

Primljen / Received: 24.4.2015.

Ispravljen / Corrected: 21.7.2015.

Prihvaćen / Accepted: 18.1.2016.

Dostupno online / Available online: 10.3.2016.

Ocjena suše primjenom standardiziranog indeksa oborine i protoka te njihov odnos na primjeru Sinjskog polja

Autori:



Dr.sc. **Igor Ljubenkov**, dipl.ing.građ.
WATER DEVELOPMENT d.o.o
iljubenkov@gmail.com



Mr.sc. **Ksenija Cindrić Kalin**, dipl.ing.fiz.
Državni hidrometeorološki zavod
ksenija.cindric@cirus.dhz.hr

Stručni rad

Igor Ljubenkov, Ksenija Cindrić Kalin

Ocjena suše primjenom standardiziranog indeksa oborine i protoka te njihov odnos na primjeru Sinjskog polja

Sinjsko polje je krško polje i nalazi se u središnjem dijelu rijeke Cetine. Obuhvaća 62 km², a većim je dijelom meliorirano s povoljnim uvjetima za poljoprivredu. Za analizu suše u ovome radu primijenjeni su standardizirani indeks oborine (SPI) i standardizirani indeks protoka (SSI). Razmatrani su meteorološki podaci sa stanice Sinj i hidrološki podaci sa postaja Han i Grab iz razdoblja 1981–2010. Pomoću vrijednosti SPI i SSI određena su sušna razdoblja koja su izražena pripadnim trajanjem, intenzitetom i magnitudom.

Ključne riječi:

krško polje, suša, oborina, protok, Cetina

Professional paper

Igor Ljubenkov, Ksenija Cindrić Kalin

Evaluation of drought using standardised precipitation and flow indices and their correlations on an example of Sinjsko polje

Sinjsko field is a karst polje situated in the central part of the Cetina River. It occupies an area of 62 square kilometres and has mostly been ameliorated, thus presenting favourable conditions for agriculture. The standardised precipitation index (SPI) and the standardised streamflow index (SSI) are used in this paper for drought analysis. Meteorological data for the Sinj station, and hydrological data for the Han and Grab stations, collected in the period from 1981 to 2010, are used. The SPI and SSI values are used to define drought periods characterized by their duration, intensity, and magnitude.

Key words:

karst field, drought, precipitation, streamflow, Cetina

Fachbericht

Igor Ljubenkov, Ksenija Cindrić Kalin

Standardisierter Niederschlags- und Durchflussindex zur Dürrebewertung und ihr Verhältnis am Beispiel des Feldes Sinjsko Polje

Das Karstfeld Sinjsko Polje befindet sich im mittleren Teil des Flusses Cetina. Es umfasst 62 km² und ist größtenteils melioriert mit günstigen Eigenschaften für die Landwirtschaft. Zur Dürreanalyse wurden in dieser Arbeit der Standardisierte Niederschlagsindex (SPI) und Durchflussindex (SSI) angewandt. Meteorologische Daten der Station Sinj und hydrologische Daten der Stationen Han und Grab aus dem Zeitraum von 1981 – 2010 wurden betrachtet. Aufgrund der SPI und SSI Werte wurden Dürren ermittelt sowie mit Dauer, Intensität und Magnitude beschrieben.

Schlüsselwörter:

Karstfeld, Dürre, Niederschlag, Durchfluss, Cetina

1. Uvod

Sinjsko polje jedno je od najvećih kraških polja u Dalmaciji. U tom području poljoprivreda ima dugu tradiciju. Stoga su u drugoj polovini 20. stoljeća provedeni opsežni melioracijski radovi kako bi se osigurali povoljni uvjeti za intenzivnu poljoprivredu. Međutim, do današnjeg dana, planirani radovi nisu u potpunosti provedeni zbog čega su usjevi izloženi periodičnim poplavama u kišnoj sezoni, kao i suši tijekom ljeta. Za odvodnju i navodnjavanje Sinjskog polja koristi se kanalska mreža. Ukupna je duljina postojećih kanala oko 150 km. Dvadesetak četvornih kilometara može se navodnjavati direktno iz ovog melioracijskog sustava, ali se samo četvrtina tog područja sustavno navodnjava, što je oko 5 km². Dio poljoprivrednog zemljišta koji se nalazi u perifernim zonama izvan dosega vode iz kanala, ne navodnjava se. Također, ne navodnjava se ni obradivo zemljište koje se nalazi izvan melioracijskog područja. Dakle, znatan dio Sinjskog polja navodnjava se isključivo na prirodan način, tj. s oborinama i kapilarno iz podzemlja. Odgovarajući prinosi prije svega ovise o režimu oborina. Zbog klimatskih uvjeta, prinosi na područjima bez navodnjavanja nepredvidljivi su iz godine u godinu, a tijekom sušnih godina oni su minimalni i mogu uzrokovati velike ekonomske gubitke. Stoga je u zadnjih 20 godina prirodna katastrofa od suše u Sinjskom polju proglašena nekoliko puta (npr. 2000., 2003., 2012.). U Splitsko-dalmatinskoj županiji, kojoj Sinjsko polje pripada, suša je druga prirodna opasnost koja uzrokuje velike ekonomske gubitke s udjelom od 19 % (nakon 26 % gubitaka zbog nevremena). Treća prirodna opasnost s velikim štetama su šumski požari koji su obično povezani s dugim sušnim razdobljima u toploj polovini godine.

Klasifikaciju suša čine četiri glavne kategorije: meteorološka, hidrološka, poljoprivredna i društveno-ekonomska [1], koje se odnose na manjak oborina, protoka, vlage u tlu ili su u međusobnoj povezanosti. Kako bi se identificirala i kvantificirala meteorološka i hidrološka suša (deficit) u Sinjskom polju, u ovom radu provedena je analiza količina oborine i protoka. Na ovom području ne postoje mjerenja vlažnosti tla kao jednog od pokazatelja poljoprivredne suše. Međutim, ona je uglavnom posljedica meteoroloških suša [2, 3], zbog čega smo u mogućnosti dati (samo) kvantitativnu procjenu poljoprivredne suše. Štoviše, neki autori primjenjuju standardizirani indeks oborine (eng. *Standardized Precipitation Index* - SPI) kao indikator poljoprivredne suše, jer taj indeks ima snažnu korelaciju s poljoprivrednim prinosom [4].

U ovom radu provedena je analiza suše pomoću SPI koji ima široku primjenu u meteorološkom praćenju suše [5-15]. Sličan koncept izračuna SPI je primijenjen i na podatke protoka pa je definiran standardizirani indeks protoka (eng. *Standardized Streamflow Index* - SSI). Ova dva indeksa su zatim uspoređena na različitim vremenskim skalama kako su opisali Vicente-Serrano i Lopez-Moreno [16]. Oni su usporedili dva hidrološka indeksa - dotok i razinu vode u akumulaciji Yesa u uzvodnijem dijelu sliva rijeke Aragon (2181 km²) u Pirinejima (Španjolska). Autori ističu da sušu treba analizirati na različitim vremenskim skalama. Njihova su istraživanja potvrdila da su različite

vremenske skale SPI prihvatljive za praćenje suše vodnih resursa koji se koriste. Naglasili su potrebu testiranja primjene indeksa suše za različite vrste suša prije izrade planova praćenja suše. Na kraju, zaključili su da je potrebno provesti daljnja istraživanja i u drugim slivovima kako bi se utvrdilo vrijeme odgovora hidroloških varijabli u odnosu na klimatske karakteristike i upravljanje vodnim resursima.

Medved-Cviki i sur. [17] analizirali su odnos između mjesečnih otjecanja i klimatskih uvjeta u tri sliva u Sloveniji čije su površine između 859 km² i 2284 km², pomoću standardiziranog indeksa oborine (SPI) i Standardiziranog indeksa protoka (SSI). Autori napominju da korelacija tih varijabli može biti značajna, tako da ovaj pristup može biti koristan za upravljanje meteorološkom i hidrometeorološkom sušom.

Slično tome, Rimkus i sur. [18] analizirali su hidrološku i meteorološku sušu pomoću standardiziranog indeksa oborine na slivu rijeke Neman (97,864 km²), koji se najvećim dijelom nalazi na području Litve, a manjim dijelom na području četiriju susjednih država. Koristili su podatke s 21 meteorološke i 15 hidroloških postaja od 1961. do 2010. U tom razdoblju nisu utvrđene promjene učestalosti i intenziteta suše. Sliv rijeke Neman je znatno veći od Sinjskog polja, gotovo 1.600 puta. Dakle, jedna kišomjerna postaja i dvije hidrološke postaje u Sinjskom polju sasvim zadovoljavaju jer su smještene na području površine od približno 62 km².

Haslinger i sur. [19] proveli su regionalnu analizu povezanosti meteorološkog indeksa suše i protoka za različite slivove u Austriji čije su površine u rasponu od 13 do 622 km². Autori su otkrili značajnu korelaciju između meteoroloških podataka i protoka, osim za slivove s izraženim akumuliranjem podzemne vode i režimom snijega.

Glavni su ciljevi ovog istraživanja identificirati i kvantificirati meteorološku i hidrološku sušu, kao i odrediti njihov odnos u krškom području tj. Sinjskom polju.

2. Područje razmatranja

Rijeka Cetina ima duljinu toka 105 km te u cijelosti teče kroz Dalmaciju, hrvatsku južnu regiju. Skupina izvora rijeke Cetine nalazi se na obroncima planine Dinare na nadmorskoj visini od 382 m. Rijeka teče u jugoistočnom smjeru prema jezeru Peruča (akumulacija). Nizvodno od brane Peruča rijeka teče kroz Hrvatačko polje, a zatim kroz Sinjsko polje, koje je najveće krško polje u slivu rijeke Cetine. U najnižvodnijem dijelu toka rijeka teče kroz kanjone, mijenja smjer toka prema zapadu i na kraju se ulijeva u Jadransko more (u gradu Omišu). Pet hidroelektrana (HE) (Peruča, Orlovac, Đale, Kraljevec i Zakučac) nalazi se na rijeci Cetini i njenim pritocima. Dakle, vodni režim rijeke je pod izravnim utjecajem rada hidroelektrana (slika 1.a).

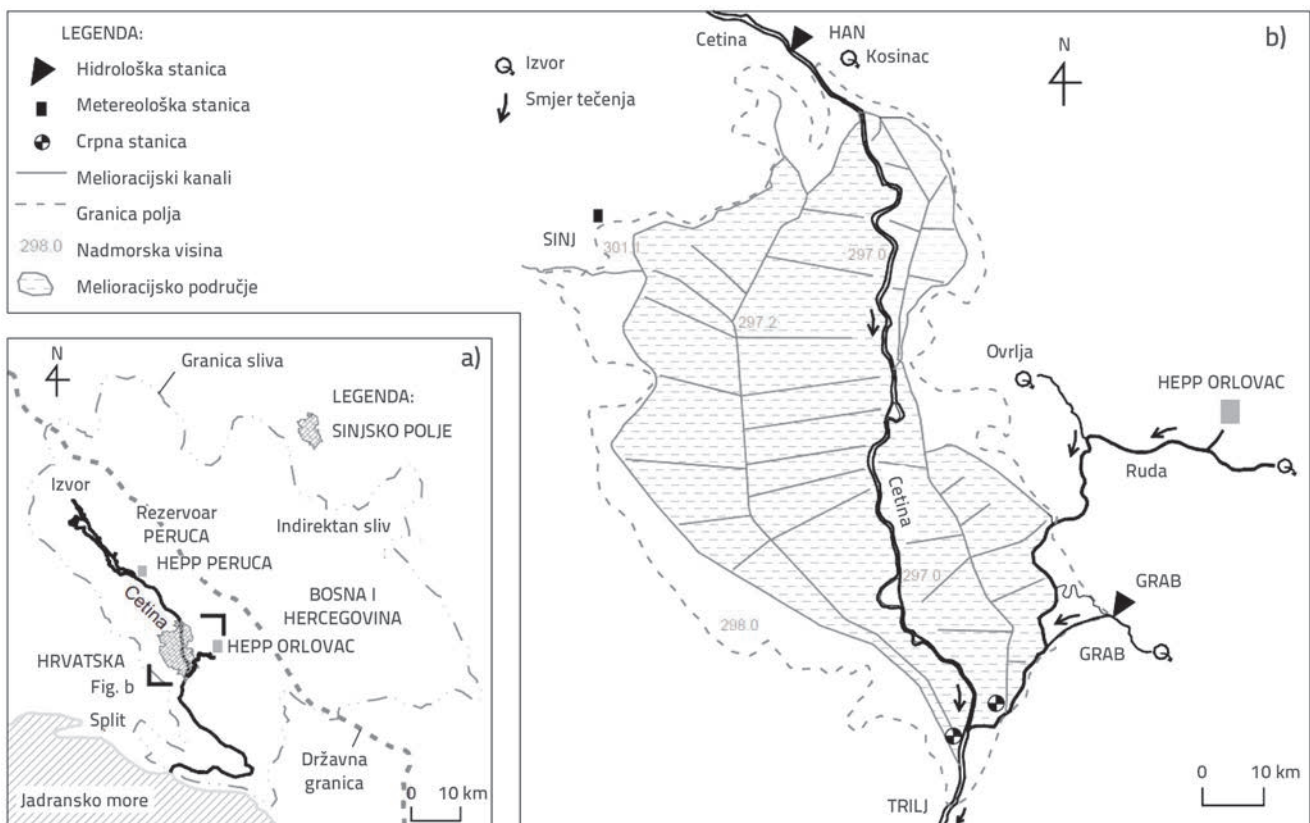
Sinjsko polje s površinom oko 62 km² jedno je od najvećih krških polja u Dalmaciji, s duljinom oko 12 km i širinom oko 5-6 km. Okruženo je planinama Dinara, Svilaja i Kamešnica, kao i nižim brežuljcima triljskog područja.

Nadmorska visina Sinjskog polja varira između 293 i 300 m. Melioracija je započela sredinom dvadesetog stoljeća otprilike na 42 km², što je oko 65 % površine polja. Međutim, još uvijek nisu potpuno osigurani uvjeti za stabilnu visoku intenzivnu poljoprivrednu proizvodnju. Razlozi su za to prije svega organizacijski i tehnički, ali ne treba zanemariti ni prirodne čimbenike kao što su klimatski i hidrološki režim. Dakle, postojeći vodnogospodarski i agronomski sustavi izloženi su povremenom višku ili manjku vode.

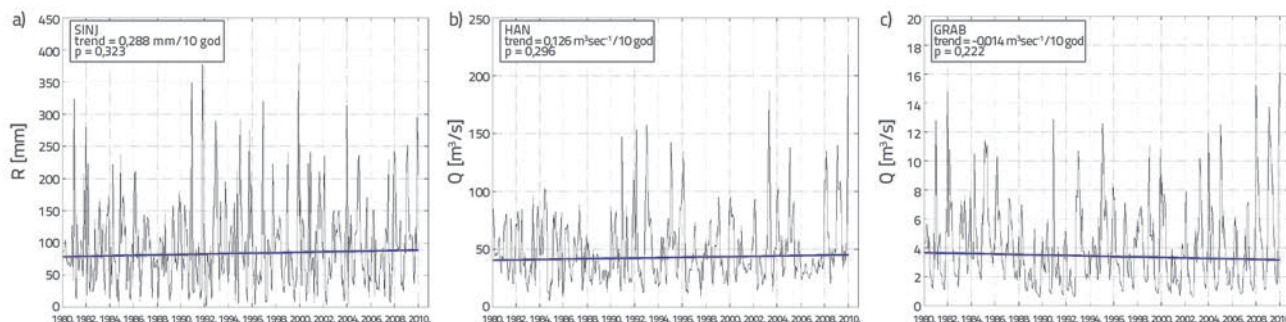
Za potrebe ovog rada korišteni su podaci o količinama oborine s meteorološke postaje Sinj i podaci o protoku s hidroloških postaja Han i Grab, koji se odnose na rijeku Cetinu odnosno njezine pritoke u 30-godišnjem razdoblju mjerenja (1981.-2010.). Rijeka Cetina je glavni izvor vode za navodnjavanje Sinjskog polja. Voda za navodnjavanje se zahvaća iz korita rijeke oko 1,5 km nizvodno od Hana i preusmjerava u kanalsku mrežu. Dakle, površinski dotok vode u toj sustav registrira se u Hanu. To je protok vode koja dolazi s cijelog uzvodnog dijela sliva ($F = 1,650 \text{ km}^2$). Stoga je protok rijeke Cetine u ovom profilu pod izravnim utjecajem HE Peruča, koji se nalazi oko 13 km uzvodno od Hana, s površinom topografskog sliva 1.200 km² i početkom rada 1960. godine. Klimatološka postaja Sinj nalazi se u sjeverozapadnom dijelu polja, a počela je s radom 1949. godine. Postaja se nalazi na koordinatama 43° 43'N i 16° 40'E i na nadmorskoj visini od 298 m (slika 1.b). To je jedina meteorološka postaja na području polja koja ujedno pripada

mreži postaja Državnog hidrometeorološkog zavoda (DHMZ). Na širem području nalaze se još dva kišomjera DHMZ-a, Han i Trilj. Prosječna godišnja temperatura zraka je 12,9°C. Godišnja količina oborine varira između 822 mm i 1686 mm, s prosjekom od 1146 mm u razdoblju 1981.-2010. Najniže prosječne količine oborine su u srpnju (42 mm), a najviše u studenom (163 mm). S poljoprivrednog aspekta dva su polugodišnja perioda važna: topli dio (ili vegetacijsko razdoblje od travnja do rujna) i hladni dio (od listopada do ožujka). U vegetacijskom razdoblju prosječno se može očekivati samo 457 mm oborine, što je oko 40 % od ukupne godišnje količine, dok se u preostalom hladnom dijelu godine prosječno može očekivati 689 mm oborine.

Što se tiče karakteristika navedenih hidroloških postaja, neki opći podaci prikazani su u tablici 1. Postaja Han se nalazi na nizvodnom dijelu mosta preko rijeke (slika 1.b), oko 4,1 km sjeveroistočno od meteorološke postaje Sinj. Mjerenja na postaji započela su krajem 20. stoljeća. Limnigraf je instaliran 1957. godine. Prosječni minimalni protoci u ljetnim mjesecima variraju između 30 i 40 m³ s⁻¹, a najviši protoci javljaju se u zimskim mjesecima s mjesečnim prosjekom oko 60 m³ s⁻¹. Protok veći od 100 m³ s⁻¹ može se javiti u svim mjesecima tijekom godine kao i vrlo mali protoci od samo nekoliko m³ s⁻¹. Najveći zabilježen protok u promatranom 30-godišnjem razdoblju bio je 331 m³ s⁻¹ (14. travnja 2004. H = 300,19 m n.n.), a najmanji je 1,6 m³ s⁻¹ (12. listopada 1983. H = 296,52 m n.n.) (slika 2.).



Slika 1. a) sliv rijeke Cetine; b) Sinjsko polje



Slika 2. Vremenski niz mjesečnih količina oborine (R) za razdoblje 1981.-2010.: a) za Sinj i protoci (Q); b) za Han; c) Grab (plava linija na dijagramu označava trend "Senov nagib" čija je vrijednost navedena u gornjem lijevom kutu uz statistiku p za procjenu značajnosti trenda)

Tablica 1. Opći hidrološki podaci o postajama Han i Grab

Postaja	Han	Grab
Vodotok	Cetina	Grab
Početak rada	1894.	1964.
Kota nule (m n.m.)	296,63	295,45
Srednji godišnji protok [m³/s]	50,0	4,1
Minimalni protok [m³/s]	1,6	0,41
Maksimalni protok [m³/s]	331	37,5

Rijeka Cetina, kad je otprilike kilometar uzvodno od Trilja, prihvaća vodu iz Rude i Graba. Protok rijeke Rude je pod izravnim utjecajem HE Orlovac (izgrađena 1972.). Vodotok Graba ima prirodni hidrološki režim, a protok ovisi o izdašnosti samog izvora površinskog dotjecanja s vlastitog sliva. Stoga je hidrološka postaja Grab također razmatrana u ovom radu (osim postaje Han čiji je režim toka pod snažnim utjecajem čovjeka zbog hidroelektrane). Hidrološka postaja Grab nalazi se na rijeci Grab, približno 800 m nizvodno od izvora, a započela je s radom 1964. Također, ona se ujedno nalazi i oko 10 km jugoistočno od meteorološke postaje Sinj. Srednji godišnji dotok Graba u Rudu je 4,1 m³/s, dok je najmanji zabilježeni protok bio 0,41 m³/s (21. rujna 1992.), a najviši 37,5 m³/s (24. prosinca 1982.) (tablica 1., slika 2.).

3. Metode

Kako bi se izračunale vrijednosti SPI na različitim vremenskim skalama (*n* mjeseci), najprije je izračunana kumulativna količina oborine za svaki mjesec *i* za *n* mjeseci unatrag. Zatim je dvoparameterska gamarazdioba prilagođena nizovima količine oborine na odabranim vremenskim skalama, pri čemu su parametri α i β određeni metodom maksimalne vjerodostojnosti [20]. Za procjenu parametara potrebno je najmanje 30 godina. U ovom je istraživanju razdoblje 1981.-2010. uzeto kao referentno u skladu s raspoloživim hidrološkim i meteorološkim mjerenjima. Dobivena teoretska kumulativna funkcija razdiobe dalje se transformira u teorijsku standardiziranu normalnu razdiobu. Dobivene SPI vrijednosti predstavljaju odstupanje od medijana izraženo u jedinicama standardne devijacije. Negativne

SPI vrijednosti upućuju na potencijalni manjak oborine na danoj lokaciji. U ovom je radu primijenjena klasifikacija intenziteta suše prema [21], koja je prikazana u tablici 2.

Prednost je upotrebe SPI da omogućuje procjenu početka i kraja suše, kao i njezin intenzitet. Sušno razdoblje za određenu vremensku skalu može se odrediti iz niza SPI vrijednosti koje započinje s prvom vrijednosti nižom od -1. Uzastopni niz negativnih SPI vrijednosti (SPI < 0) upućuju na trajanje suše koja završava kada SPI postane pozitivan ili jednak nuli. Magnituda (M) takvog sušnog razdoblja se računa kao zbroj uzastopnih SPI vrijednosti u trajanju D:

$$M = \sum_{i=1}^D SPI(i) \tag{1}$$

U radu su određena sušna razdoblja na različitim vremenskim skalama (1, 3, 6, 9, 12 i 24 mjeseci) kao i pripadajuće magnitude (M). Prednost je standardiziranog indeksa oborine (SPI) što ima mogućnost izračuna na različitim vremenskim skalama, a to je korisno ne samo za praćenje meteorološke suše već i za poljoprivrednu i hidrološku sušu.

Isti pristup je primijenjen i na protoke registrirane na hidrološkim postajama Han i Grab te je dobiven standardizirani indeks protoka (SSI), čime je omogućena usporedba meteoroloških i hidroloških varijabli. Naime, McKee i sur. (1993.) [21] navode da na primjeru izračuna SPI-a koji zahtijeva samo jednu ulaznu varijablu, sličan bi se postupak mogao primijeniti i za snježni pokrivač, protok, akumulaciju, vlažnost tla i podzemne vode. Ipak, proveli smo preliminarnu statističke analize i testirali prilagodbu gamarazdiobe empirijskim podacima protoka (nije prikazano). Grafičke provjere kao i hi-kvadrat test su potvrdili gama-razdiobu kao prihvatljivu teorijsku razdiobu za protoke Hana i Graba.

Analiza korelacije između SPI i SSI na različitim vremenskim skalama provedena je na dva sljedeća načina [16]: kontinuiranom usporedbom (svih mjeseci u kontinuitetu) i mjesečnom usporedbom. U tu svrhu korišten je standardni Pearsonov koeficijent korelacije [20].

Kako bi se utvrdile vremenske promjene količine oborine i protoka tijekom 30-godišnjeg razdoblja (1981.-2010.), procijenjen je trend pomoću Kendallove tau-metode (ili Senov nagib). Taj procjenitelj nagiba statistički je otporan za razliku od

procjene metodom najmanjih kvadrata. Statistička značajnost je provjerena pomoću Mann-Kendall testa uz razinu značajnosti od 5 % [22].

Tablica 2. Klasifikacija SPI

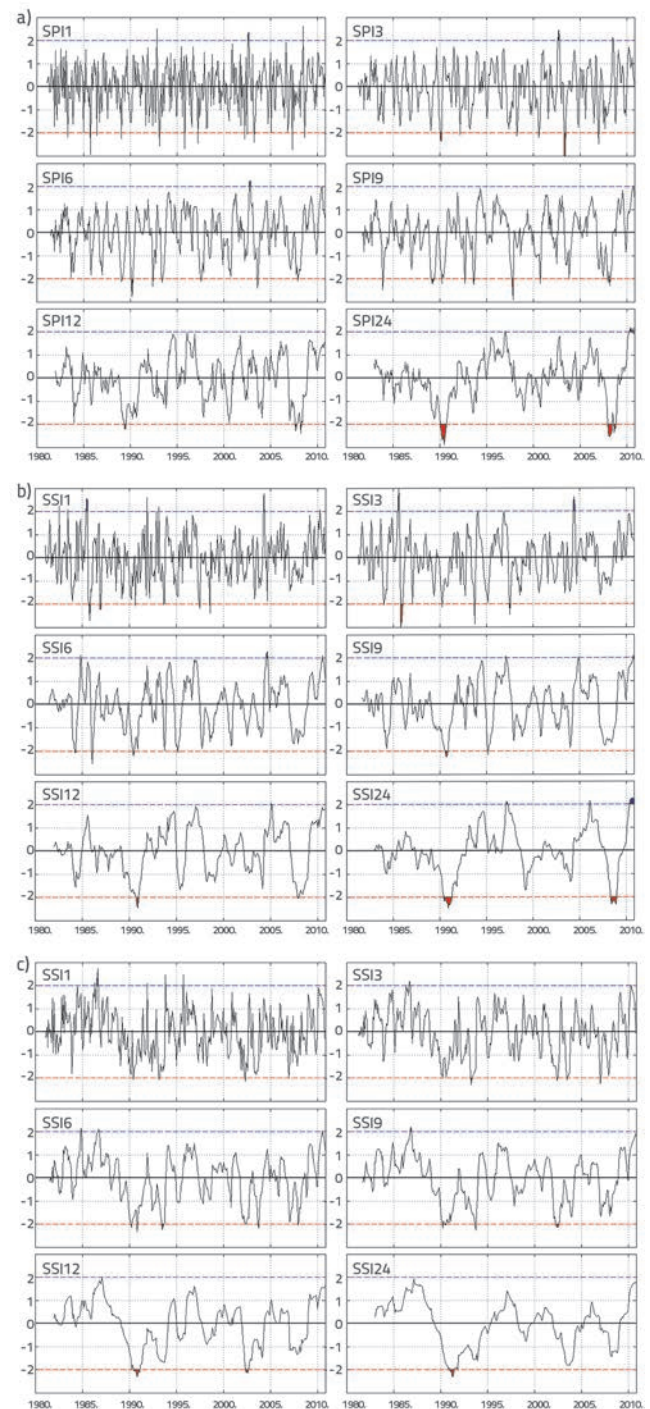
SPI	Kategorija
≥ 2	vrlo vlažan
1,5 do 1,99	vlažan
1,0 do 1,49	umjereno vlažan
-0,99 do 0,99	normalan
-1,0 do -1,49	umjereno suh
-1,5 do -1,99	suh
≤ -2	vrlo suh

4. Rezultati

Rezultati trenda pokazuju slab, statistički neznačajan porast godišnjih količina oborine (0,29 mm/10 god) kao i protoka na postaji Han (0,13 m³s⁻¹/10 god) te slabo smanjenje protoka postaje Grab (-0,014 m³s⁻¹/10 god) u promatranom 30-godišnjem razdoblju (slika 2.).

Na slici 3.a prikazan je vremenski niz SPI vrijednosti, a slike 3.b i 3.c prikazuju nizove SSI na vremenskim skalama od 1 do 24 mjeseca. Minimalne vrijednosti SPI i SSI za različite vremenske skale prikazane su u tablici 3., s odgovarajućim količinama oborine (R) i pripadajućim protocima (Q). Rezultati pokazuju da postoje različita sušna razdoblja, po intenzitetu i trajanju u okviru promatranog 30-godišnjeg razdoblja. Ekstremne vrijednosti SPI pojavile su se 1985., 1990., 1997., 2003. i 2008. za odabrane vremenske skale. Najdulja sušna razdoblja uglavnom su zabilježena u zadnjem desetljeću analiziranog razdoblja za vremenske skale do 12 mjeseci. Međutim, za vremensku skalu od 24 mjeseca, najdulje sušno razdoblje započelo je u veljači 1989., a trajalo je 34 mjeseca (tablica 3.). Dakle, za kraće vremenske skale učestalost suše je veća u usporedbi s većim skalama, ali s manjim intenzitetom. S druge pak strane, na duljim vremenskim skalama (9, 12 i 24 mjeseci), suša je rjeđa, ali ima dulje trajanje i veće magnitude. Suprotno obilježjima oborine, protoci (SSI - Han) pokazuju najsušnije razdoblje u 1980.-im, uključujući 1990., kada pripadajući indeksi imaju minimalne vrijednosti za više vremenskih skala (tablica 3.). To može biti posljedica režima rada HE Peruča, odnosno ispuštanja protoka manjih od propisanog biološkog minimuma (3,5 m³/s) u prethodnim godinama. Današnji hidrološki uvjeti u koritu rijeke Cetine povoljniji su jer su uređeni i kontrolirani odnosi elektroprivrede i vodnoga gospodarstva. Zadnji registrirani protok manji od biološkog minimuma na postaji Han bio je 2003. Vrijednosti SSI-Grab bile su najmanje 1990., 1991. i 2002. godine. Najdulja sušna razdoblja zabilježena su 1989., 1992., 2002. i 2003. Slično kao meteorološka suša,

hidrološka suša je dulja i jača za veće vremenske skale (24 mjeseci), iako se javlja rjeđe. Na kraćim vremenskim skalama hidrološka suša ima kraće trajanje, niži intenzitet, a pojavljuje se češće.



Slika 3. Vremenski nizovi za razdoblje 1981.-2010.: a) SPI; b) SSI-Han; c) SSI-Grab (crvena i plava isprekidana linija pokazuje ekstremno niske i visoke vrijednosti pojedinog indeksa za vremenske skale 1, 3, 6, 9, 12 i 24 mjeseca)

Tablica 3. Minimalne vrijednosti SPI, SSI-Han i SSI-Grab za različite vremenske skale uz pripadajuće količine oborine i protoke

Vremenska skala	1	3	6	9	12	24
SPI						
Godina	1985.	2003.	1990.	1997.	2008.	1990.
Mjesec	rujan	svibanj	veljača	listopad	ožujak	lipanj
SPI	-2,9	-3,1	-2,8	-2,9	-2,4	-2,9
R [mm]	0,7	84,4	272,5	427	737	1739,7
Dmax	4	11	12	20	24	34
Godina	2000.	2007.	1999.	2006.	2006.	1989.
Mjesec	lipanj	lipanj	studenj	studenj	listopad	veljača
M	3,7	10,2	11,6	27,5	34,1	47,5
SSI-Han						
Godina	1985.	1985.	1986.	1990.	1990.	1990.
Mjesec	listopad	prosinac	siječanj	rujan	studenj	studenj
SSI	-2,7	-3,0	-2,5	-2,3	-2,5	-2,5
Q [m ³ /s]	5,6	31,5	104,4	226,0	313,5	769,0
Dmax	7	19	21	24	27	32
Godina	1983.	2007.	1997., 2007.	1989.	1989.	1990.
Mjesec	listopad	siječanj	kolovoz, ožujak	lipanj	svibanj	siječanj
M	8,6	18,5	17,9	31,1	37,0	47,1
SSI-Grab						
Godina	2002.	1993.	1990.	1993.	1990.	1991.
Mjesec	travanj	ožujak	listopad	rujan	listopad	ožujak
SSI	-2,1	-2,3	-2,3	-2,3	-2,3	-2,3
Q [m ³ /s]	1,8	3,7	5,7	11,0	20,1	51,7
Dmax	10	29	32	28	50	62
Godina	2001.	1989.	1992.	2001.	2002.	2002.
Mjesec	listopad	siječanj	svibanj	prosinac	ožujak	prosinac
M	14,0	29,7	37,0	33,6	42,0	41,5

Dmax označava maksimalno trajanje sušnog razdoblja (u mjesecima) i njegov početak s pripadajućom magnitudom (M), za različite vremenske skale (1, 3, 6, 9, 12 i 24 mjeseca)

S agronomskog stajališta, SPI6 i SSI6 za rujun su vrlo važni, jer oni u cijelosti obuhvaćaju vegetacijsko razdoblje. Tablica 4 daje 20 % najnižih vrijednosti SPI6 i SSI6 izračunanih za rujun. Prema SPI vrijednostima, ekstremno sušne meteorološke prilike nisu zabilježene u Sinjskom polju u analiziranom razdoblju, ali je bilo nekoliko vrlo suhih razdoblja (1985., 1990., 1992., 1997., 2000., 2003. i 2007.). Međutim, indeksi protoka u Grabu pokazuju izrazito suho vegetacijsko razdoblje u 2003., kada je SSI6 za rujun bio manji od -2. Vrlo suha 6-mjesečna razdoblja u Grabu i Hanu zabilježena su uglavnom u 1990-ima, kao i na početku 2000-ih.

Slika 4.a prikazuje Pearsonov koeficijent korelacije između SPI i SSI-Han kontinuiranog niza (lijevo) i za svaki mjesec (desno). Koeficijent korelacije u kontinuiranom nizu ima pozitivne vrijednosti i povećava se s povećanjem vremenske skale. Na najkraćoj skali (SPI1 vs SSI1) korelacija je najslabija, a koeficijent je 0,22, dok na vremenskoj skali

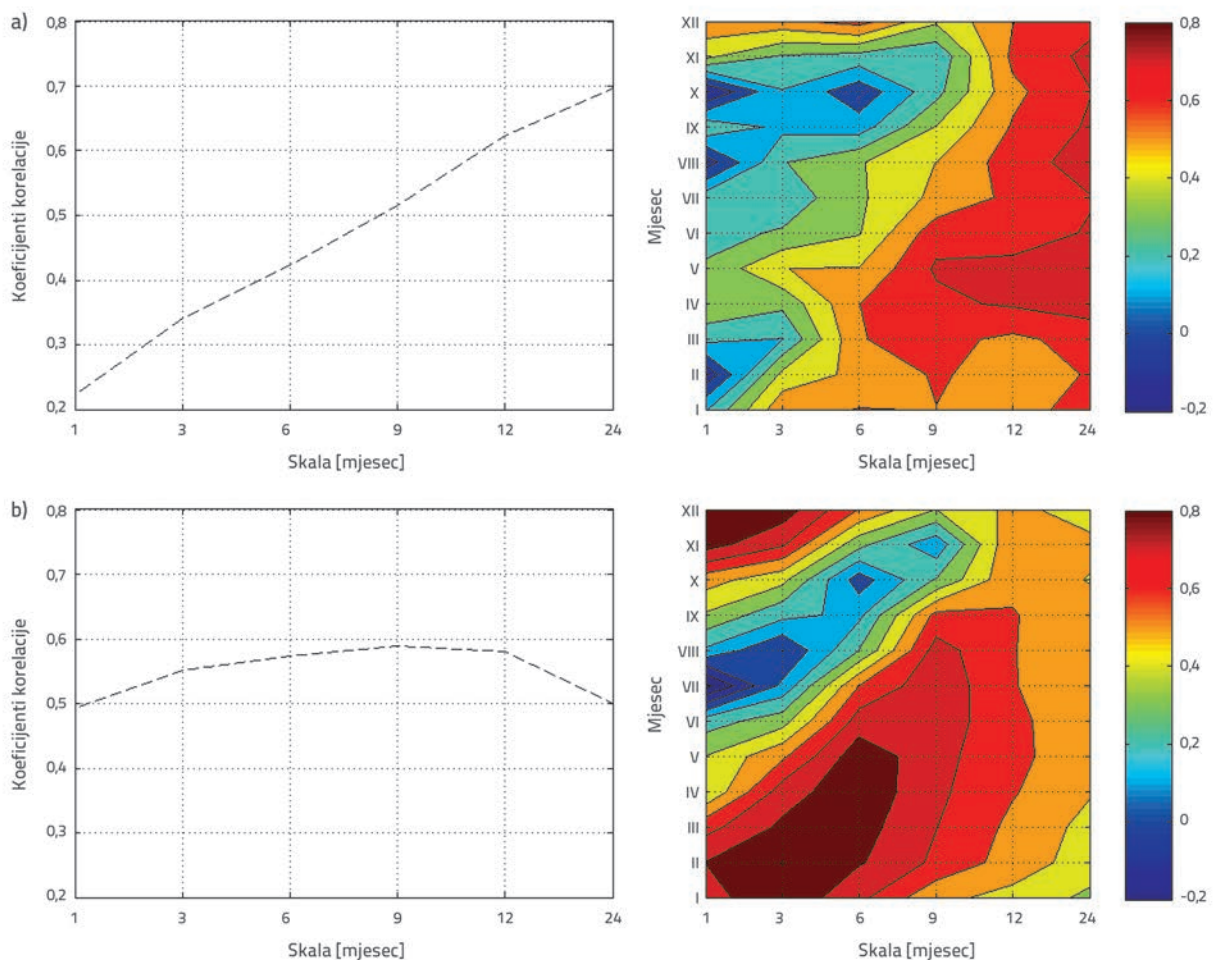
od 24 mjeseca koeficijent korelacije između navedenih indeksa ima maksimalnu vrijednost od 0,7 (SPI24 vs SSI24). Dakle, veza između protoka i količine oborine je jača za veće vremenske skale. Budući da je indeks protoka Cetine slabo povezan s indeksom oborine na kraćim vremenskim skalama, SPI se ne može primijeniti za analizu hidrološke suše ovog vodotoka. To se može objasniti činjenicom da se protok u Hanu može podijeliti u dvije komponente: prirodnu i umjetnu. Prirodni dio protoka proizlazi iz oborina sa sliva između Hana i Peruče. Umjetna komponenta protoka predstavlja ispuštanja iz HE Peruča, koju kontrolira čovjek. Na temelju analize korelacije možemo zaključiti da prirodno otjecanje ima značajnu ulogu samo na većim vremenskim skalama kada je korelacija između oborina i protoka značajna. S druge pak strane, protok u Hanu na kraćim skalama uglavnom ovisi o ljudskom faktoru (HE) i gotovo da ne postoji veza, ili je vrlo slaba, s kišnim režimom.

Tablica 4. Minimalne vrijednosti SPI6, SSI6-Han i SSI6-Grab za rujan (vegetacijsko razdoblje) i pripadajuća godina

R. br.	Godina	SPI6	R. br.	Godina	SSI6-Han	R. br.	Godina	SSI6-Grab
1.	2000.	-1,91	1.	1993.	-1,95	1.	2003.	-2,18
2.	2007.	-1,82	2.	1997.	-1,89	2.	1993.	-1,94
3.	1985.	-1,42	3.	1998.	-1,43	3.	1990.	-1,41
4.	1992.	-1,34	4.	1990.	-1,36	4.	1992.	-1,11
5.	1997.	-1,3	5.	2000.	-1,17	5.	1997.	-0,98
6.	2003.	-1,05	6.	2003.	-1,11	6.	2002.	-0,88

Prema odnosu SSI-Han i SPI mjesečno za svaku vremensku skalu, uočava se korelacija koja je proporcionalna vremenskoj skali (slika 4.a, desno). Minimalna vrijednost korelacije uvrđena je za najkraću vremensku skalu od mjesec dana, pri čemu je samo u studenom i prosincu korelacija statistički značajna (prema t-testu za 95-postotnu razinu povjerenja). Za tromjesečnu skalu, odnos između oborina i protoka je izraženiji u siječnju, veljači, svibnju i prosincu nego u drugim mjesecima. Za šestomjesečnu skalu veza je značajna u svim sezonama osim u jesen (od rujna do studenog); dok za devet mjeseci r-vrijednost nije značajna samo

u listopadu i studenom. Za veće vremenske skale (12 mjeseci), korelacija između protoka i oborina je statistički značajna u svim mjesecima s pripadajućim vrijednostima r većim od 0,5. U ovom slučaju ne može se uočiti sezonska povezanost između oborina i protoka, a odnos ovisi isključivo o veličini vremenske skale. Sličan prikaz korelacije između SPI i SSI-Grab dan je na slici 4.b. Koeficijenti korelacije za kontinuirane nizove imaju vrlo slične r-vrijednosti za sve vremenske skale, u rasponu između 0,5 i 0,6. Na mjesečnoj razini, općenito, najjača korelacija ($r > 0.7$) količine oborine (SPI) i protoka (SSI-Grab) zabilježena je u



Slika 4. Koeficijenti korelacije između SPI i a) SSI-Han; b) SSI-Grab za kontinuirani niz (lijevo) i za svaki mjesec (desno), za različite vremenske skale (u mjesecima)

najhladnijim mjesecima (studeni-veljača) za vremenske skale od 1 i 3 mjeseca, ali i kod proljetnih mjeseci (travanj i svibanj) na šestomjesečnoj skali. Plava zona koja je iscrtana na slici 4.b predstavlja neznačajne vrijednosti korelacije.

5. Rasprava

Vicente-Serrano i Lopez-Moreno [16] pokazali su da kontinuirani niz na rijeci Aragon (1950.-2000.) imaju značajnu korelaciju između SPI i protoka za vremenske skale do 3 mjeseca ($r > 0,5$), nakon čega se korelacija smanjuje. Maksimalno se pojavljuje na skali od 2 mjeseca s koeficijentom korelacije $r = 0,63$. U njihovom radu, korelacija između razine vode i SPI je značajna za skale od 7 do 10 mjeseci ($r > 0,5$), dok se za druge vremenske skale korelacija smanjuje. Oni tvrde da SPI nije pogodan za određivanje hidrološke suše na duljim vremenskim skalama (> 12 mjeseci). Valja napomenuti da hidrološki parametar, razina vode u akumulaciji, ima također djelomično umjetni karakter. Njegova vrijednost ovisi o dotoku s uzvodnog sliva, ali i o ispuštanju vode iz akumulacije, tj. zahvaćanju vode za vodoopskrbu i poljoprivredu. Rezultati analize korelacije u Sinjskom polju i postaje Han su u suprotnosti s ovim rezultatima za rijeku Aragon, jer pokazuju kontinuirani porast koeficijenta korelacije. Razlog za takav atipični rezultat vjerojatno bi mogla biti činjenica da je protok na ovom mjestu pod neposrednim i jakim utjecajem uzvodne hidroelektrane. S druge strane, najveći koeficijent korelacije za postaju Grab nalazi se na vremenskoj skali od devet mjeseci ($r = 0,56$), s nižim vrijednostima za kraće i dulje skale. Takav oblik krivulje podudara se s rezultatima za rijeku Aragon gdje odnos *SPI - razina vode* ima maksimum za osam mjeseci, dok odnos *SPI - protok* ima maksimum na dvomjesečnoj skali.

Nadalje, mjesečni nizovi rijeke Aragon [16] imaju vrlo sezonski karakter. Tako je najznačajnija korelacija ($r > 0,7$) *SPI - protok* utvrđena u hladnoj sezoni (jesen i zima) na kraćim vremenskim skalama (do 6 mjeseci). Razina vode ima najznačajniju korelaciju u kasnu jesen i zimu za vremenske skale od 4 do 10 mjeseci. U Sinjskom polju, rijeka Cetina (postaja Han) nema sezonsku povezanost između hidrološkog indeksa i oborina, ali njihov je odnos slabiji za kraće i jači za dulje vremenske skale. Vodotok Grab ima najjaču korelaciju ($r > 0,7$) u zimskim i proljetnim mjesecima za kraće vremenske skale (od 1 do 6).

Rimkus i sur. [18] ističu da se standardizirani indeks oborine ne može uspješno primijeniti za identifikaciju hidroloških ljetnih suša u područjima gdje topljenje snijega čini velik udio godišnjeg toka. Također, Medved-Cvikl i sur. [17] navode da učinak podzemnog zadržavanja vode kao i obilježja reljefa regije također utječu na povezanost između indeksa oborine i protoka na svim postajama njihovog istraživanja. Zbog toga, koeficijenti otjecanja razmatranih vodotoka znatno se razlikuju među pojedinim slovenskim regijama.

Očito je da gotovo svaki sustav, npr. hidrološki sliv, krško polje, itd., ima svoje specifičnosti koje proizlaze iz njegove fizičke strukture (geologija, topografija, tlo, vegetacija),

klimatskih uvjeta (kišni režim, snijeg, isparavanje) i upravljanja hidrotehničkim građevinama (branama) i zato ga čini gotovo jedinstvenim sustavom koji se treba zasebno proučavati i analizirati. U svakom slučaju, iskustva s nekih drugih mjesta korisna su kad se analizira pojava suše. Analiza korelacija provedena u ovom radu ističe razliku između sliva s kontroliranim upravljanjem vodnog režima (Cetine) i sliva s prirodnim režimom (Grab). Ostali parametri kao što su veličina sliva, geologija i sl. također utječu na vodni režim. Treba istaknuti da se razmatrano područje nalazi u dinarskom kršu, koje karakteriziraju vrlo složeni hidrološki i hidrogeološki odnosi. Dakle, hidrološki procesi, kao i meteorološki i hidrološki odnosi zahtijevaju opsežno istraživanje. Osim toga, ovaj rad otvara potrebu za sustavnom analizom SSI procjene primjenom različitih teorijskih razdioba, što je u planu za buduće istraživanje.

6. Zaključak

U ovom radu prikazana je primjena standardiziranog indeksa oborine (SPI) za određivanje meteorološke suše. Isti koncept primijenjen je na hidrološke podatke (protok), tako da je određen standardizirani indeks protoka (SSI). Za analizu je korišten niz mjesečnih količina oborine (Sinj) i protoka (Han i Grab) iz razdoblja 1981. - 2010.

Ekstremne meteorološke suše pojavljuju se svakih 5-6 godina na razmatranom području. Najnepovoljniji hidrološki uvjeti na rijeci Cetini (Han) zabilježeni su 1980-ih, uključujući 1990. godinu. Budući da je protok Cetine pod izravnim utjecajem HE Peruča, vjerujemo da minimalni indeksi suše odgovaraju razdoblju kada nisu u dovoljnoj mjeri uzeti u obzir vodopravni uvjeti. Dakle, minimalni propisan protok na hidroelektrani danas se više uzima u obzir, što je korisno za ublažavanje hidrološke suše. S druge strane, prirodni vodotok Grab bilježi minimalni indeks suše u 1990., 1991. i 2002.

Što se tiče meteorološkog i hidrološkog deficita koji ima velik utjecaj na poljoprivredu, može se reći da je posebno nepovoljan svake treće ili četvrte godine. Postoji značajna korelacija između meteorološkog i hidrološkog deficita na većim vremenskim skalama kod rijeke Cetine (Han) (12-48 mjeseci), što nije prikladno za identifikaciju suše. S druge strane, Grab bilježi zimsko-proljetnu povezanost meteoroloških i hidroloških pokazatelja na kraćim skalama (do 6 mjeseci). Osim toga, ljetni indeks protoka kod Graba ima najjaču povezanost s oborinama za devetomjesečnu skalu. To znači da ljetni protok uvelike ovisi o oborinama u zimsko-proljetnom razdoblju. Dakle, SSI (Grab) može poslužiti za identifikaciju suše u tom području, osobito za prirodni režim.

Nekoliko autora istaknulo je u svojim radovima važnost proučavanja suše na različitim vremenskim i prostornim skalama [16, 17, 19]. Također, neki su od njih [17, 19] istaknuli da prirodni čimbenici kao što su geološka struktura, režim oborina itd. imaju važan utjecaj na interakciju meteoroloških i hidroloških parametara. Ovdje je dodan još jedan faktor,

antropogeni, koji se očituje kroz hidroenergetsko korištenje vode i opskrbu vodom, što također može imati vrlo jak utjecaj na meteorološko - hidrološke odnose. To upućuje na mogućnost da se upravljanje vodama može uspješno primijeniti za ublažavanje suše u kontroliranim slivovima kao što je sliv Cetine. Bilo bi vrlo korisno ispuštanje adekvatne količine vode iz hidroelektrana osobito u vegetacijskom razdoblju, bez oborina, kada su prirodni vodotoci slabi ili suhi.

Na kraju, treba istaknuti da je ova analiza prvi korak u proučavanju suše u Sinjskom polju i da sigurno ostaju brojne mogućnosti za daljnje istraživanje meteoroloških i hidroloških obilježja. Posebno bi bilo korisno sustavno i detaljno istražiti prilagodbu teorijskih razdioba za izračun SSI vrijednosti, jer u Hrvatskoj nedostaje takvo istraživanje i primjena SSI. Bilo bi

korisno provesti adekvatno praćenje suše u Sinjskom polju radi procjene podzemnih voda i vlage u tlu koji su ključni za uvjete razvoja poljoprivrede. Uloga i značenje ovog krškog područja u poljoprivredi te u socijalnom i ekonomskom napretku važni su ne samo za grad Sinj već i za cijelu regiju. Nastojanja, rezultati i ideje iz ovog rada su ohrabrujući za nastavak istraživanja i pružanja informacija koje bi mogle biti korisne za gospodarenje tlom i vodama Sinjskog polja.

Zahvala

Zahvaljujemo dvojici anonimnih recenzenata za njihov detaljan pregled i konstruktivne prijedloge. Ovaj rad je sufinancirala Hrvatska zaklada za znanost projektom 2831 (CARE).

LITERATURA

- [1] WMO: *Drought monitoring and early warning: concept, progress and future challenges*, WMO No. 1006, 2006.
- [2] Ramsey, S., Subbia, A.R., Bass, S., Juergens I.: *Livelihood adaption to climate variability and change in drought-prone areas of Bangladesh*, Asian Disaster Preparedness Center, FAO, 2007.
- [3] Alam, J.A.T.M., Rahman, S.M., Saadat, A.H.M.: Monitoring meteorological and agricultural drought dynamics in Barind region Bangladesh using SPI and Markov chain model, *International Journal of Geomatics and Geoscience*, 3 (2013) 3, pp. 511-524.
- [4] Jayanthi, H., Husak, G.: *A probabilistic approach to assess agricultural drought risk*, UNISDR, Geneva, 2013.
- [5] Hayes, M., Wilhite, D.A., Svoboda, M., Vanyarkho, O.: Monitoring the 1996 drought using the standardized precipitation index, *Bulletin of the American Meteorological Society*, 80 (1999), pp. 429-438, [http://dx.doi.org/10.1175/1520-0477\(1999\)080<0429:MTDUTS>2.0.CO;2](http://dx.doi.org/10.1175/1520-0477(1999)080<0429:MTDUTS>2.0.CO;2)
- [6] Lana, X., Serra, C., Burgueno, A.: Patterns of monthly rainfall shortage and excess in terms of the standardized precipitation index for Catalonia (NE Spain), *International Journal of Climatology*, 21 (2001), pp. 1669-1691, <http://dx.doi.org/10.1002/joc.697>
- [7] Sonmez, F.K., Komuscu, A.U., Erkan, A., Tzrgu, E.: An Analysis of Spatial and Temporal Dimension of Drought Vulnerability in Turkey using the Standardized Precipitation Index, *Natural Hazards*, 35 (2005) 2, pp. 243-264.
- [8] Vicente-Serrano, S.M.: Spatial and temporal analysis of droughts in the Iberian Peninsula (1910-2000), *Hydrological Science Journal*, 52 (2006) 1, pp. 83-97.
- [9] Mihajlović, D.: Monitoring the 2003-2004 meteorological drought over Pannonian part of Croatia", *International Journal of Climatology*, 26 (2006) 15, pp. 2213-2225.
- [10] Livada, I., Assimakopoulos, V.D.: Spatial and temporal analysis of drought in Greece using the Standardized Precipitation Index (SPI), *Theoretical and Applied Climatology*, 89 (2007), pp. 143-153, <http://dx.doi.org/10.1007/s00704-005-0227-z>
- [11] Santos, J.F., Portela, M.M., Pulido-Calvo, I.: Regional Frequency Analysis of Droughts in Portugal, *Water Resources Management*, 25 (2011), pp. 3537-3558, <http://dx.doi.org/10.1007/s11269-011-9869-z>
- [12] Capra, A., Scicolone, B.: Spatiotemporal variability of drought on a short-medium time scale in the Calabria Region (Southern Italy), *Theoretical and Applied Climatology*, 110 (2012) 3, pp. 471-488.
- [13] Dash, B.K., Rafiuddin, M., Khanam, F., Islam, M.N.: Characteristics of meteorological drought in Bangladesh, *Natural Hazards*, 64 (2012), pp. 1461-1474, <http://dx.doi.org/10.1007/s11069-012-0307-1>
- [14] Zhang, Q., Li, J., Singh, U.P., Bai, Y.: SPI-based evaluation of drought events in Xinjiang, China, *Natural Hazards*, 64 (2012) 1, pp. 481-492.
- [15] Morán-Tejeda, E., Ceglar, A., Medved-Cvikl, B., Vicente-Serrano, S.M., López-Moreno, J.I., González-Hidalgo, J.C., Revuelto, J., Lorenzo-Lacruz, J., Camarero, J., Pasho, E.: Assessing the capability of multi-scale drought datasets to quantify drought severity and to identify drought impacts: an example in the Ebro Basin, *International Journal of Climatology*, 33 (2013) 8, pp. 1884-1897.
- [16] Vicente-Serrano, S.M., Lopez-Moreno, J.I.: Hydrological response to different time scales of climatological drought: an evaluation of the Standardized Precipitation Index in a mountainous Mediterranean basin, *Hydrological Earth System Science*, 9 (2005), pp. 523-533, <http://dx.doi.org/10.5194/hess-9-523-2005>
- [17] Medved-Cvikl, B., Ceglar, A., Kajfež-Bogataj, I.: The response of hydrological droughts to climatic droughts at different time scales in Dravinja, Savinja and Krka Basins in Slovenia, *International Conference BALWOIS, Ohrid, Macedonia*, pp. 1-12, 2012.
- [18] Rimkus, E., Stonevičius, E., Korneev, V., Kažys, J., Valiuškevičius, G., Pakhomau, A.: Dynamics of meteorological and hydrological droughts in the Neman river basin, *Environmental Research Letter*, 8 (2013), pp. 1-10, <http://dx.doi.org/10.1088/1748-9326/8/4/045014>
- [19] Haslinger, K., Koffler, D., Schoner, W., Laaha, G.: Exploring the link between drought and streamflow: Effects of climate-catchment interaction, *Water Resources Research*, 50 (2014), pp. 1-20, <http://dx.doi.org/10.1002/2013WR015051>
- [20] Wilks, D.S.: *Statistical Methods in the Atmospheric Sciences*, Elsevier Inc, Oxford, 2011.
- [21] McKee, T.B., Doeksen, N.J., Kleist, J.: The relationship of drought frequency and duration on time scales, *8th Conference of Applied Climatology, American Meteorological Society*, Boston MA, pp. 179-184, 1993.
- [22] Gilbert, R.O.: *Statistical methods for environmental pollution monitoring*, John Wiley & Sons, Inc., New York, 1987.