

# PRIJEDLOG NOVE METODE ZA ANALIZU SUŠA

**dr. sc. Ognjen Bonacci, prof. emerit.**

Sveučilište u Splitu  
Fakultet građevinarstva,  
arhitekture i geodezije  
Matice hrvatske 15, Split, Hrvatska,  
obonacci@gradst.hr

**mr. sc. Duje Bonacci, dipl. ing. fiz.**

Sveučilište u Zagrebu  
Fakultet hrvatskih studija  
Borongajska cesta 83d, Zagreb, Hrvatska

Ključan čimbenik pojave i intenziteta suše u svakom okolišu je manja količina oborina od prosječne. Uz to, na fenomen suše snažan utjecaj vrši i temperatura zraka. Što je ona viša od prosječne vrijednosti u određenom dijelu godine, to su i negativne posljedice suše teže. U doba recentne globalne promjene klime koja se najizrazitije manifestira upravo porastom temperature zraka, taj je ključni klimatološki parametar neophodno uvesti u proračun indeksa suše. Uvođenjem tog parametra uz parametar oborine, moguće je definirati integralni indeks suše primjenjiv za analizu bilo koje vrste suše. U članku je prikazana nova metoda analize suše u kojoj se koriste standardizirane vrijednosti oborine i srednje temperature zraka u određenom razdoblju. Standardizirana vrijednost izračunava se tako da se od svake pojedine izmjerene vrijednosti oborine i temperature u nekom vremenskom intervalu (mjесец, sezona, godina, itd.) odbije njena prosječna vrijednost u razmatranom razdoblju te se ta veličina podijeli sa standardnom devijacijom u tom intervalu. Novi Indeks Suše (NIS) izračuna se tako da se od standardizirane vrijednosti oborine odbije standardizirana vrijednost temperature. Vrijednosti NIS-a analizirane su za nizove mjesecnih i godišnjih količina oborine i srednje mjesecne i srednje godišnje temperature zraka izmjerениh na postajama Split-Marjan i Zagreb-Grič u razdoblju 1948. - 2020. Izračunate vrijednosti NIS-ova ukazuju na to da se opasnost od suše značajno intenzivira u posljednjim desetljećima, što se može povezati s učinkom aktualnog globalnog zagrijavanja. Na razini mjeseci, sušom su najugroženiji oni u toplom dijelu godine, od travnja do kolovoza u Zagrebu te od lipnja do kolovoza u Splitu.

**Ključne riječi:** suša, temperatura zraka, Novi Indeks Suše (NIS), Mann-Kendall test, Split-Marjan, Zagreb-Grič

## 1. UVOD

Suša je fenomen koji može uzrokovati katastrofalne posljedice. U svrhu njene analize, razvijeni su brojni koncepti i metode koje koriste različite parametre za potrebe njenog izučavanja, identificiranja i kvantificiranja. Suša se različito tretira s različitim stanovišta (hidrološkog, meteorološkog, agronomskog, društveno-političkog itd.). Različiti pristupi daju vrlo

često i različite rezultate i navode na različite zaključke, što unosi zabunu i otežava borbu protiv ove sve prisutnije nepogode. Potrebe za poduzimanjem učinkovitih i pravovremenih akcija s ciljem ublažavanje posljedica suše sve su aktualnije. U sadašnjem vremenu ove su potrebe potencirane globalnim klimatskim promjenama. Na trajanje i intenzitet suše osobito snažan utjecaj vrši

porast temperatura (npr. Dai, 2011.). Koristeći *Standard Weighted Average Precipitation Index* Zhao i sur. (2020.) su ukazali na mogućnost da će, zbog klimatskih promjena tijekom 21. stoljeća, doći do češćih naglih izmjena suša i poplava.

Suša predstavlja kompleksan fenomen uzrokovani različitim čimbenicima (npr. Van Loon, 2015.). Brojni, prije svih hidrološki i klimatološki, ali i neki drugi parametri, karakteriziraju sušu, ali se za njeno definiranje i kvantificiranje najčešće koriste informacije o oborinama i protocima otvorenih vodotoka, razinama podzemnih voda i vlage u tlu. Bez dvojbe, na pojavu i svojstva suše bitno utječu manjak oborine i više temperature zraka u odnosu na prosječne vrijednosti u analiziranom razdoblju na promatranoj prostoru.

Literatura u kojoj se tretira problematika suše vrlo je obimna (npr. Palmer, 1965.; Bonacci, 1993.; Hisdal, 2002.; Morid i sur., 2006.; Mishra i Singh, 2010.; Van Lanen i sur. 2013.; Tadić i sur., 2015.; Barker i sur., 2016.; Pandžić i sur., 2020.; Ferina i sur. 2021.; Li i sur., 2021. itd.). Zbog kompleksnosti fenomena suše neophodno je koristiti objektivne i jasne pristupe njenom definiranju. Suša se u literaturi pokušava prikazati brojnim indeksima suše (*drought index*), koji se razlikuju u postupcima definiranja i podacima potrebnim za njihovo računanje. I pored brojnih nastojanja do danas nije ustanovljen jedan univerzalni indeks suše. U literaturi se koristi i pojam indeksa suhoće (*aridity index*) koji predstavlja odnos između srednje godišnje potencijalne evapotranspiracije i oborina, koji kontrolira srednje godišnje doteke površinskih i podzemnih voda na nekom prostoru (Neto i sur., 2020.).

Potreba da se karakteristike suše kvantitativno izraze rezultirala je formiranjem brojnih indeksa suše koji na vrlo različite načine procjenjuju ovaj fenomen. Od karakteristika suše najčešće se definiraju: (1) trajanje (T); (2) jakost ili kumulativni deficit (S); (3) intenzitet deficit-a (S/T). Jakost ili kumulativni deficit predstavlja sumu svih pojedinih deficit-a svih jedinica vremena tijekom trajanja i koraka suše. Intenzitet deficit-a predstavlja omjer jakosti i trajanja suše. Osim toga važno je definirati i vrijeme početka suše dok je vrijeme kraja obično lakše odrediti. Ono uglavnom nastupa kad se na analiziranom prostoru pojave obilne oborine. Lloyd-Hughes (2014.) smatra da je za njezinu kvantifikaciju i detaljniji opis neophodno uvesti i reference koje se odnose na potrebe za vodom i upravljanje vodnim resursima u analiziranom prostoru. Isti je autor naveo da je u literaturi moguće naići na više od sto indeksa suše što ukazuje na njenu kompleksnost, ali i na poteškoće pri definiranju opće prihvatljivog i pouzdanog pokazatelja. Činjenica da su brojni od parametara na osnovi kojih se proračunavaju indeksi suše međusobno visoko korelirani njihovim uvrštavanjem u definiranje indeksa, ne donosi nikakve pomake. Pri određivanju hidrološke suše treba uzeti u obzir činjenicu nelinearног odgovora kopnenih procesa na klimatske impulse (Van Lanen i sur., 2013.; Van Loon, 2015.).

Opće prihvaćena definicija suše glasi: „Suša predstavlja deficit vode u odnosu na normalne (prosječne) uvjete koji vladaju u nekom području“ (Lloyd-Hughes, 2014.). Zanimljivo je mišljenje o suši koje su iznijeli Panu i Sharma (2002.): „Suša se percipira kao ekstremni klimatski događaj, dok bi je u stvarnosti trebalo prepoznati kao normalnu pojavu“. AghaKouchak i sur. (2021.) smatraju da tradicionalno prihvaćena definicija suše kao deficita s vodom vezanih varijabli i/ili aktivnosti (npr. oborine, vlage u tlu, rezervi površinskih i podzemnih voda, vode za navodnjavanje itd.) uzrokovanih prirodnom varijabilnošću nije dobra jer ne uzima u obzir lokalne čimbenike. Zbog toga autori tog rada smatraju da unutar spregnutog sustava čovjek-voda, suša mora biti drugačije definirana i shvaćena. Za ispunjavanje tog cilja potrebno je uzeti u obzir kompleksnu međusobno povezanu dinamiku prirodnih pojava i ljudskim djelatnostima unesenih promjena. Tzv. antropogenu sušu treba shvatiti kao fenomen koji spaja više dimenzija na različitim vremenskim skalamama. Sušom upravlja kombinacija prirodne varijabilnosti pojave vode, klimatske promjene, ljudske aktivnosti i odluke kao i mikroklimatski uvjeti koji se događaju zbog promjena korištenja zemljišta i procesa upravljanja vodnim resursima. Antropogenu sušu u širem kontekstu treba definirati kao pojavu suše uzrokovane ili intenzivirane ljudskim djelatnostima.

Bez obzira na to što su se dosada provela brojna istraživanja vezana s kvantifikacijom suše (a intenzivno se provode i danas) postoje još brojne nedoumice. Indeks standardizirane oborine (*Standardized Precipitation Index, SPI*), se najčešće koristi u praksi. Brojni ga autori smatraju najpouzdanijim indeksom suše (npr. WMO, 2012.; Tadić i sur. 2015.; Pandžić i sur. 2020. itd.). Zasnovan je na vjerojatnosti pojave oborina tijekom određenog vremenskog perioda. Kreiran je da bude prostorno neovisan indikator suše uvažavajući značaj vremenskih intervala u analizama raspoloživosti vode i korištenja vode (Draginčić i sur., 2017.). Činjenica da SPI isključivo koristi podatke o oborinama donekle ograničava mogućnost njegovog cjelovitog karakteriziranja svojstava raznih vrsta suša. Barker i sur. (2016.) su koristeći *Standardized Streamflow Index* i *Standardized Precipitation Index* ispitivali odnose između hidrološke i meteorološke suše u Velikoj Britaniji.

Palmerov indeks suše je razvijen za potrebe praćenja promjena vodne bilance zemljišta (Palmer, 1965.). U SAD-u se koristi kao standard za izučavanje meteorološke suše. Ovisi o mnogim čimbenicima (npr. Pandžić i sur., 2006.). Zasnovan je na hidrološkoj bilanci kretanja oborinske vode u sustavu tlo – biljka – atmosfera. Osim oborine i temperature zraka za definiranje Palmerovog indeksa potrebni su podaci o količini vlage u tlu, evapotranspiraciji i stopi ispunjenosti vlagom u dva površinska sloja tla koji graniče s atmosferom (gornjem do 20 cm, i donjem do 80 cm). Neki od, u ovoj metodi traženih, podataka rijetko se mijere, te se stoga koriste procjene koje nisu pouzdane. Zaključeno je da ovaj indeks dobro određuje dugotrajne suše trajanja više mjeseci.

U radu će nastavno biti opisan tzv. Novi Indeks Suše (NIS) koji se definira korištenjem podataka oborina i temperature zraka. U kontekstu analize suše, temperatura ima obrnuto proporcionalno djelovanje od oborine. Više oborine od prosječnih i niže temperature od prosječnih povoljnije djeluju na ublažavanje suša i obratno (Ljubenkov i Bonacci, 2011.). Bitno je uočiti da su ova dva klimatološka parametra međusobno neovisna.

## 2. MATERIJALI I METODE

### 2.1. Korišteni klimatološki podaci

U članku su korišteni podaci godišnjih i mjesecnih oborina i srednjih mjesecnih i godišnjih temperatura zraka opaženi na glavnim meteorološkim postajama Državnog Hidrometeorološko Zavoda (DHMZ) Zagreb-Grič (u dalnjem tekstu Zagreb) i Split-Marjan (u dalnjem tekstu Split) u razdoblju od 73 godine, od 1948. do 2020. Podaci su dobiveni od strane DHMZ-a na čemu im se ovim putem zahvaljujemo.

Zračna udaljenost između meteoroloških postaja Zagreb i Split iznosi 259 km. Na lokaciji glavne meteorološke postaje Zagreb, klima je umjereni topla, vlažna s toplim ljetima (npr. Šegota i Filipčić, 2003.). Prema Köppen-Geiger (1936.) klasifikaciji klime ona spada u Cfb klasu. Nadmorska visina postaje je 157 metara (m n.v.), a geografske koordinate postaje su 45° 48' 52" N i 15° 58' 19" E. Na lokaciji glavne meteorološke postaje Split klima je sredozemna s vrućim ljetima (npr. Šegota i Filipčić, 2003.). Prema Köppen-Geiger (1936.) klasifikaciji klime ona spada u Csa klasu. Nadmorska visina postaje iznosi 122 metra (m n.v.), a geografske koordinate postaje su 43° 30' 30" N i 16° 25' 35" E. Obje analizirane postaje nalaze se u gradovima koji se ubrzano razvijaju. Budući da su locirane na vrhovima brežuljaka, nisu izložene snažnoj urbanizaciji (to se osobito odnosi na postaju Split) te je efekt urbanog toplinskog otoka ublažen.

### 2.2. Korištene statističke metode

Za potrebe analize vremenskih nizova korištene su metode linearne i nelinearne regresije i korelacije. Neparametarski F-test i t-test korišteni su za utvrđivanje statističke značajnosti razlika između varijanci i prosječnih vrijednosti uzastopnih podnizova oborina, srednjih temperatura i NIS-ova (McGhee, 1985.).

*Rescaled Adjusted Partial Sums* (RAPS) metoda korištena je za određivanje podrazdoblja sa statistički značajnom razlikom prosječnih vrijednosti u cjelovitim vremenskim nizovima (1948. - 2020.) oborine i temperature (Garbrecht i Fernandez, 1994.; Bonacci i Roje-Bonacci, 2020.). Statistička značajnost razlika utvrđuje se pomoću F-testa i t-testa. Izraz za računanje RAPS-a glasi:

$$\text{RAPS}_k = \sum_{t=1}^k \frac{Y_t - Y_m}{S_y} \quad (1)$$

pri čemu:  $Y_t$  predstavlja oborinu ili srednju temperaturu u određenom vremenskom intervalu,  $t$ ,  $Y_m$ ,

je prosječna vrijednost cijelog analiziranog niza,  $S_y$  je standardna devijacija,  $n$ , broj članova vremenske serije, dok,  $k \in (1, 2, \dots, n)$ , predstavlja brojač zbroja za  $k$ -tu analiziranu vremensku jedinicu u nizu od njih ukupno,  $n$ .

Statistička značajnost linearnih trendova nizova godišnjih i mjesecnih oborina, srednjih temperatura i NIS-ova utvrđivana je primjenom Mann-Kendall (M-K) testa. (Mann, 1945.; Kendall, 1975.; Hamed i Ramachandra, 1998.). Ovaj se test smatra danas najpouzdanijim postupkom za procjenu statističke značajnosti trendova u analiziranim vremenskim serijama. Jedna od njegovih bitnih prednosti je u tome što on ne traži da se analizirani podaci prilagođavaju bilo kojoj krivulji raspodjela, tj. M-K test je neparametarski. Kao takav ima najširu upotrebu i u analizi vremenskih nizova klimatoloških parametara, osobito temperature i oborine (npr. Allen i sur. 2015.; Hori i sur. 2017.; Wang i Stephanson, 2018.). U radu je korišten je *pyMannKendall package for Python*. (Hussain Shourov i Mahmud, 2019.). Nulta hipoteza je da ne postoji monotoni trend u analiziranom vremenskom nizu. Alternativna hipoteza je da trend postoji. U ovom radu kao kriterij za prihvatanje alternativne hipoteze (postojanje statistički značajnog linearog trenda) korištena je vrijednost vjerojatnosti,  $p < 0,05$ .

### 2.3. Novi Indeks Suše (NIS)

Korištenjem mjernih podataka o oborinama i temperaturama zraka u ovom je radu definiran Novi Indeks Suše (NIS). Oba klimatološka parametra koja su korištena za definiranje NIS-a igraju ključnu ulogu u formiranju svih karakteristika suše: trajanja, jakosti deficit, intenziteta deficit te početka i kraja sušnog razdoblja. Kod oborine, na intenziviranje spomenutih karakteristika suše, utječe njihov nedostatak (manjak u odnosu na prosječne vrijednosti u analiziranom razdoblju na analiziranom prostoru). Kod temperature, na intenziviranje suše, utječu vrijednosti temperature više od prosječnih u analiziranom razdoblju i unutar analiziranog područja. Uvođenje temperature uz oborinu, indeks suše dobiva osobito na važnosti u vremenu kada na našem planetu traje proces globalne promjene klime koji se najčešće manifestira u porastu prizemne temperature.

Kako bi se oba klimatska parametra mogla zajednički koristiti u jednom indeksu potrebno ih je transformirati u bezdimenzionalne veličine postupkom standardizacije. Izraz za definiranje NIS-a glasi:

$$NIS_i = [(P_i - P_{p_i})/S_p] - [(T_i - T_{p_i})/S_T] \quad (2)$$

kod čega je:

$P_i$  oborina u godini ili mjesecu, i,

$P_{p_i}$  prosječna vrijednost analiziranog niza oborine u analiziranom razdoblju,

$S_p$  standardna devijacija analiziranog niza oborine u analiziranom razdoblju,

$T_i$  srednja temperatura u godini ili mjesecu, i,

$T_{pr}$ , prosječna vrijednost analiziranog niza srednje temperature u analiziranom razdoblju,

$S_p$ , standardna devijacija analiziranog niza temperature u analiziranom razdoblju.

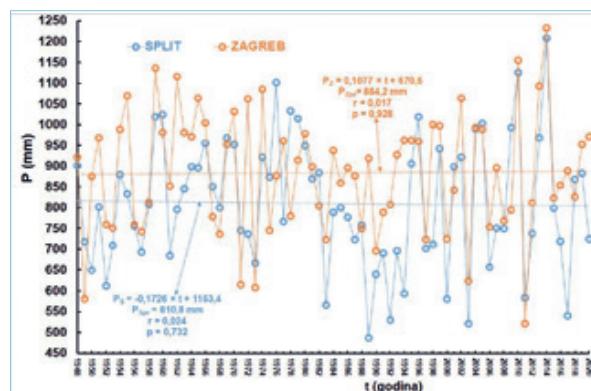
U ovom radu analiziraju se nizovi u razdoblju od 1948. do 2020. godine, dakle ukupno 73 godine ili 876 mjeseci, pri analizi godišnjih vrijednosti,  $i \in (1, 2, \dots, 73)$ , a u slučaju analize cijelog niza mjesecnih vrijednosti od siječnja 1948. do prosinca 2020.,  $i \in (1, 2, \dots, 876)$ .

### 3. REZULTATI I RASPRAVA

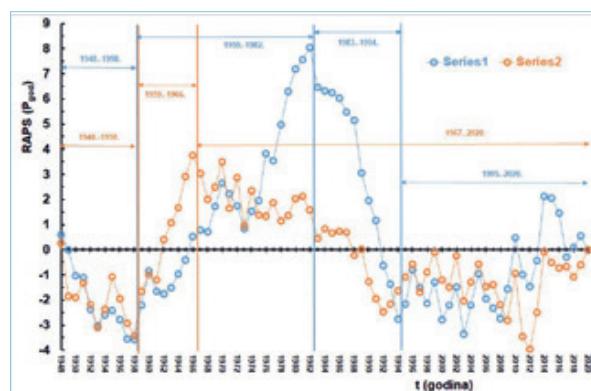
#### 3.1. Analiza godišnjih nizova oborina i temperature

U prvom retku Tablice 1 unesene su vrijednosti prosječnih godišnjih oborina,  $P_{pr}$ , temperatura,  $T_{pr}$ , i standardnih devijacija,  $S$ , Splita i Zagreba u razdoblju 1948. - 2020. U razmatranom razdoblju, prosječne oborine izmjerene u Zagrebu iznosile su 884,2 mm te su bile za 73,4 mm više od onih u Splitu koje su iznosile 810,8 mm. Prosječna godišnja temperatura izmjerena u Splitu iznosila je 16,36 °C i bila je viša za 4,25 °C od one izmjerene u Zagrebu koja je iznosila 12,11 °C.

Na slici 1 prikazani su nizovi godišnje oborine Splita i Zagreba u razdoblju 1948. - 2020. Na slici su ucrtani i pravci linearne regresije, te upisane jednadžbe linearne regresije, vrijednosti koeficijenata linearne korelacije,  $r$ , te vrijednosti vjerojatnoće M-K testa,  $p$ . Na dvije analizirane postaje nije uočen statistički značajan trend u nizu godišnjih oborina. Iako cjeloviti vremenski nizovi oborina na obje postaje ne pokazuju nikakav trend unutar 73 godine, pojavila su se podrazdoblja sa



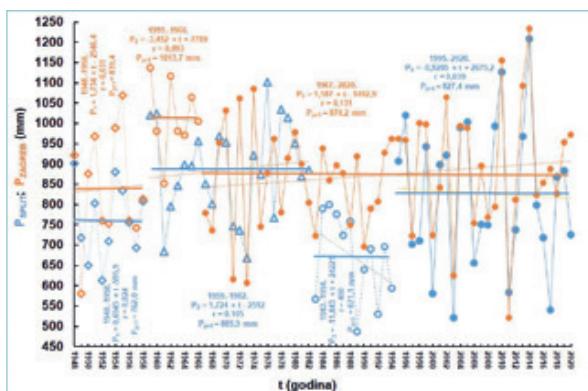
Slika 1: Nizovi godišnjih oborina Splita i Zagreba u razdoblju 1948. - 2020.



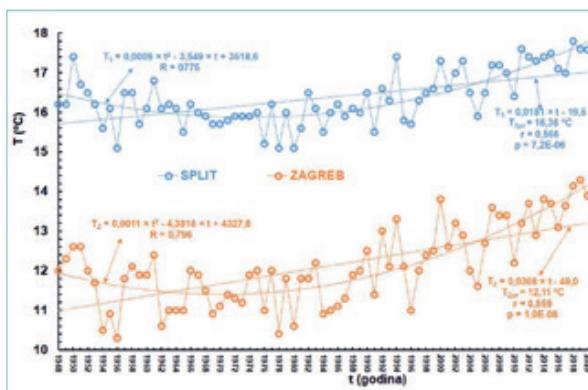
Slika 2: Grafički prikaz RAPS-ova za nizove godišnjih oborina Splita i Zagreba u razdoblju 1948. - 2020.

Tablica 1: Matrica prosječnih godišnjih i mjesecnih oborina,  $P_{pr}$ , temperatura,  $T_{pr}$  i standardnih devijacija,  $S$ , Splita i Zagreba u razdoblju 1948. - 2020.

razdoblje	SPLIT				ZAGREB			
	$P_{pr}$ (mm)	$S$ (mm)	$T_{pr}$ (°C)	$S$ (°C)	$P_{pr}$ (mm)	$S$ (mm)	$T_{pr}$ (°C)	$S$ (°C)
<b>godina</b>	810,8	155,2	16,36	0,678	884,2	144,3	12,11	0,993
<b>siječanj</b>	77,9	45,1	7,95	1,56	52,8	33,5	1,45	2,57
<b>veljača</b>	66,2	40,7	8,40	1,91	47,0	28,4	3,49	3,04
<b>ožujak</b>	63,3	46,1	10,80	1,67	51,7	28,8	7,76	2,33
<b>travanj</b>	62,6	33,0	14,39	1,39	62,7	31,0	12,47	1,68
<b>svibanj</b>	57,3	36,7	19,11	1,51	81,2	37,8	16,08	1,62
<b>lipanj</b>	50,1	35,7	23,24	1,49	96,9	38,0	20,23	1,57
<b>srpanj</b>	27,6	28,0	26,05	1,35	88,3	44,8	22,14	1,54
<b>kolovoz</b>	38,6	40,3	25,78	1,64	85,2	50,4	21,58	1,81
<b>rujan</b>	71,6	53,1	21,55	1,46	90,8	47,9	17,33	1,52
<b>listopad</b>	78,8	50,7	17,13	1,21	77,7	51,4	12,23	1,43
<b>studen</b>	113,4	55,0	12,7	1,39	85,5	48,4	7,03	2,11
<b>prosinac</b>	103,3	66,6	9,32	1,26	64,5	36,1	2,65	2,03



Slika 3: Prikaz četiri podniza oborina Splita i tri podniza oborina Zagreba određenih RAPS metodom na slici 2



Slika 4: Nizovi srednjih godišnjih temperatura Splita i Zagreba u razdoblju 1948. – 2020.

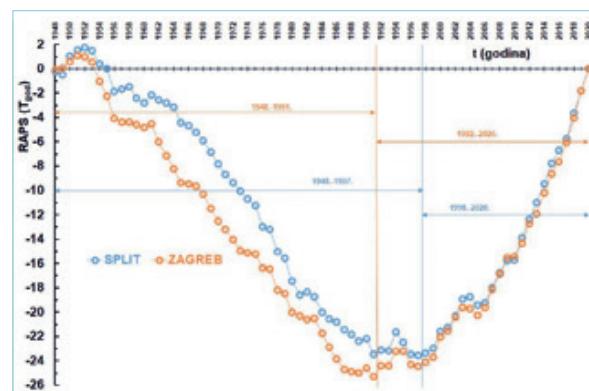
statistički značajno različitim prosječnim vrijednostima. Korištenjem RAPS metode, čiji je grafički prikaz dan na slici 2 ustanovljeno je postojanje četiri podrazdoblja na postaji Split (1948. – 1958.; 1959. – 1982.; 1983. – 1994.; 1995. – 2020.) i tri podrazdoblja na postaji Zagreb (1948. – 1958.; 1959. – 1966.; 1967. – 2020.). Grafički prikazi četiri podniza Splita i tri podniza Zagreba ucrtani su na slici 3. Razlike između uzastopnih prosječnih vrijednosti podrazdoblja testirane su F-testom i t-testom, a rezultati vjerojatnosti,  $p$ , t-testa između uzastopnih podnizova su uneseni u Tablicu 2.

Tablica 2: Matrica prosječnih vrijednosti godišnjih oborina u podrazdobljima,  $P_{pr}$ , određenim RAPS metodom (slika 2) i rezultata t-testa,  $p$ , između uzastopnih podrazdoblja

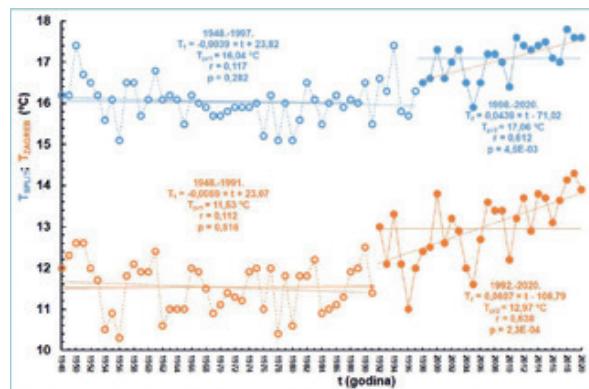
	podrazdoblje	$P_{pr}$ (mm)	$p$ (t-test)
SPLIT	1948. – 1958.	762,0	3,4E-03 5,3E-06 8,7E-03
	1959. – 1982.	885,9	
	1983. – 1994.	671,1	
	1995. – 2020.	827,4	
ZAGREB	1948. – 1958.	839,4	7,0E-03 9,7E-03
	1959. – 1966.	1013,7	
	1967. – 2020.	874,2	

Na slici 4 ucrtani su nizovi srednjih godišnjih temperaturama Splita i Zagreba u razdoblju 1948. – 2020. Na slici su ucrtani i pravci linearne regresije, te upisane jednadžbe linearne regresije, vrijednosti koeficijenata linearne korelacije,  $r$ , te vrijednosti vjerojatnoće M-K testa,  $p$ . Na ovoj su slici ucrtane i krivulje drugog reda te je upisana njihova jednadžba i vrijednosti indeksa nelinearne (parabolične) korelacije,  $R$ . Na obje postaje linearni trendovi porasta su statistički značajni. Međutim, treba uočiti da se krivulje drugog reda mnogo bolje prilagođavaju analiziranim nizovima te da su vrijednosti kvadrata indeksa nelinearne korelacije značajno viši od kvadrata koeficijenata linearne korelacije. Vizualno se uočava da je nagli porast temperatura započeo u posljednjim desetljećima dvadesetog stoljeća. Slično je ponašanje vremenskih nizova temperature uočeno na cijelom području Hrvatske i šire (Bonacci, 2010.; 2012.), ali i na brojnim drugim lokacijama na planetu (npr. Kothawale i Kumar, 2005.; Levi, 2008.; Li, 2010.; Kim i sur., 2015.; Pandžić i sur., 2020. itd.).

Grafički prikaz RAPS-ova srednjih godišnjih temperaturama (slika 5) pokazuje da je na postaji Split nagli porast temperature započeo 1998., dok je na postaji Zagreb započeo šest godina ranije 1992. Grafički prikazi dvaju podnizova Splita i Zagreba ucrtani su na slici 6.



Slika 5: Grafički prikaz RAPS-ova za nizove srednjih godišnjih temperaturama Splita i Zagreba u razdoblju 1948. – 2020.



Slika 6: Prikaz dva podniza srednjih godišnjih temperatura Splita i Zagreba određenih RAPS metodom na slici 5

Važno je konstatirati da na obje postaje u recentnom razdoblju M-K test ukazuje da su trendovi porasta statistički značajni i kako se čini, nemaju intenciju ni zaustavljanja niti ublažavanja. Rezultati vjerojatnosti,  $p$ ,  $t$ -testa između uzastopnih podnizova uneseni su u Tablicu 3. Vrijednost kvadrata koeficijenta linearne korelacije između srednjih godišnjih temperatura na dvije analizirane postaje je visoka te iznosi,  $r^2=0,906$ .

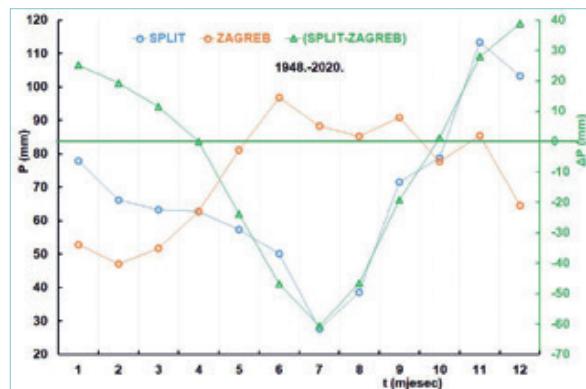
Tablica 3: Matrica prosječnih vrijednosti srednjih godišnjih temperatura u podrazdobljima,  $T_{pr}$ , određenim RAPS metodom (slika 5) i rezultata t-testa,  $p$ , između uzastopnih podrazdoblja

	podrazdoblje	$T_{pr}$ ( $^\circ\text{C}$ )	$p$ (t-test)
SPLIT	1948. - 1997.	16,04	5,9E-12
	1998. - 2020.	17,06	
ZAGREB	1948. - 1991.	11,53	1,4E-12
	1992. - 2020.	12,97	

### 3.2. Analiza mjesecnih nizova oborina i temperaturu

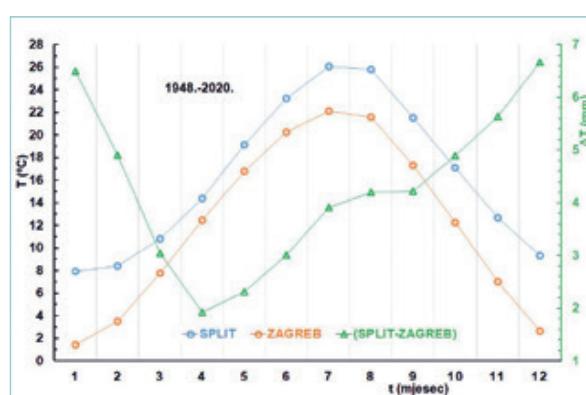
U Tablici 1 upisane su vrijednosti prosječnih mjesecnih oborina,  $P_{pr}$ , temperatura,  $T_{pr}$ , i standardnih devijacija,  $S$ , Splita i Zagreba u razdoblju 1948. – 2020. Kako bi se moglo jasno uočiti razlike oborinskih režima na dvije analizirane postaje tijekom dvanaest mjeseci godine na slici 7 su grafički prikazane njihove prosječne mjesecne vrijednosti kao i razlike među njima,  $\Delta P_i = P_{i,SPLIT} - P_{i,ZAGREB}$ .

Iako se godišnje količine oborina razlikuju tek za red veličine 10 %, razlike u oborinskom režimu tijekom godine su značajne, što bitno utječe i na potencijalne režime suša na ove dvije lokacije. Na postaji Split obilne se oborine javljaju u hladnom razdoblju godine. Maksimum se javlja u studenom, a minimum u srpnju. Na postaji Zagreb obilne oborine se javljaju u razdoblju od svibnja do studenog s maksimumom u lipnju i minimumom u veljači. U razdoblju od studenog do ožujka prosječne mjesecne oborine u Zagrebu niže su od onih u Splitu, dok su od svibnja do rujna više. U travnju i listopadu su praktično iste.



Slika 7: Prosječne mjesecne vrijednosti oborina na analiziranim postajama tijekom razdoblja 1948. - 2020., kao i razlike među njima,  $\Delta P_i = P_{i,SPLIT} - P_{i,ZAGREB}$

Režim prosječnih vrijednosti srednjih mjesecnih temperatura tijekom godine na obje postaje je vrlo sličan. Na slici 8 prikazane su pripadne prosječne mjesecne vrijednosti kao i razlike među njima,  $\Delta T_i = T_{i,SPLIT} - T_{i,ZAGREB}$ . Maksimumi se javljaju u srpnju, a minimumi u siječnju. Najveće razlike se javljaju u prosincu i iznose,  $\Delta T_{12} = 6,66^\circ\text{C}$ , dok se minimalne vrijednosti javljaju u travnju kad razlika iznosi,  $\Delta T_4 = 1,93^\circ\text{C}$ .



Slika 8: Prosječne mjesecne vrijednosti srednjih mjesecnih temperatura na analiziranim postajama tijekom razdoblja 1948. - 2020., kao i razlike među njima,  $\Delta T_i = T_{i,SPLIT} - T_{i,ZAGREB}$

U Tablici 4 su upisane vrijednosti koeficijenata linearne korelacije,  $r$ , i rezultata M-K testa,  $p$ , za nizove mjesecnih oborina i srednjih mjesecnih temperatura na obje postaje u razdoblju 1948. – 2020. Plavom bojom su upisani rezultati za nizove sa statistički neznačajnim

**Tablica 4:** Matrica koeficijenata linearne korelacije,  $r$ , i rezultata M-K testa,  $p$ , za nizove mjesecnih oborina i srednjih mjesecnih temperatura na obije postaje u razdoblju 1948. - 2020.

mjesec	oborina				temperatura			
	SPLIT		ZAGREB		SPLIT		ZAGREB	
	r	p	r	p	r	p	r	p
siječanj	0,085	0,363	0,161	0,105	0,130	0,282	0,307	9,5E-03
veljača	0,065	0,801	0,140	0,561	0,163	0,277	0,258	0,072
ožujak	0,044	0,587	0,022	0,973	0,284	0,029	0,360	4,9E-03
travanj	0,027	0,753	0,085	0,440	0,300	0,007	0,374	6,8E-04
svibanj	0,076	0,336	0,098	0,443	0,256	0,017	0,342	1,7E-03
lipanj	0,071	0,179	0,107	0,353	0,446	1,3E-04	0,498	1,7E-05
srpanj	0,042	0,238	0,091	0,644	0,478	5,6E-05	0,534	9,2E-07
kolovoz	0,083	0,127	0,003	0,932	0,421	3,2E-04	0,490	1,9E-05
rujan	0,072	0,376	0,259	0,114	0,062	0,658	0,118	0,548
listopad	0,050	0,775	0,201	0,096	0,191	0,117	0,283	0,019
studen	0,017	0,797	0,033	0,992	0,246	0,048	0,235	0,045
prosinac	0,095	0,338	0,011	0,890	0,066	0,472	0,233	0,022

Plavom bojom su upisani rezultati za nizove sa statistički neznačajnim trendom opadanja ( $p>0,05$ )

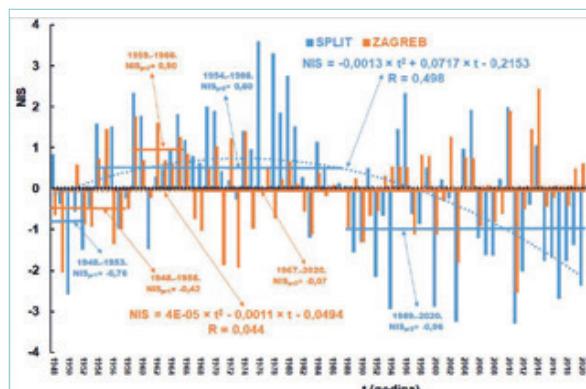
Crveno podebljano su upisani rezultati za nizovi sa statistički značajnim trendom porasta ( $p<0,05$ )

Crnom bojom su upisani rezultati za nizove sa statistički neznačajnim trendom porasta ( $p>0,05$ )

trendom opadanja ( $p>0,05$ ). Crveno podebljano su upisani rezultati za nizove sa statistički značajnim trendom porasta ( $p<0,05$ ) dok su crnom bojom upisani rezultati za nizove sa statistički neznačajnim trendom porasta ( $p>0,05$ ). U slučaju nizova mjesecnih oborina javljaju se trendovi opadanja (označeni plavom bojom) kao i trendovi porasta (označeni crnom bojom). Uglavnom su svi statistički neznačajni. Situacija s nizovima srednjih mjesecnih temperatura potpuno je drugačija. Svi mjesecni nizovi na obje postaje pokazuju trend porasta. U većini mjeseci, osobito tijekom ljetnog razdoblja, ovi su uzlazni trendovi i statistički značajni što je utvrđeno primjenom M-K testa.

### 3.3. Analiza godišnjih vrijednosti NIS-a

U obliku histograma na [slici 9](#) su prikazani nizovi NIS-a,  $NIS_i$ ,  $i \in \{1,2,\dots,73\}$ , definirani na osnovi 73-godišnje vrijednosti oborina i srednjih godišnjih temperatura Splita i Zagreba u razdoblju 1948. - 2020. Ucrtane su i krivulje drugog reda te njihove jednadžbe i indeksi nelinearne korelacije,  $R$ . Ucrtana su i podrazdoblja u kojima se korištenjem F-testa i t-testa uzastopne prosječne vrijednosti NIS-ova statistički značajno razlikuju. Za određivanje podrazdoblja koristi se grafički prikaz sume NIS-ova,  $\Sigma NIS_i$ ,  $i \in \{1,2,\dots,73\}$ , koji se nalazi na [slici 10](#). [Tablica 5](#) predstavlja matricu prosječnih vrijednosti godišnjih NIS-ova,  $NIS_{pi}$ , u podrazdobljima

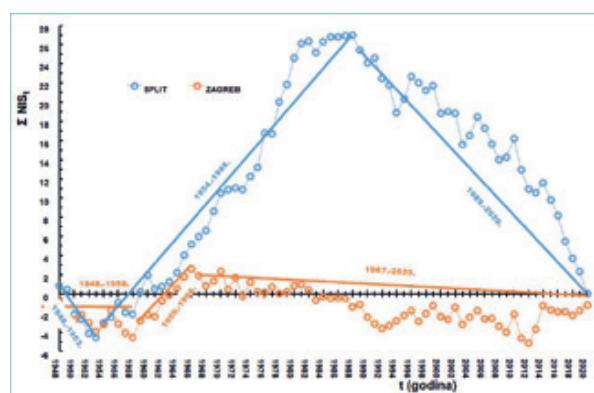


**Slika 9:** Prikaz nizova Novih Indeksu Suše,  $NIS_i$ ,  $i \in \{1,2,\dots,73\}$ , definiranih na osnovi godišnjih vrijednosti oborina i srednjih godišnjih temperatura Splita i Zagreba u razdoblju 1948. - 2020.

određenim na [slici 10](#) i rezultata t-testa,  $p$ , između uzastopnih podrazdoblja. Kada se godina tretira kao jedinica analize može se zaključiti da je pojava suše na lokaciji Splita započela 1988. godine i bila je intenzivna što se može zaključiti iz nagiba pravca ucrtanog na [slici 10](#) u podrazdoblju 1989. - 2020. NIS u slučaju postaje Zagreb pokazuje mnogo blažu sušu u razdoblju 1967. - 2020. Što više, čini se da je u podrazdoblju 2012. - 2020. došlo do prestanka suše i do pojave vlažnog podrazdoblja. To nije bilo moguće ustanoviti testiranjem.

**Tablica 5:** Matrica prosječnih vrijednosti godišnjih Novih Indeksa Suše,  $NIS_{pr}$ , u podrazdobljima određenim na slici 10 i rezultata t-testa,  $p$ , između uzastopnih podrazdoblja

	podrazdoblje	$NIS_{pr}$	$p$ (t-test)
SPLIT	1948. - 1953.	-0,758	2,4E-03 6,9E-05
	1954. - 1988.	0,901	
	1989. - 2020.	-0,844	
ZAGREB	1948. - 1958.	-0,416	4,9E-03 9,7E-03
	1959. - 1966.	0,897	
	1967. - 2020.	-0,070	

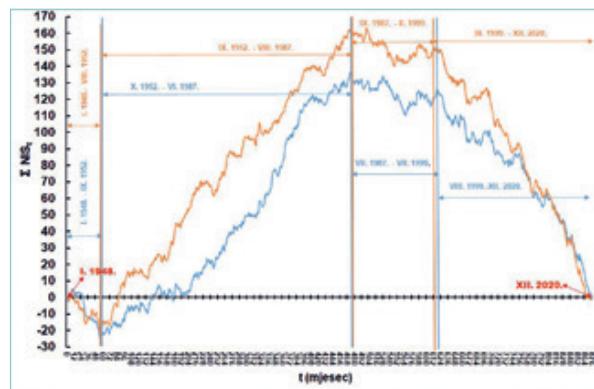


**Slika 10:** Prikaz sume Novih Indeksa Suše,  $\Sigma NIS_i$ ,  $i \in \{1,2,\dots,73\}$ , definiranih na osnovi godišnjih vrijednosti oborina i srednjih godišnjih temperatura Splita i Zagreba u razdoblju 1948. - 2020.

### 3.4. Analiza mjesecnih vrijednosti NIS-a

Zbog sezonalnosti svakog klimatskog režima, za potrebe izučavanja pojavnosti suše i promjena između sušnih i vlažnih podrazdoblja, mjesec kao kraća vremenska jedinica može bolje i pouzdano karakterizirati pojavnost suša.

Na [slici 11](#) prikazane su sume mjesecnih NIS-ova,  $\Sigma NIS_i$ ,  $i \in \{1,2,\dots,876\}$ , u razdoblju od I. 1948. do XII. 2020. Uočava se slično ponašanje sume vremenskih nizova na obje analizirane postaje bez obzira na razliku njihovih klimatskih karakteristika. U oba slučaja postoje četiri podrazdoblja.



**Slika 11:** Prikaz sume Novih Indeksa Suše,  $\Sigma NIS_i$ ,  $i \in \{1,2,\dots,876\}$ , definiranih na osnovi mjesecnih vrijednosti oborina i srednjih godišnjih temperatura Splita i Zagreba u razdoblju I. 1948. - XII. 2020.

U [Tablici 6](#) se nalaze prosječne vrijednosti godišnjih NIS-ova,  $NIS_{pr}$ , u podrazdobljima određenim na [slici 11](#) i rezultata t-testa,  $p$ , između uzastopnih podrazdoblja. Dugotrajno opadanje sumarne vrijednosti NIS-ova započelo je na postaji Split u kolovozu 1999. dok je na postaji Zagreb počela pet mjeseci ranije u ožujku 1999. U posljednjem podrazdoblju bilo je i povremenih vlažnih podrazdoblja, ali opći trend ukazuje da na obje postaje prevladava suša koja će se najvjerojatnije nastaviti ako temperatura zraka nastavi rasti, što je zbog globalnog zagrijavanja za očekivati, a oborine ostanu iste.

Nastavno će se analizirati ponašanje vremenskih nizova NIS-ova svakog pojedinog mjeseca tijekom razdoblja 1948. - 2020. Ova će analiza pokazati ponašanje NIS-a u svakom pojedinom mjesecu tijekom 73 analizirane godine.

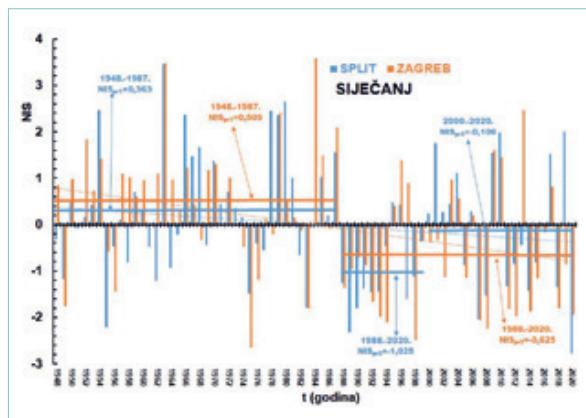
[Slika 12](#) prikazuje nizove NIS-ova,  $NIS_i$ ,  $i \in \{1,2,\dots,73\}$ , definiranih na osnovi mjesecnih vrijednosti oborina i srednjih godišnjih temperatura Splita i Zagreba u mjesecu siječnju u razdoblju 1948. - 2020. Podrazdoblja za mjesec siječanj su definirana i ucrtana na sumarnom prikazu NIS-ova,  $\Sigma NIS_i$ ,  $i \in \{1,2,\dots,73\}$ , na [slikama 13](#). Na [slikama 14 do 24](#) prikazat će se samo sumarne vrijednosti NIS-ova,  $\Sigma NIS_i$ ,  $i \in \{1,2,\dots,73\}$ , za mjesec od veljače ([slika 14](#)) do prosinca ([slika 24](#)).

U [Tablici 7](#) se nalaze vrijednosti koeficijenata linearne korelacije,  $r$ , i rezultata M-K testa,  $p$ , za nizove pojedinih mjesecnih NIS-ova,  $NIS_{pr}$ , na obje postaje u razdoblju 1948.-2020. U svim mjesecima osim rujna ustanovljeni su trendovi opadanja. Statistički značajni su češće na postaji Zagreb čak tijekom 6 mjeseci u siječnju, te od travnja do kolovoza. Na postaji Split statistički su značajni samo tijekom tri ljetna mjeseca od lipnja do kolovoza. Očito je da NIS ukazuje da je suša jače izražena tijekom toplog razdoblja godine.

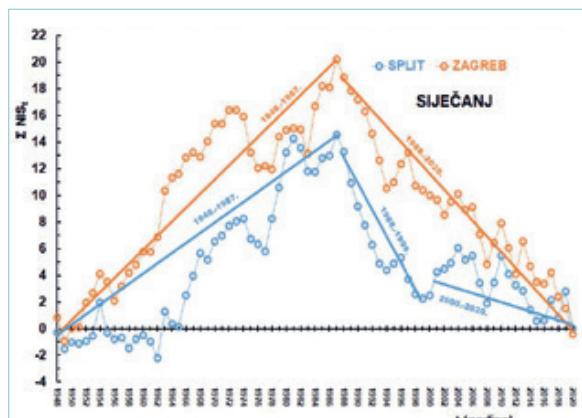
U [Tablici 8](#) su unesene prosječne vrijednosti mjesecnih Novih Indeksa Suše,  $NIS_{pr}$ , za svaki pojedini mjesec godine u podrazdobljima određenim na [slikama 13 do 24](#) i rezultata t-testa,  $p$ , između uzastopnih podrazdoblja. Iz podataka navedenih u [Tablici 8](#) i grafičkih prikaza na [slikama 14 do 24](#) može se uočiti da se NIS različito ponašao tijekom različitih podrazdoblja unutar cjelokupno analiziranog 73-godišnjeg perioda.

**Tablica 6:** Matrica prosječnih vrijednosti mjesecnih Novih Indeksa Suše,  $NIS_{pr}$ , u podrazdobljima određenim na slici 11 i rezultata t-testa,  $p$ , između uzastopnih podrazdoblja

	podrazdoblje	$NIS_{pr}$	p (t-test)
SPLIT	I. 1948. - IX. 1952.	-0,424	9,3E-05 1,1E-03 8,5E-03
	X. 1952. - VI. 1987.	0,385	
	VII. 1987. - VII. 1999.	-0,073	
	VIII. 1999. - XII. 2020.	-0,490	
ZAGREB	I. 1948. - IX. 1952.	-0,366	5,0E-08 3,3E-04 6,4E-03
	X. 1952. - VIII. 1987.	0,434	
	IX. 1987. - II. 1999.	-0,076	
	III. 1999. - XII. 2020.	-0,580	



**Slika 12:** Prikaz nizova Novih Indeksa Suše,  $NIS_i$ ,  $i \in (1,2,\dots,73)$ , definiranih na osnovi mjesecnih vrijednosti oborina i srednjih godišnjih temperatura Splita i Zagreba u mjesecu siječnju u razdoblju 1948. - 2020.



**Slika 13:** Prikaz sume Novih Indeksa Suše,  $\Sigma NIS_i$ ,  $i \in (1,2,\dots,73)$ , definiranih na osnovi mjesecnih vrijednosti oborina i srednjih godišnjih temperatura Splita i Zagreba u mjesecu siječnju u razdoblju 1948. - 2020.

**Tablica 7:** Matrica koeficijenata linearne korelacije, r, i rezultata M-K testa, p, za nizove pojedinih mjesecnih Novih Indeksa Suše,  $NIS_i$ ,  $i \in (1,2,\dots,73)$ , na obje postaje u razdoblju 1948. - 2020.

mjesec	karakteristika	Split	Zagreb
siječanj	r	0,159	<b>0,332</b>
	p	0,232	<b>0,003</b>
veljača	r	0,069	0,081
	p	0,764	0,577
ožujak	r	0,153	0,217
	p	0,207	0,102
travanj	r	0,173	<b>0,288</b>
	p	0,136	<b>0,004</b>
svibanj	r	0,103	<b>0,254</b>
	p	0,348	<b>0,044</b>
lipanj	r	<b>0,310</b>	<b>0,374</b>
	p	<b>0,008</b>	<b>1,6E-04</b>
srpanj	r	<b>0,320</b>	<b>0,374</b>
	p	<b>1,9E-04</b>	<b>0,002</b>
kolovoz	r	<b>0,285</b>	<b>0,288</b>
	p	<b>0,003</b>	<b>0,007</b>
rujan	r	0,006	0,084
	p	<b>0,928</b>	<b>0,735</b>
listopad	r	0,094	0,539
	p	0,449	0,943
studeni	r	0,192	0,195
	p	0,172	0,076
prosinac	r	0,076	0,268
	p	0,438	0,079

Plavom bojom su upisani rezultati za nizove sa statistički neznačajnim trendom porasta ( $p>0,05$ )

Crvenom bojom podebljano su upisani rezultati za nizovi sa statistički značajnim trendom opadanja ( $p<0,05$ )

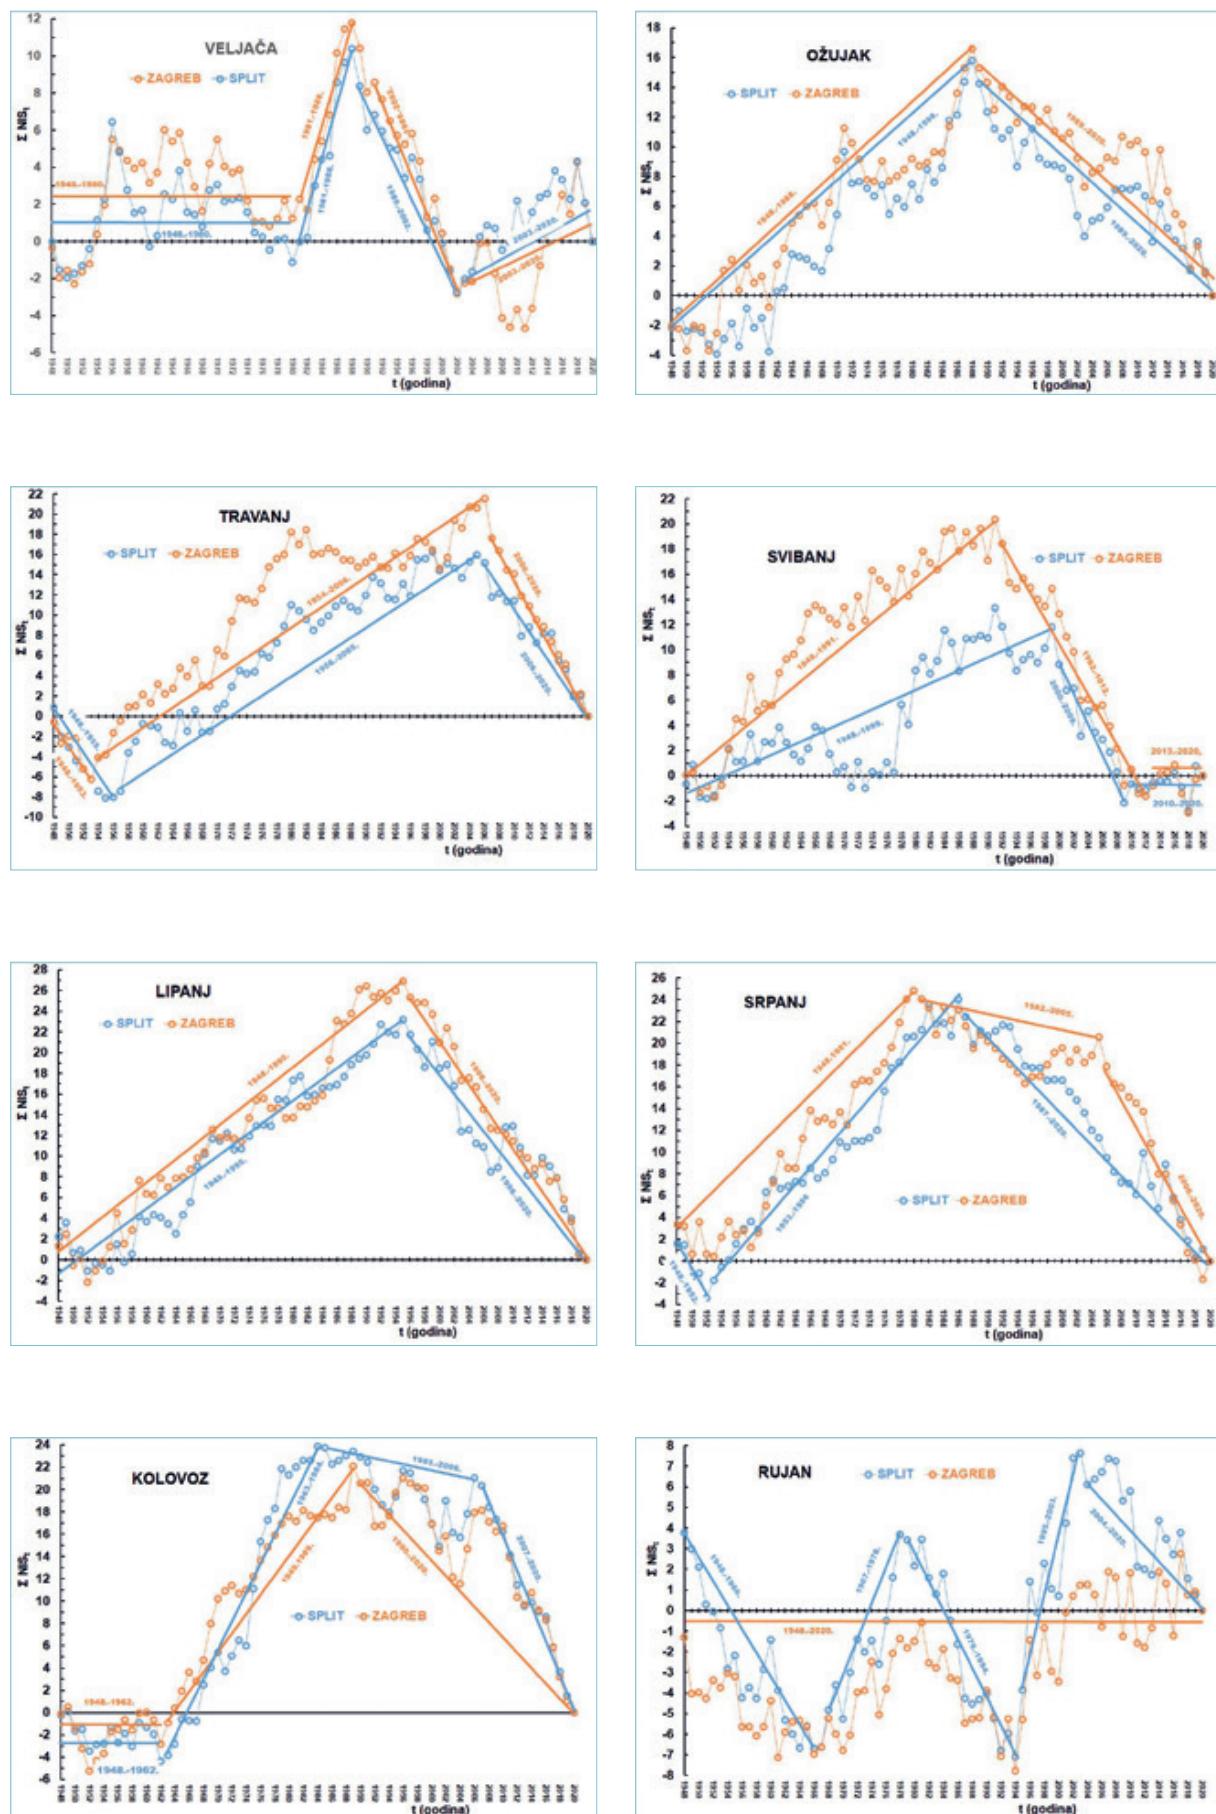
Crnom bojom su upisani rezultati za nizove sa statistički neznačajnim trendom opadanja ( $p>0,05$ )

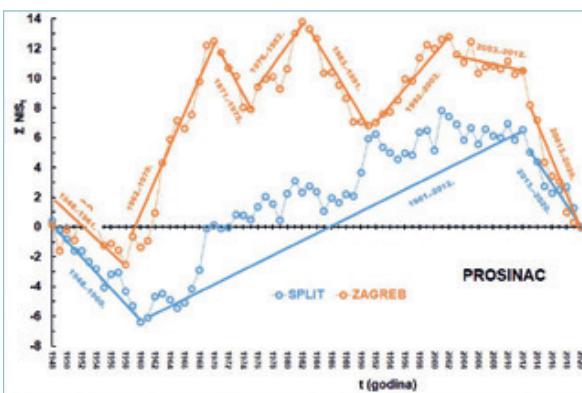
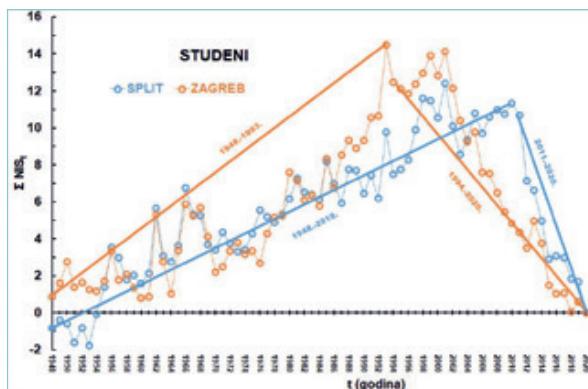
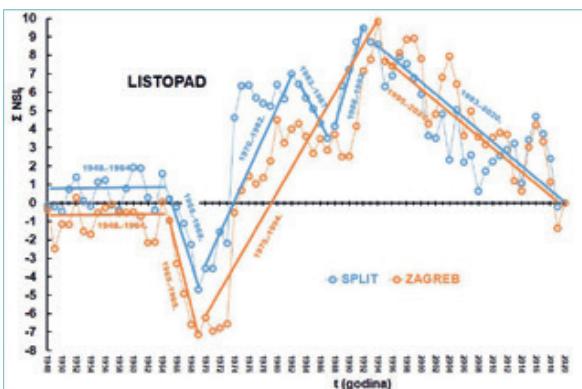
**Tablica 8:** Matrica prosječnih vrijednosti Novih Indeksa Suše,  $NIS_{pr}$ , za svaki pojedini mjesec u podrazdobljima određenim RAPS metodom (slike 13 do 24) i rezultata t-testa,  $p$ , između uzastopnih podrazdoblja

mjesec	postaja	podrazdoblje	$NIS_{pr}$	$p$ (t-test)	
siječanj	Split	1948. - 1987.	0,363	0,0012 0,049	
		1988. - 1999.	-1,025		
		2000. - 2020.	-0,106		
	Zagreb	1948. - 1987.	0,505	0,0004	
		1988. - 2020.	-0,625		
	Split	1948. - 1980.	-0,033	0,008 0,0003 0,023	
veljača		1981. - 1988.	1,436		
		1989. - 2002.	-0,937		
		2003. - 2020.	0,151		
Zagreb	1948. - 1980.	0,038	0,0148 0,0002 0,0268		
	1981. - 1988.	1,317			
	1989. - 2002.	-1,042			
	2003. - 2020.	0,192			
ožujak	Split	1948. - 1988.	0,385	0,0164 0,0111	
		1989. - 2020.	-0,494		
	Zagreb	1948. - 1988.	0,405		
		1989. - 2020.	-0,519		
travanj	Split	1948. - 1955.	-1,011	0,007 0,0004	
		1956. - 2005.	0,481		
		2006. - 2020.	-1,065		
	Zagreb	1948. - 1953.	-1,035	0,014 3,7E-06	
		1954. - 2006.	0,523		
		2007. - 2020.	-1,538		
svibanj	Split	1948. - 1999.	0,227	0,007 0,029	
		2000. - 2009.	-1,393		
		2010. - 2020.	0,191		
	Zagreb	1948. - 1991.	0,463	0,009 0,043	
		1992. - 2012.	-1,047		
		2013. - 2020.	0,205		
lipanj	Split	1948. - 1995.	0,483	0,0004	
		1996. - 2020.	-0,927		
	Zagreb	1948. - 1995.	0,560	1,4E-05	
		1996. - 2020.	-1,076		
srpanj	Split	1948. - 1952.	-0,679	0,027 4,5E-05	
		1953. - 1986.	0,807		
		1987. - 2020.	-0,707		
	Zagreb	1948. - 1981.	0,752	0,026 0,006	
		1982. - 2005.	-0,170		
		2006. - 2020.	-1,372		

mjesec	postaja	podrazdoblje	NIS <sub>pr</sub>	p (t-test)
kolovoz	Split	1948. - 1962.	-0,292	0,003 0,009 0,005
		1963. - 1984.	1,285	
		1985. - 2006.	-0,128	
		2007. - 2020.	-1,504	
	Zagreb	1948. - 1962.	-0,185	0,007 0,0002
		1963. - 1989.	0,921	
		1990. - 2020.	-0,713	
rujan	Split	1948. - 1966.	-0,571	0,033 0,004 0,021 0,001
		1967. - 1978.	0,866	
		1979. - 1995.	-0,675	
		1996. - 2003.	1,639	
		2004. - 2020.	-0,450	
	Zagreb	1948. - 2020.	0,0003	
listopad	Split	1948. - 1964.	0,093	0,013 0,035 0,014 0,002 0,034
		1965. - 1969.	-1,256	
		1970. - 1982.	0,899	
		1983. - 1987.	-0,697	
		1988. - 1992.	1,195	
		1993. - 2020.	-0,338	
	Zagreb	1948. - 1964.	0,003	0,015 0,006 0,019
		1965. - 1969.	-1,438	
		1970. - 1994.	0,678	
		1995. - 2020.	-0,378	
studeni	Split	1948. - 2010.	0,180	0,004
		2011. - 2020.	-1,131	
	Zagreb	1948. - 1993.	0,315	0,0096
		1994. - 2020.	-0,535	
prosinac	Split	1948. - 1960.	-0,491	0,012 0,005
		1961. - 2012.	0,249	
		2013. - 2020.	-0,818	
	Zagreb	1948. - 1961.	-0,066	0,007 0,001 0,009 0,003 0,0004 0,042 0,0005
		1962. - 1970.	1,491	
		1971. - 1975.	-0,919	
		1976. - 1982.	0,838	
		1983. - 1991.	-0,770	
		1992. - 2002.	0,539	
		2003. - 2012.	-0,225	
		2013. - 2020.	-1,314	

Slika 14-24: Prikaz sume Novih Indeksa Suše,  $\Sigma NIS_i$ ,  $i \in (1, 2, \dots, 73)$ , definiranih na osnovi mjesecnih vrijednosti oborina i srednjih godišnjih temperatura Splita i Zagreba u razdoblju 1948. - 2020.





Ne može se zanemariti ni činjenica sličnog ponašanja mjesecnih NIS-ova na obje analizirane postaje. Najviše se razlikuju u mjesecu rujnu kada na postaji Zagreb gotovo da nema statistički značajne razlike između vlažnih i sušnih podrazdoblja, dok se na postaji Split izmjenjuje čak njih pet.

#### 4. ZAKLJUČAK

Iako se problematikom suše bave brojne institucije i pojedinci, te unatoč tome što je broj objavljenih radova o najrazličitijim aspektima ove problematike u stalnom porastu i dalje kao urgentan problem stoji potreba i izazov da se razviju objektivne i učinkovite metode i tehnike za procjenu intenziteta kao i prognozu početka i kraja pojave suše (Panu i Sharma, 2002.). Monitoring suše i razvoj sustava ranog uzbunjivanja vezanog sa sušom ključan je za učinkovitu borbu protiv ove sve očitije ne samo prirodne nepogode (Barker i sur., 2015.; AghaKouchak i sur., 2021.; Thompson, 2021.).

U ovom radu je iznesena jedna nova i originalna metoda za računanje indeksa suše nazvanog NIS. Kao bitni indikatori suše u njoj su korištene standardizirane vrijednosti prizemne temperaturu zraka i oborine. U radu su analize vršene s vremenskim inkrementima mjeseca i godina. Moguće ih je primijeniti i za druge vremenske inkremente kao npr. sezone te dekade. NIS se proračunava tako da se od standardizirane vrijednosti oborine odbije standardizirana vrijednost temperature. Važno je uočiti da bi metoda mogla biti lako i široko primjenjiva upravo zbog činjenice što se radi o dva klimatska parametra koji se najčešće i najduže motre u cijelom svijetu.

Sistemi monitoringa i rane najave suše bazirani na različitim indeksima suše mogli bi biti od značaja u ublažavanju i prevenciji posljedica od suše. Osobito je važno da se rezultati istraživanja suše približe praksi, tj. krajnjim korisnicima, kako bi se stvorili uvjeti za učinkovitu borbu protiv ove sve opasnije ugroze. Učinak globalnog zagrijavanja očito će i u budućnosti utjecati na intenziviranje suše na brojnim prostorima. Pri tome treba imati na umu da na svakoj pojedinoj lokaciji, često i na bliskim i sa sličnim klimatskim svojstvima, suša može izazvati različite posljedice. Na primjer lokalni nedostaci vode mogu biti neuočeni zbog toga jer se voda iz jedne lokacije transferira u drugo područje. Ostali nedostaci mogu biti kronični kod zajednica koje uvek trebaju više vode od one koja im je na raspolaganju, čak i tijekom vlažnih razdoblja. Sve češće se događa da nedostaci vode nastaju zbog njenog onečišćenja. Svi prethodno navedeni kao i niz onih koji nisu spomenuti, urgentno nalažu bolju konceptualizaciju problematike suše (Thompson, 2021.).

Neophodno je nastaviti s istraživačkim naporima u prevladavanju postojećih dilema vezanih s identifikacijom i kvantifikacijom fenomena suše. Istraživanja koja su izvršena u ovom radu treba shvatiti kao mogući doprinos u rješavanju ove složene i vrlo aktualne problematike. Ovaj rad predstavlja pokušaj da se zajedničkim korištenjem dva bitna parametra za formiranje suše, oborina i temperature, pridonese rješavanju ove aktualne problematike. Predloženi postupak određivanja NIS-a iznesen u ovom radu treba više shvatiti kao dio analize procesa suše nego kao prijedlog nekog novog i absolutno pouzdanog indeksa.

#### ZAHVALA

Ovaj rad je sufincirano kroz projekt "VODIME – Vode Imotske krajine" (KK.05.1.1.02.0024), projekt financiran sredstvima Vlade Republike Hrvatske i sredstvima Europske unije kroz Europski strukturni fond, u sklopu poziva "Shema za jačanje primijenjenih istraživanja za mjere prilagodbe klimatskim promjenama" (KK.05.1.1.02.).

Ovo istraživanje je djelomično sufincirano kroz projekt KK.01.1.1.02.0027, koji je sufinciran od strane Hrvatske Vlade i Europske Unije kroz „European Regional Development Fund – the Competitiveness and Cohesion Operational Programme“.

## LITERATURA

- Allen, S. M., Gough, W. A., Mohsin, T. (2015.): Changes in the frequency of extreme temperature records for Toronto, Ontario, Canada. *Theoretical and Applied Climatology*, 119 (3-4), 481-491. DOI:10.1007/s00704-014-1131-1
- AghaKouchak, A., Mirchi, A., Madani, K., Di Baldassarre, G., Nazemi, A., Alborzi, A., Anjileli, H., Azarderakhsh, M., Chiang, F., Hassanzadeh, E., Huning, L. S.; Mallakpour, I., Martinez, A., Mazdiyasni, O., Moftakhari, H., Norouzi, H., Sedegh, M., Sadeqi, D., Van Loon A. F., Wanders, N. (2021.): Anthropogenic drought: definition, challenges, and opportunities. *Reviews of Geophysics*, 58 (2), e2019RG000683. DOI: 10.1029/2019RG000683
- Barker, L. J., Hannaford, J., Chiverton, A., Svensson, C. (2016.): From meteorological to hydrological drought using standardised indicators. *Hydrology and Earth System Sciences*, 20 (6), 2483–2505. DOI: 10.5194/hess-20-2483-2016
- Bonacci, O. (1993.): Hydrological identification of drought. *Hydrological Processes*. 7 (3), 249–262. DOI:10.1002/hyp.3360070303
- Bonacci, O. (2010.): Analiza nizova srednjih godišnjih temperatura zraka u Hrvatskoj. *Građevinar*, 62(9), 781–791.
- Bonacci, O. (2012.): Increase of mean annual surface air temperature in the Western Balkans during last 30 years. *Vodoprivreda*, 44 (255-257), 75–89.
- Bonacci, O., Roje-Bonacci, T. (2020.): Primjena metode dan za danom (*day to day*) varijabilnosti temperature zraka na podatcima opaženim na opservatoriju Zagreb-Grič (1887.-2018.). *Hrvatske Vode*, 28 (112), 125-134
- Dai, A. (2011.): Drought under global warming: a review. *Wiley Interdisciplinary Reviews: 2* (1), 45–65. DOI: 10.1002/wcc.81
- Draginčić, J., Bezdan, A., Pejić, B., Mesaroš, M., Blagojević, B. (2017.): Analiza pojave suše na području Severnog Banata. *Annals of Agronomy*, 41 (2) 77-84.
- Ferina, J., Vučetić, V., Bašić, T., Anić, M. (2021.): Spatial distribution and long-term changes in water balance components in Croatia. *Theoretical and Applied Climatology*, 144 (3-4), 1311–1333. DOI: 10.1007/s00704-021-03593-1
- Garbrecht, J., Fernandez, G. P. (1994.): Visualization of trends and fluctuations in climatic records. *Water Resources Bulletin*, 30 (2), 297–306. DOI:10.1111/j.1752-1688.1994.tb03292.x
- Hamed, K. H., Ramachandra, R. (1998.): A modified Mann-Kendal trend test for autocorrelated data. *Journal of Hydrology*, 204 (14), 182–196. DOI: 10.1016/S0022-1694(97)
- Hisdal, H. (2002.): Regional aspects of drought. Dissertation. Faculty of mathematics and natural sciences, University of Oslo, Norge.
- Hori, Y., Gough, W. A., Butler, K., Tsuji, L. J. (2017.): Trends in the seasonal length and opening dates of a winter road in the western James Bay region, Ontario, Canada. *Theoretical and Applied Climatology*, 129 (3-4), 1309–1320. DOI: 10.1007/s00704-016-1855-1
- Husain Shourov, M. M., Mahmud, I. (2019.): pyMannKendall: a python package for non parametric Mann Kendall family of trend tests. *Journal of Open Source Software*, 4 (9), 1556. DOI:10.21105/joss.01556
- Kendall, M. G. (1975.): *Rank correlation methods*, 4th edition. Charles Griffin, London, Great Britain
- Kim, Y. H.; Kim, M. K.; Lau, W. K. M.; Kim, K. M.; Cho, C. H. (2015.): Possible mechanism of abrupt jump in winter surface air temperature in the late 1980s over the northern hemisphere. *Journal of Geophysical Research Atmospheres*, 120 (12), 474–485. DOI 10.1002/2015JD023864
- Köppen, W., Geiger, R. (1936.): *Handbuch der Klimatologie: Das geographische System der Klimate*. Verlag vod Gebrüder Borntraeger, Berlin.
- Kothawale, D. R.; Kumar, K. R. (2005.): On the recent changes in surface temperature trends over India. *Geophysical Research Letter*, 32 (18): L18714. DOI:10.1029/2005GL023528
- Levi, B. G. (2008.): Trends in the hydrology of the western US bear the imprint of manmade change. *Physics Today*, 61 (4), 16–18. DOI: 10.1063/1.2911164
- Li, G. (2010.): Changes of the Yellow River water resources and countermeasures. Climate change and adaptation for water resources in Yellow river basin, China, *IHP VII Technical Documents in Hydrology*, UNESCO Office in Beijing, 11-23.
- Li, J., Wu, C., Xia, C. A., Yeh, P. J. F., Hu, B. X., Huang, G. (2021.): Assessing the responses of hydrological drought to meteorological drought in the Huai River Basin, China. *Theoretical and Applied Climatology* 144 (3-4) 1043–1057. DOI: 10.1007/s00704-021-03567-3
- Lloyd-Hughes, B. (2014.): The impracticality of a universal drought definition. *Theoretical and Applied Climatology*, 117 (3), 607–611. DOI: 10.1007/s00704-013-1025-7
- Ljubenkov, I., Bonacci, O. (2011.): Utvrđivanje i određivanje suše na otoku Korčuli. *Hrvatske Vode*, 19 (77), 181–194.
- Mann, H. B. (1945.): Non-parametric test of randomness against trend. *Econometrica* 13 (3), 245–259. DOI: 10.2307/1907187
- McGhee, J. W. (1985.): *Introductory statistics*. West Publishing Company, St Paul and New York.
- Mishra, A. K., Singh, V. P. (2010.): A review of drought concept, *Journal of Hydrology*, 391, 202-216, 2010., DOI:10.1016/j.jhydrol.2010.07.012
- Morid, S., Smakhtin, V., Moghaddasi, M. (2006.): Comparison of seven meteorological indices for drought monitoring in Iran, *International Journal of Climatology*, 26, (7), 971–985. DOI:10.1002/joc.1264
- Neto, A. A. M., Roy, T., de Oliveira, P. T. S., Troch, P. A. (2020.): An aridity index-based formulation of

- streamflow components. *Water Resources Research*, 56, e2020WR027123. DOI: 10.1029/2020WR027123
- Palmer, W. C. (1965.): *Meteorological drought*. Research Paper No. 45. US Department of Commerce Weather Bureau, Washington DC.
- Pandžić, K., Šimunić, I., Tomić, F., Husnjak, S., Likso, T., Petović, D. (2006.): Comparison of three mathematical models for the estimation of 10-day drain discharge. *Theoretical and Applied Climatology*, 85 (1) 107–115. DOI: 10.1007/s00704-005-0165-9
- Pandžić, K., Likso, T., Curić, O., Mesić, M., Pejić, I., Pasarić, Z. (2020.): Drought indices for the Zagreb-Grič Observatory with an overview of drought damage in agriculture in Croatia. *Theoretical and Applied Climatology*, 142 (1-2), 555–567. DOI: 10.1007/s00704-020-03330-0
- Panu U. S., Sharma, T. C. (2002.): Challenges in drought research: some perspectives and future directions. *Hydrological Sciences Journal*, 47 (sup1) S19–S30, DOI: 10.1080/02626660209493019
- Šegota, T., Filipčić, A. (2003.): Köppenova podjela klima i hrvatsko nazivlje. *Geoadria*, 8 (1), 17–37.
- Tadić, L., Dadić, T., Bosak, M. (2015.): Usporedba različitih metoda za ocjenu suše na području kontinentalne Hrvatske, *Grđevinar*, 67 (1), 11–22, DOI: 10.14256/JCE.1088.2014
- Thompson, E. (2021.): A better way to understand drought, *Eos*, 102, DOI: 10.1029/2021EO155289.
- Van Lanen, H. A. J., Wanders, N., Tallaksen, L. M., Van Loon, A. F. (2013.): Hydrological drought across the world: impact of climate and physical catchment structure, *Hydrology and Earth System Sciences*, 17 5(), 1715–1732. DOI:10.5194/hess-17-1715-2013.
- Van Loon, A. F. (2015.): Hydrological drought explained. *Wiley Interdisciplinary Reviews: Water*, 2 (25), 359–392. DOI: 10.1002/wat2.1085
- Wang, H., Stephenson, S. R. (2018.): Quantifying the impacts of climate change and land use/cover change on runoff in the lower Connecticut River Basin. *Hydrological Processes*, 32 (9), 1301–1312. DOI: 10.1002/hyp.11509
- WMO (2012.): *Standardized Precipitation Index User Guide*. World Meteorological Organization WMO-No 1090, Geneve, Switzerland.
- Zhao, Y., Weng, Z., Chen, H., Yang, J. (2020.): Analysis of the evolution of drought, flood, and drought-flood abrupt alternation events under climate change using the daily SWAP Indeks. *Water*, 12 (7), 1969. DOI: 10.3390/w12071969

## PROPOSAL OF A NEW DROUGHT ANALYSIS METHOD

**Abstract.** The key factor in drought occurrence and intensity in any environment are quantities of precipitation that are lower than the average. Additionally, drought phenomenon is strongly affected by air temperature - the higher it is than the average temperature value in a certain period of the year, the more severe are the adverse consequences of drought. In this period of climate change, whose most pronounced manifestation is increased air temperature, this key climatological parameter should be, indeed, included in the calculation of drought index. If included, it can, combined with precipitation, determine the integrated drought index that is applicable to analyses of any kind of drought. The paper presents a new drought analysis method using standardised values of precipitation and mean air temperature in a certain period. The standardised value is calculated by subtracting the average value in the observed period from each individual measured value of precipitation and temperature in a time interval (month, season, year, etc.), and then dividing this value with the standard deviation in that interval. The new drought index (NDI) is calculated by subtracting the value of standardised temperature from the value of standardised precipitation. The NDI values were analysed for series of monthly and annual precipitation quantities and mean monthly and annual air temperatures measured at the stations Split-Marjan and Zagreb-Grič in the 1948-2020 period. The calculated NDI values indicate that drought hazard has been significantly intensifying in the past decades, which can be linked to the effects of global warming. The months most affected by droughts are those in the warm part of the year, i.e. from April to August in Zagreb and from June to August in Split.

**Key words:** drought, air temperature, New Drought Index (NDI), Mann-Kendall test, Split-Marjan, Zagreb-Grič

## VORSCHLAG EINER NEUEN METHODE ZUR ANALYSE DER TROCKENHEIT

**Zusammenfassung.** Der Schlüsselfaktor des Auftretens und der Intensität der Trockenzeit in jeder Umgebung ist die unterdurchschnittliche Niederschlagsmenge. Zusätzlich übt die Lufttemperatur einen starken Einfluss auf die Trockenheit aus. Je höher die Lufttemperatur in Bezug auf den Mittelwert einer bestimmten Jahreszeit, desto schwerwiegender die negativen Folgen. Zur Zeit des globalen Klimawandels, der sich insbesondere im Anstieg der Lufttemperatur manifestiert, soll dieser klimatologische Schlüsselpараметer in die Berechnung des Trockenheitsindex mit der Niederschlagsmenge einbezogen werden. Auf diese Weise ist es möglich den integralen Trockenheitsindex zu bestimmen, der für die Analyse aller Trockenheitstypen anwendbar ist. Im Beitrag wird eine neue Methode zur Analyse der Trockenheit dargestellt, in der standardisierte Werte des Niederschlags und der mittleren Lufttemperatur in einem bestimmten Zeitraum verwendet werden. Standardisierter Wert wird so berechnet, dass von jedem einzelnen gemessenen Wert des Niederschlags und der Temperatur in einem Zeitraum (Monat, Jahreszeit, Jahr usw.) sein durchschnittlicher Wert in diesem Zeitraum abgezogen wird und diese Größe durch die Standardabweichung in diesem Zeitraum geteilt wird. Der neue Trockenheitsindex wird dann so berechnet, dass vom standardisierten Niederschlagswert der standardisierte Temperaturwert abgezogen wird. Die Werte des neuen Trockenheitsindex wurden für die Zeitreihen von monatlichen und jährlichen Niederschlagsmengen sowie für die mittleren Monats- und Jahreslufttemperaturen analysiert, die an den Stationen Split-Marjan und Zagreb-Grič im Zeitraum 1948-2020 gemessen wurden. Die berechneten Werte des neuen Trockenheitsindex weisen darauf hin, dass die Gefahr der Trockenheit namentlich in den letzten Jahrzeiten zunimmt, was mit den Auswirkungen der globalen Erwärmung verbunden werden kann. Die durch Trockenheit am stärksten bedrohten Monate sind die Monate in der warmen Jahreszeit und zwar von April bis August in Zagreb und von Juni bis August in Split.

**Schlüsselwörter:** Trockenzeit, Lufttemperatur, neuer Trockenheitsindex, Mann-Kendall-Test, Split-Marjan, Zagreb-Grič