)** za odbačene praznine.



Slika 4. Grafički prikaz Raff metode [4]

Sjecište krivulje **Fa(t)** s krivuljom **1 - Fr(t)** daje vrijednost t_c za kritičnu vremensku prazninu koja predstavlja medijan distribucije kritičnih praznina. Krivulja je stepenasta i sastoji se od diskretnih točaka.

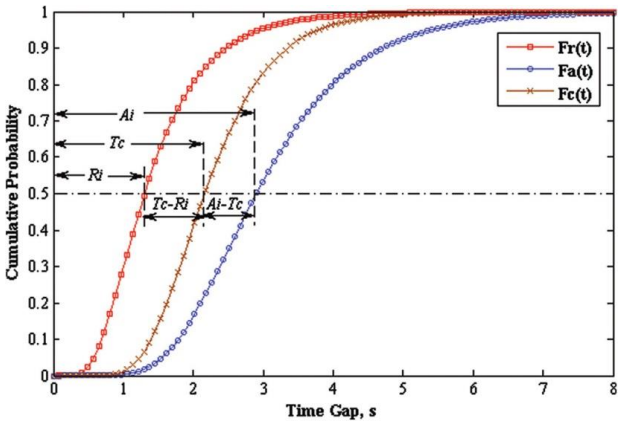
3.2. MLM metoda

Metoda maksimalne vjerojatnosti (MLM) je parametarska metoda pa se treba unaprijed definirati razdioba za koju se onda traže potrebni parametri (očekivanje, standardna devijacija...)
U literaturi NCHR 572 se preporučuje koristiti log-normalnu razdiobu zato što jako dobro opisuje ovu vrstu podataka, asimetrična je i daje isključivo pozitivne vrijednosti.
Funkcija vjerojatnosti definira se kao vjerojatnost da se distribucija kritične praznine nalazi između promatrane distribucije maksimalnih odbačenih praznina i prihvaćenih praznina, prema izrazu (2)

$$L = \sum_{d=1}^{n} ln[F_a(a_d) - F_r(r_d)] \qquad (2)$$

gdje je:
d- vozač na sporednom privozu (veličina uzorka n),
a_d-prihvaćena praznina,
r_d-odbačena praznina.
U ovom se modelu uzimaju u obzir samo maksimalne odbačene praznine, koje su manje od odgovarajućih prihvaćenih praznina.
Dakle za prihvaćenu prazninu *a*, postoji samo jedna odgovarajuća odbačena praznina *r* koja se razmatra.
Za jednog individualnog vozača *d* na sporednom toku (privozu) promatra se: jedna prihvaćena praznina a_d i jedna odgovarajuća maksimalna odbačena praznina r_d.. Maksimalna odbačena praznina je najveća vrijednost svih odbačenih praznina za individualnog vozača na sporednom toku. MLM metoda temeljena je na pretpostavci da su svi vozači na sporednom privozu konzistentni i homogeni ($a_d \geq r_d$).
To znači da će svaki vozač na sporednom toku odbaciti svaku prazninu koja je manja od njegove kritične vremenske praznine te da će prihvatiti prvu prazninu koja je veća od kritične
Slika 5 predstavlja grafički prikaz MLM metode procjene kritične vremenske praznine, gdje je:

Fa(t) - krivulja funkcije vjerojatnosti prihvaćenih praznina,
Fc(t) - krivulja funkcije vjerojatnosti kritične vremenske praznine,
Fr(t) - krivulja funkcije vjerojatnosti odbačenih praznina.



Slika 5. Grafički prikaz MLM metode [5]

3.3 Logit metoda

Logit metoda koristi negativni logaritam funkcije vjerodostojnosti (*Likelihood*) [4]. Razvijeno je nekoliko pristupa koji se mogu sažeti kao logit modeli. Logit je u osnovi linearni regresijski model s matematičkim oblikom kao što je prikazano u jednadžbi (3):

$$P(a) = (1 + e^{-(\beta_0 + \beta_1(i))})^{-1} \quad (3)$$

gdje je i - vjerojatnost prihvaćanja praznine veličine,, a β-regresijski koeficijenti.

Ovaj model često služi i za provjeru utjecaja različitih neovisnih varijabli u kritičnoj praznini, kao što je vrijeme čekanja, prosječna brzina, itd.

Treba napomenuti da s ovom formulacijom vozač koji prihvaća prazninu manju od prethodno odbačene, ne može se definirati kao "nekonzistentan" jer vrijeme čekanja može objasniti to ponašanje. Stoga treba uključiti sve praznine, ne samo onu maksimalnu koju svaki vozač odbaci.

3.4. Wu metoda

Wu metoda se temelji na ravnotežnoj vjerojatnosti odbačenih i prihvaćenih smjerova.

Ne zahtijeva unaprijed definiranu funkciju raspodjele kritičnih praznina ili pretpostavke o dosljednosti ili homogenosti vozača. Kumulativna je funkcija gustoće (CDF-*cumulative distribution function*) kritičnih praznina.

Glavna prednost ovog modela je da pruža pravi prosjek kritične vremenske praznine, a za to ne treba unaprijed definirana funkcija distribucije kritične vremenske praznine. Pretpostavke se odnose na dosljednost i homogenost vozača dok je MLM trebao unaprijed definiranu funkciju raspodjele, kao i ove pretpostavke.

Definirana je matematičkim izrazom

$$F_{tc}(t) = \frac{F_a(t)}{F_a(t)+1-F_r(t)} = 1 - \frac{1-F_r(t)}{F_a(t)+1-F_r(t)} \quad (4)$$

gdje je:

$F_a(t)$-funkcija vjerojatnosti prihvaćenih praznina,
$F_r(t)$- funkcija vjerojatnosti odbačenih praznina.
Ova metoda daje empirijsku distribuciju kritičnih praznina što može biti korisno za mikroskopsku simulaciju.

4. Zaključak

Procjena kritične vremenske praznine zahtjevan je dio kalibracije kružnog raskrižja, a posebice zbog velikog izbora statističkih metodi. Ovaj rad je kratki pregled najčešće korištenih statističkih metoda procjene, a daljna istraživanja su temeljena na njihovoj primjeni.
Naime svaka od ovih metoda daje različite vrijednosti kritične praznine, stoga je nužno odrediti pri kojim uvjetima se koja metoda treba koristiti.

Literatura

[1] Transportation Research Board of the National Academies NCHR 572, Roundabouts in the United States, 2007.

[2] Cvitanić, D.: Modeliranje kapaciteta i odrađivanje razine usluge nesemaforiziranih raskrižja, magistarski rad, Građevinski fakultet Sveučilišta u Splitu, Split, 2000.

[3] Barry, C.: Calibration of the hcm 2010 single-lane Roundabout capacity equations for Georgia conditions, disertacija, Georgia, 2012. I riječ disertacija bi trebala biti napisana na engleskom jeziku kada je već sve drugo tako napisano

[4] Vasconcelos, A. L. P., Seco, Á. J. M., Silva, A. M. C. B.: Comparison of Procedures to Estimate Critical Headways at Roundabouts, Promet – Traffic&Transportation, Vol. 25, 2013, doi: 10.7307/ptt.v25i1.1246.

[5] Ahmad, A., Rastogi, R.,Chandra, S.: Estimation of critical gap on a roundabout by minimizing the sum of absolute difference in accepted gap data , Canadian Journal of Civil Engineering 42(12), 2015, doi:10.1139/cjce-2014-0450 .

[6] Amin, H.J., Maurya A. K.: A review of critical gap estimation approaches at uncontrolled intersection in case of heterogeneous traffic conditions, Journal of Transport Literature, 9(3): 5-9, Jul. 2015, doi:10.1590/2238-1031.jtl.v9n3a1.

[7] Wu, N.: Estimating Distribution Function of Critical Gaps at Unsignalized Intersections Based on Equilibrium of Probabilities. Transportation Research Record, No. 2286 (TRB 2012 Annual Meeting, Preprint No. 12-0453). TRB, National Academies, Washington, D.C., USA, 2012.

[8] Gazzarri, A., Martello, M. T., Pratelli, A.,Souleyrette, R. R.: Estimation of Gap Acceptance Parameters for HCM 2010 Roundabout Capacity Model Applications" Civil Engineering Faculty Publications. Paper 3, 2012, doi: 10.2495/UT120271.