Analiza HTP krivih za formiranje funkcionalne zavisnosti na širem području Republike Srpske

PETAR R. PRAŠTALO, Univerzitet u Banjoj Luci,

Arhitektonsko-građevinsko-geodetski fakultet,
Banja Luka, Republika Srpska

ANICA B. MILANOVIĆ, Univerzitet u Banjoj Luci,

Arhitektonsko-građevinsko-geodetski fakultet,
Banja Luka, Republika Srpska

Stručni rad

UDC: 551.577.2:519.87(497.6)

DOI: 10.5937/tehnika2104411P

U hidrotehničkoj praksi velika je potreba za korišćenjem podataka o padavinama na širem području oblasti u kojoj se radi istraživanje. Nedostatak padavinskih stanica koje mogu da registruju kiše kraćeg trajanja, manje od 24 časa, predstavlja ogroman problem inženjerima u praksi. U ovom radu se koristi analiza već postojećih podataka o padavinama koji su bili dostupni, a na osnovu kojih je formirana funkcionalna zavisnost šireg regiona. Tako formirana funkcionalna zavisnost olakšava rješavanje velikog broja hidrotehničkih problema. U ovom radu se prikazuje formiranje matematičkog modela na osnovu MS-a.

Ključne riječi: HTP krive, ITP krive, matematički model, meteorološke stanice

1. UVOD

Mjerenje padavina na određenim karakterističnim lokacijama, tzv. meteorološkim (padavinskim) stanicama obavlja se pomoću uređaja za diskontinualno i kontinualno mjerenje. Veliki broj MS u Republici Srpskoj upravo mjeri diskontinualno padavine pomoću kišomjera i totalizatora. Mali broj MS je opremljen sa uređajima koji mogu da kontinualno registruju padavine.

Zavisnosti visina kiše – trajanje kiše – povratni period (HTP krive) predstavljaju jedan od osnovnih ulaznih podataka za hidrološke proračune i projektovanje objekata za zaštitu od velikih voda na malim i srednjim slivovima na kojima su mjerodavna trajanja kiše kraća od 24 časa [1]. Ovakva zavisnost se dobija statističkom analizom podataka o kratkotrajnim jakim kišama sa pluviografskih stanica nakon primarne obrade izdvajanja maksimalnih visina kiša u intervalima vremena različitih dužina [1].

Osnovni problem u Republici Srpskoj jeste loša

pokrivenost teritorije pluviografima, tako da ostaje problem o raspoloživim podacima za lokacije koje nisu pokrivene sa mjerenjima.

U ovom radu se analiziraju postojeće HTP krive, koje pokrivaju sjeverni dio RS. Na osnovu HTP krivih analiziran je jedan matematički model pomoću kojeg je formirana funkcionalna zavisnost. U ovom modelu analizirana su tri koeficijenta koja služe da se odredi visina kiše za kraće trajanje kiše, u odnosu na kišu trajanja 24 časa određenog povratnog perioda.

2. METODOLOGIJA I DOSTUPNI PODACI

Ova analiza obuhvatila je sjeverni dio Republike Srpske, odnosno one stanice za koje postoje izrađene HTP krive. Na koji način su ove HTP krive urađene autorima rada nije poznato već su bile dostupne u formiranom obliku. Dakle, u ovom radu korišćeno je 5 stanica za koje su dostupne HTP krive. U sljedećoj tabeli se prikazuju MS i njihov položaj.

Tabela 1. Prikaz MS-a koje su korištene u analizi

Redni broj	Naziv stanice	X [m]	Y [m]
1	MS Bihać	6332083.03	4965151.64
2	MS Prijedor	6398730.40	4981646.66
3	MS Banja Luka	6437501.08	4961255.55
4	MS Sanski Most	6395758.38	4959020.43
5	MS Doboј	6564407.07	4953932.02

Adresa autora: Petar Praštalo, Univerzitet u Banjoj Luci, Arhitektonsko-građevinsko-geodetski fakultet, Banja Luka, Vojvode Stepe Stepanovića 77, Republika Srpska

e-mail: Petarprastalo3@gmail.com

Rad primljen: 12.04.2021.

Rad prihvaćen: 16.07.2021.

Zavisnost intenziteta I , ili visine kiše P , od njenog trajanja t , i povratnog perioda T , kao finalni produkt statističke analize jakih kiša, moguće je odrediti za pluviografsku stanicu koja ima dovoljno dug period osmatranja [2]. Za većinu takvih stanica, različiti autori određivali su zavisnosti $I(t,T)$ ili $P(t,T)$ za različite namjene i sa različitim pristupima.

Izučavanje zakonitosti promjena karakteristika jakih kiša po prostoru zahtjeva, prije svega, definisanje matematičkog modela zavisnosti $I(t,T)$ u tački [2]. Ako se taj model nađe u formi $I(t,T)=(t,T,a,A,B,C,\dots)$, onda on važi za najčešće jednu MS. Ovi parametri modela mogu se dovesti u vezu sa nekim karakteristikama dnevnih kiša koje se mjere na znatno većem broju tačaka – MS-a.

Upravo u ovom radu se i analiziraju parametri modela za dostupne HTP krive u vezi sa karakterističnim dnevnim kišama određenog povratnog perioda. Za tako definisane parametre jednog modela na širem području koje obuhvata područje navedenih MS-a pronađeni su karakteristični parametri. Sa poznavanjem tih parametara, kao i karakterističnih vrijednosti dnevnih kiša uz statističku analizu moguće je jednostavno izraditi HTP ili ITP krive. Ovo omogućava da se dođe do računskih oblika kiša za prostor koji nije obuhvaćen pluviografskim stanicama.

2.1. Metodološki pristup

Kao matematički model zavisnosti $I(t,T)$ pogodan je izraz [3]:

$$I(t,T) = \frac{I_o(T)}{(A \cdot t + 1)^B}$$

U kome su A i B bezdimenzionalni koeficijenti, a $I_o(T)$ granični (trenutni) intenzitet kiše.

Ovi koeficijenti se određuju na osnovu već postojećih HTP krivih za šire područje Republike Srbije. Ovo u suštini predstavlja kalibraciju matematičkog modela za već uspostavljene zavisnosti.

Ako se uzme da se parametri A i B , mogu predstaviti u formi karti izolacija za posmatranu teritoriju, onda se vrijednost graničnog intenziteta, $I_o(T)$ za neku tačku može odrediti preko odgovarajućih vrijednosti maksimalnih dnevnih kiša, $P(T)$. Visina dnevne kiše (1440 minuta) i vjerovatnoće P , prema modelu mogu se prikazati kao:

$$H(1440, P) = \frac{I_o(P)}{(1440 \cdot A + 1)^B} \cdot 1440$$

Odakle slijedi da je:

$$I_o(P) = H(1440, P) \cdot \frac{(1440 \cdot A + 1)^B}{1440}$$

Usvajanjem odnosa $H(1440, P) = a \cdot H_d(P)$ dobija se,

$$I_o(P) = a \cdot H_d(P) \cdot \frac{(1440 \cdot A + 1)^B}{1440}$$

Odnosno konačan oblik za visinu kiše,

$$H(t, T) = \frac{a \cdot t}{1440} \cdot \left(\frac{1440 \cdot A + 1}{A \cdot T + 1} \right)^B \cdot H_d(P)$$

Logična je pretpostavka da su veličine $H(1440, P)$ i $H_d(P)$ direktno proporcionalne, i da je koeficijent (a) blizak jedinici jer se radi o veličinama određenim iz serije godišnjih maksimuma dnevnih kiša zabilježenih na kišomjeru na jednoj MS [2]. Parametri A i B imaju opseg vrijednosti manji od 1.

U ovom radu urađeno je kalibrisanje ova tri parametra na osnovu matematičkog modela za svaku stanicu posebno. Dobijeni parametri modela se odnose isključivo za područje te stanice za koju se analiziraju parametri. Na osnovu dobijenih rezultata urađena je osjetljivost parametara a , A i B na funkcionisanje modela. Pomoću dobijenih parametara formirane su karte izolacija za šire područje koje pokrivaju korišćene MS.

2.2. Ocjena parametara matematičkog modela

Ocjena parametara matematičkog modela urađena je na način da se matematički model što bolje prilagodi HTP krivoj za određene povratne periode. Dovoljno je da se odrede parametri matematičkog modela kiše jednog povratnog perioda, jer tako određeni parametri odgovaraju i za ostale povratne periode. U tom slučaju jedino se mijenja visina dnevne kiše za određene povratne periode. Kalibracija modela određena je na način da relativna sumarna razlika bude minimalna,

$$\delta = \frac{(P_{pp} - P_{mm})}{P_{pp}} \cdot 100 [\%]$$

gdje oznake predstavljaju sledeće:

δ – relativna greška,

P_{pp} – visina kiše za postojeće podatke,

P_{mm} – visina kiše na osnovu matematičkog modela,

Pored relativne greške ocjena slaganja modela urađena je i pomoću Nash-Sutcliffe efikasnosti modela (NSE).

$$NSE = 1 - \frac{\sum_{i=1}^n (P_{mm} - P_{pp})^2}{\sum_{i=1}^n (P_{pp} - P_{pp,dn})^2}$$

gdje su korišćene sledeće oznake:

NSE – vrijednosti efikasnosti $[-\infty; 1]$,

P_{pp} – visina kiše za postojeće podatke,

P_{mm} – visina kiše na osnovu matematičkog modela,

$P_{pp,dn}$ – dnevna visina kiše određenog povratnog perioda za postojeće podatke,

2.3. Osjetljivost parametara matematičkog modela

Analiza osjetljivosti parametara matematičkog modela urađena je za sve razmatrane stanice. Analizirana su sva tri parametra, u odnosu na promjenu vrijednosti Nash-Sutcliffe koeficijenta efikasnosti modela (NSE).

Promjena određenog parametra svakako utiče na slaganje modela, u zavisnosti od razmatranih stanica analiziran je i uticaj pojedinih parametara na slaganje matematičkog modela sa postojećim podacima.

Za sve parametre modela (a, A i B) urađena je osjetljivost na osnovu vrijednosti koeficijenta efikasnosti NSE. Provjera je urađena tako što je jedan parametar variran u opsegu vrijednosti, dok ostala dva imaju fiksnu vrijednost. Na ovaj način utvrđeno je koji parametar je najosjetljiviji u matematičkom modelu.

Za prihvatanje rezultata matematičkog modela vrijednost efikasnosti modela treba da bude u određenim granicama prema preporukama, a koje se mogu svrstati u četiri grupe [4]:

- veoma dobro - $0.75 < NSE \leq 1.00$,
- dobro - $0.65 < NSE \leq 0.75$,
- zadovoljavajuće - $0.50 < NSE \leq 0.65$,
- nezadovoljavajuće - $NSE \leq 0.50$

Prema tome jasno je što je vrijednost bliža jedinici da je slaganje modela bolje, odnosno efikasnije.

3. PRIKAZ REZULTATA

U nastavku se prikazuju rezultati odnosno vrijednosti parametara matematičkog modela koji su dobijeni na osnovu kalibracije modela. Vrijednosti parametara date su za svaku MS koja je analizirana u ovom radu.

Tabela 2. Prikaz vrijednosti parametara matematičkog modela dobijenih kalibracijom

Naziv stanice	a [-]	A [-]	B [-]
MS Bihać	0.99936	0.169999	0.77963
MS Prijedor	0.98500	0.1697	0.7557
MS Banja Luka	1.00000	0.16949	0.77900
MS Sanski Most	0.99014	0.16997	0.77132
MS Doboj	1.01670	0.17027	0.81010

Za sve MS vrijednost efikasnosti modela je bliska 1.0, što predstavlja veoma dobro slaganje modela sa postojećim podacima.

Pored prikazanih vrijednosti parametara koji se odnose na MS, u narednoj tabeli se prikazuju vrijednosti visina kiša za određena vremenska trajanja stogodišnjeg povratnog perioda. Na slikama je takođe prikazan i grafički prikaz dobijenih HTP krivih za analizirane stanice. Pored tabelarnog i grafičkog prikaza

rezultata u nastavku se takođe prikazuju formirane karte izolinija sa vrijednostima parametara modela a, A i B. Na osnovu malog broja korišćenih stanica izolinije su linearno interpolovane između raspoloživih stanica. Obrada rezultata urađena je pomoću gis alata QGIS-a, gdje su prikazani i pripadajući slivovi na ovom području na kojima se nalaze predmetne stanice.

Slika 1 - HTP krive za MS Bihać (lijevo) i MS Doboj (desno) na osnovu matematičkog modela

Slika 2 - HTP krive za MS Prijedor (lijevo) i MS Sanski Most (desno) na osnovu matematičkog modela

Pored prikazanih rezultata i na osnovu dobijenih parametara matematičkog modela u nastavku se daje prikaz rezultata osjetljivosti parametara modela. Osjetljivost je prikazana u odnosu na srednju vrijednost

parametara za sve MS. Ova osjetljivost parametara modela data je za svaku MS posebno. Generalno, osjetljivost parametara modela se odnosi na cjelokupni oblik HTP krive i to za vrijednosti trajanja kiše od 5 minuta do 24 časa.

Slika 3 - HTP krive za MS Banja Luka na osnovu matematičkog modela

Slika 4 - Karta izolinija parametra a (lijevo) i parametra A (desno) za razmatrano područje

Slika 5 - Karta izolinija parametra B za razmatrano područje

Slika 6 - Prikaz osjetljivosti parametra a (lijevo) i parametra A (desno) u odnosu na vrijednosti NSE-a

Slika 7 - Prikaz osjetljivosti parametra B u odnosu na vrijednosti NSE-a

4. DISKUSIJA REZULTATA

Na osnovu prikazanih rezultata i formiranog matematičkog modela dobijena je funkcionalna zavisnost za šire područje Republike Srpske. Matematički model je određen sa tri parametra pri čemu za razmatrane MS svi parametri imaju blisku vrijednost. Za sve MS dobijene su visoke vrijednosti koeficijenta efikasnosti, dok relativna greška ima male vrijednosti. Dobijeni koeficijenti se razlikuju međusobno za svaku MS, ali u dosta uskim granicama, jer se prostor koji je predmet istraživanja nalazi u istim klimatskim uslovima, odnosno prilično odgovara kontinentalnom režimu padavina [5]. Prema tome može se primijetiti da sve MS imaju sličan padavinski režim.

Ukoliko se pogleda analiza osjetljivosti parametara jasno se vidi da pojedini parametri nemaju značajnu osjetljivost za neke MS. Dakle parametar a, skoro da nema osjetljivost za MS Prijedor, dok za MS

Bihać ima značajnu osjetljivost pri čemu vrijednost koeficijenta efikasnosti smanji do cca $NSE = 0.50$. Parametar A, nema značajnu osjetljivost jer njegovom promjenom u širokom opsegu nema značajnog opadanja koeficijenta efikasnosti ispod $NSE = 0.90$ za sve analizirane MS.

Najveću osjetljivost ima parametar B, jer sve analizirane MS imaju značajnu promjenu koeficijenta efikasnosti. Za vrijednosti koje su manje od srednje koeficijent efikasnosti NSE nije manji od 0.80, dok za veće vrijednosti od ovog parametra vrijednost koeficijenta efikasnosti opada i do cca 0.60.

Na osnovu prikazanih slika za osjetljivost parametara jasno je da ima razlike u osjetljivosti pojedinačnih parametara za svaku MS. Ovo svakako može da se primijeti jer navedeni prostor nema uniforman raspored padavina, odnosno na predmetnom području padavine nisu ravnomjerno raspoređene.

5. ZAKLJUČAK

U navedenom istraživanju korišćeno je svega 5 MS-a, za sjeverni dio Republike Srpske gdje su na raspolaganju bile dostupne HTP krive. U radu je korišćen jedan jedinstveni matematički model koji je imao za cilj formiranje jedne funkcionalne zavisnosti za posmatrano područje. Na osnovu provedenog istraživanja formiran je matematički model za sve korišćene MS. Određeni su parametri modela pojedinačno za sve MS. Dobijen je značajno visok Nash-Sutcliffe koeficijent efikasnosti modela (NSE), kao i zanemarljivo mala relativna greška salganja modela.

Iz razmatrane analize jasno je da je formiran jedan matematički model koji je imao za cilj da uz korištenje podataka o dnevnim visinama kiše određenog povratnog perioda sa obližnjih MS-a, dođe do podatka o visini kiše kraćeg trajanja za određeni povratni period. Na taj način uz korištenje dobijenih koeficijenata može da se ocjeni visina kiše za razmatranu lokaciju.

Tabela 3. Prikaz vrijednost HTP krive stogodišnjeg povratnog perioda u odnosu na postojeće podatke i na urađeni matematički model

t_k (min)	MS Banja Luka		MS Prijedor		MS Sanski Most		MS Bihać		MS Doboј	
	PP	MM	PP	MM	PP	MM	PP	MM	PP	MM
60	71.3	71.3	27.9	27.2	57.8	59.4	54.2	54.3	49.9	50.8
120	86.1	86.1	34.5	33.4	71.4	72.1	65.5	65.7	58.5	60.1
180	95.4	95.4	38.6	37.3	79.8	80.1	72.5	72.6	63.9	65.7
360	112.5	112.5	46.1	44.7	95.3	95.0	85.9	85.6	73.9	75.9
1440	154.3	154.3	64.3	63.3	133.0	131.7	117.4	117.3	98.2	99.8

Prema tome, jasno je da je za ovu analizu korišćen relativno mali broj MS-a na razmatranom području. Generalna preporuka je da se u budućem periodu poveća broj MS-a i na taj način dođe do HTP krivih i na osnovu toga ocjeni valjanost uspostavljenog matematičkog modela. Pored toga svakako je od interesa da se provjeri i neizvjesnost kod računskih velikih voda na osnovu podataka dobijenih uspostavljenim matematičkim modelom, kao i na osnovu preporuka iz prakse ili empirijskih formula koje se preporučuju kada nema dostupnih podataka za proračun.

LITERATURA

- [1] J. Plavšić, Ž. Topalović, and J. Despotović, Konsistentno određivanje računskih kiša, *Vodoprivreda*, vol. 47, no. 4–6, pp. 151–159, 2015.
- [2] Stevan J. Prohaska, *Intenzitet jakih kiša u Srbiji* Institut za vodoprivredu „Jaroslav Černi“ Beograd, 2013
- [3] V. Te Chow, D. R. Maidment, L. W. Mays, and L. W. M. Ven Te Chow, David R. Maidment, “Applied Hydrology Chow 1988.pdf.” pp. 1–294, 1998, [Online]. Available: http://ponce.sdsu.edu/Applied_Hydrology_Chow_1988.pdf.
- [4] H. Yuemei, Z. Xiaoqin, S. Jianguo, and N. Jina, “Conduction between left superior pulmonary vein and left atria and atria fibrillation under cervical vagal trunk stimulation,” *Colomb. Med.*, vol. 39, no. 3, pp. 227–234, , doi: 10.1234/590, 2008
- [5] H. Hrelja, *Inženjerska HIDROLOGIJA*, Građevinski fakultet Sarajevo, Sarajevo, 2007.

SUMMARY

ANALYSIS OF HDF CURVES FOR THE FORMATION OF FUNCTIONAL DEPENDENCE IN THE WIDER AREA OF THE REPUBLIC OF SRPSKA

In hydrotechnical practice, there is a great need to use precipitation data in the wider area of the area where the research is being done. The lack of precipitation stations that can register shorter-duration rainfall, less than 24 hours, poses a huge problem for Engineers in practice.

Based on this work, an analysis of existing precipitation data is used to create a functional dependence on the wider region based on the available data. Thus formed functional dependency facilitates the solving of a large number of hydrotechnical problems. This work shows the formation of a mathematical model based on MS.

Key words: *HDF curve, IDF curve, mathematical model, meteorological stations*