Očekivano toplinsko opterećenje Dubrovnika, Osijeka, Rijeke, Zadra i Zagreba prema projekcijama regionalnih klimatskih modela

Agapito, Mia

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:417679

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

SVEUČILIŠTE U ZAGREBU

PRIRODOSLOVNO-MATEMATIČKI FAKULTET

GEOFIZIČKI ODSJEK

Mia Agapito

OČEKIVANO TOPLINSKO OPTEREĆENJE DUBROVNIKA, OSIJEKA, RIJEKE, ZADRA I ZAGREBA PREMA PROJEKCIJAMA REGIONALNIH KLIMATSKIH MODELA

Diplomski rad

Zagreb, 2021.

SVEUČILIŠTE U ZAGREBU

PRIRODOSLOVNO-MATEMATIČKI FAKULTET

GEOFIZIČKI ODSJEK

DIPLOMSKI SVEUČILIŠNI STUDIJ FIZIKA-GEOFIZIKA

SMJER: METEOROLOGIJA I FIZIČKA OCEANOGRAFIJA

Mia Agapito

Diplomski rad

Očekivano toplinsko opterećenje Dubrovnika, Osijeka, Rijeke, Zadra i Zagreba prema projekcijama regionalnih klimatskih modela

Voditeljica diplomskog rada: izv. prof. dr. sc. Ivana Herceg Bulić

Zagreb, 2021.

Htjela bih se zahvaliti svojoj obitelji i prijateljima koji su me podržavali tijekom studiranja u Zagrebu. Veliko hvala svim profesorima, a posebno mentorici izv. prof. dr. sc. Ivani Herceg Bulić i kolegi dr. sc. Ivanu Güttleru koji su me strpljivo učili i navodili u pisanju ovog diplomskog rada. Najveće hvala mojoj mami, na svemu.

U izradi ovog dokumenta korišten je dio rezultata regionalnog klimatskog modela RegCM4 dobivenih u sklopu projekta „Jačanje kapaciteta Ministarstva zaštite okoliša i energetike za prilagodbu klimatskim promjenama te priprema Nacrta Strategije prilagodbe klimatskim promjenama (Broj ugovora: TF/HR/P3-M1-O1-010)" koji se financira sredstvima iz Prijelaznog instrumenta tehničke pomoći EU, a kojem je pristup omogućio Državni hidrometeorološki zavod (DHMZ) kojem se ovim putem zahvaljujem. Zahvalila bih DHMZ-u i na korištenju njihovih mjerenja s traženih mjernih postaja. Pohvalila bih radnu skupinu Svjetskog programa za istraživanje klime o regionalnoj klimi (WCRP; engl. *World Climate Research Programme*) i radnu skupinu za združeno modeliranje (engl. *Coupled Modelling*), bivše koordinacijsko tijelo CORDEX-a (engl. *Coordinated Regional Climate Downscaling Experiment*) i odgovorno povjerenstvo za CMIP5 (engl. *Coupled Model Intercomparison Project, Phase 5*). Također zahvaljujem skupinama za modeliranje klime koje su proizvele i učinile dostupnim svoj model čije rezultate koristim u ovom radu. Pohvaljujem infrastrukturu *Earth SystemGrid* Federacije na međunarodnom naporu predvođenom Programom američkog ministarstva energije za dijagnostiku i usporedbu klimatskih modela, Europskom mrežom za modeliranje zemaljskih sustava i drugim partnerima u Globalnoj organizaciji za znanstvene portale o sustavu Zemlje (GO-ESSP).

Ovaj je rad napravljen u sklopu aktivnosti projekta HRZZ UIP-2017-05-6396 „Klimatske promjene i varijabilnost u Hrvatskoj – od globalnih utjecaja do lokalnih zelenih rješenja" (CroClimGoGreen).

Sažetak

U ovom radu ispitano je buduće stanje klime u pet hrvatskih gradova: Dubrovniku, Zadru, Rijeci, Zagrebu i Osijeku. To je napravljeno analiziranjem klimatskih indeksa *FD*, *ID*, *SU*, *TR*, *DTR* i *ETR* te srednjih, maksimalnih i minimalnih dnevnih temperatura dobivenih klimatskim simulacijama korištenjem dvaju različitih regionalnih klimatskih modela, RegCM4 i SMHI-RCA4 horizontalne rezolucije 12.5 km, u kombinaciji s dva globalna klimatska modela, EC-EARTH i MPI-ESM-MR, za dva različita scenarija buduće klime, RCP 4.5 i RCP 8.5. Uspoređivanjem ovih varijabli u razdoblju 2041. – 2070. god. u odnosu na dosadašnju klimu, iz razdoblja 1991. – 2020. god., uočen je značajan porast srednjih, maksimalnih i minimalnih temperatura u svim korištenim kombinacijama regionalnih i globalnih klimatskih modela za sve promatrane gradove, a najveći je uglavnom u toplom dijelu godine. U Dubrovniku i Rijeci ovaj se porast pokazao najbržim, a zbog malih vrijednosti trendova u rasponu temperatura možemo zaključiti da se minimalne i maksimalne temperature u promatranim gradovima povećavaju podjednakim brzinama. U uvjetima toplije klime u svim se promatranim gradovima povećava broj dana s maksimalnom temperaturom zraka iznad 25 °C (posebice u Dubrovniku) i minimalnom iznad 20 °C (osobito u Rijeci i Zadru). Nadalje, u svim je gradovima dobiveno smanjenje broja dana s maksimalnom i minimalnom temperaturom ispod 0 °C.

Ključne riječi: toplinsko opterećenje gradova, klimatski indeksi, projekcije regionalnih klimatskih modela

Expected heat load of Dubrovnik, Osijek, Rijeka, Zadar and Zagreb based on projections of regional climate models

Abstract

This paper examines the future climate state in five Croatian cities: Dubrovnik, Zadar, Rijeka, Zagreb and Osijek. This was done by analyzing climate indices *FD*, *ID*, *SU*, *TR*, *DTR* and *ETR* and mean, maximum and minimum daily temperatures obtained by climate simulations using two different regional climate models, RegCM4 and SMHI-RCA4, with a horizontal resolution of 12.5 km, combined with two global climate models, EC-EARTH and MPI-ESM-MR, for two different future climate scenarios, RCP 4.5 and RCP 8.5. By comparing these variables for the period 2041-2070 in relation to the current climate, from the period 1991-2020, a significant increase in mean, maximum and minimum temperatures was observed in all used combinations of regional and global climate models for all observed cities, and the largest increase was mainly in the warm part of the year. In Dubrovnik and Rijeka, this increase proved to be the fastest, and due to the small values of trends in the temperature range, we can conclude that the minimum and maximum temperatures in all of the observed cities are increasing at similar rates. In warmer climate conditions, in all observed cities, the number of days with a maximum air temperature above 25 °C increases (especially in Dubrovnik) as well as the number of days with minimum air temperature above 20 °C (especially in Rijeka and Zadar). Furthermore, a reduction in the number of days with maximum and minimum temperatures below 0 °C was obtained in all cities.

Keywords: heat load of cities, climate indices, regional climate model projections

Sadržaj

1. Uvod 1

1.1 Teorijska pozadina 1

1.2 Motivacija i cilj istraživanja; Dosadašnja istraživanja 5

2. Podaci i metode 7

2.1 Projekcija buduće klime 7

2.2 Korekcija pristranosti modela (engl. Bias correction) 8

2.3 Klimatski indeksi 11

2.4 Procjena statističke značajnosti trendova 12

3. Rezultati i diskusija 14

3.1 Srednja temperatura zraka 15

3.2 Maksimalna temperatura zraka 20

3.3 Minimalna temperatura zraka 29

4. Zaključak 44

Popis kratica 47

Literatura 50

Dodatak A: Višegodišnji mjesečni srednjaci 57

Dodatak B: Vremenski nizovi *tas*, *tasmax* i *tasmin* 77

Dodatak C: Vremenski nizovi klimatskih indeksa *FD*, *IF*, *SU*, *TR*, *DTR* i *ETR* 83

1. Uvod

1.1 Teorijska pozadina

Mjerenja na meteorološkim postajama u određenom trenutku pokazuju kakvo je vrijeme, dok analizom podataka prikupljenih dugotrajnim, dugogodišnjim mjerenjima i opažanjima saznajemo kakva je klima. Za proučavanje klime najčešće se promatraju 30-godišnja razdoblja, pa tada klima predstavlja prevladavajuće stanje vremena za određeno mjesto u tom razdoblju.

Na globalnoj razini klima je određena bilancom zračenja koja je rezultat svih oblika primljene i izgubljene energije elektromagnetskog zračenja, dok su na manjim prostornim skalama klimatske karakteristike određenih područja na Zemlji prvenstveno određene njihovim geografskim položajem (zbog toga što je Zemlja sfernog oblika pa intenzitet Sunčevog zračenja koje dolazi do površine ovisi o geografskoj širini).

U širem smislu, klima se odnosi na srednje stanje klimatskog sustava koji je sastavljen od atmosfere, hidrosfere, kriosfere, tla i biosfere te njihovog međudjelovanja. Klima u užem smislu predstavlja prosječne vremenske prilike izražene pomoću srednjaka, ekstrema i varijabilnosti klimatskih veličina, kao što su primjerice prizemna temperatura zraka, oborina i vjetar, u dužem razdoblju.

Klima se, osim prostorno, mijenja i u vremenu. Ako postoje statistički značajne promjene srednjeg stanja klime ili varijabilnosti klimatskih parametara (i drugih statističkih veličina koje opisuju stanje klime) koje traju desetljećima i duže, možemo reći da je došlo do klimatske promjene. Do ovakvih promjena može doći zbog raznih prirodnih i/ili antropogenih utjecaja. Od velikog interesa su promjene klime izazvane ljudskim aktivnostima (antropogeni utjecaj) jer njima u atmosferu dolaze tzv. staklenički plinovi (npr. vodena para, ugljikov dioksid, metan, didušikov oksid, ozon) koji imaju ključnu ulogu u zagrijavanju atmosfere. Zemljina atmosfera propušta većinu kratkovalnog zračenja sa Sunca tako da ono može doći do površine Zemlje, a budući da se ta površina zagrijava Sunčevim zračenjem, ona emitira dugovalno zračenje natrag prema svemiru.

Stakleнički plinovi u atmosferi apsorbiraju dio dugovalnog zračenja sa Zemlje čime se atmosfera zagrijava. Od početka industrijske revolucije u drugoj polovici 18. stoljeća količina ovih stakleničkih plinova u atmosferi povećava se i uzrokuje sve jače zagrijavanje Zemlje. U posljednjem IPCC izvještaju iz 2021. godine pokazana je približno linearna veza između kumulativnih emisija CO_2 i porasta globalne površinske temperature kroz povijest, što možemo očekivati i u budućnosti (slika 1.1.1).

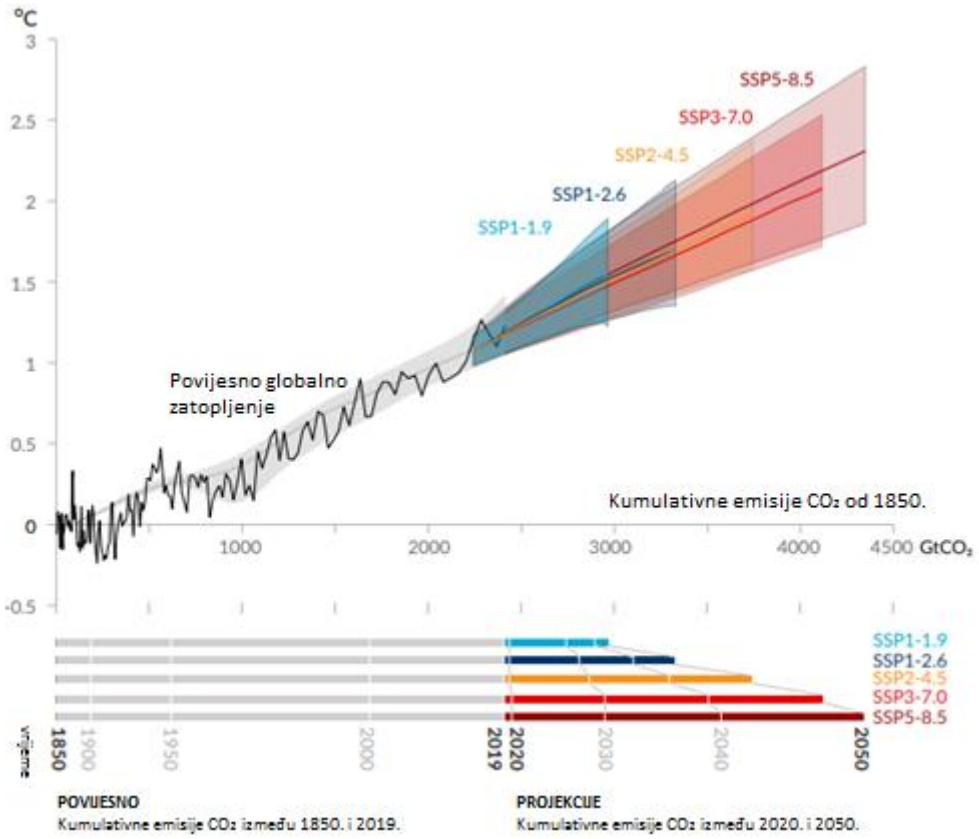

Slika 1.1.1: Približno linearna veza između kumulativnih emisija CO_2 i porasta globalne površinske temperature (preuzeto iz IPCC, 2021).

Prema svim dosadašnjim pokazateljima, to je zagrijavanje posljedica antropogenog utjecaja (IPCC, 2021). Većina ljudi na Zemlji živi u gradovima, oko 55 % (prema izvješću Državnog zavoda za statistiku Republike Hrvatske iz 2020. godine, u Hrvatskoj i više od 55 %), i ovo je brojka koja raste iz dana u dan, te se do 2050. godine očekuje da će oko 68 % ukupne populacije Zemlje živjeti u gradovima (UN, 2018.). Iako razvoj tih gradova ljudima omogućava brojne pogodnosti kao što je povećanje životnog standarda, urbani razvoj

mijenja obilježja Zemljine površine pa time i atmosfere. Dolazi do promjena u ravnoteži zračenja i preraspodjele topline i vode, pa se u urbanim sredinama javljaju neke negativne posljedice kao što je to npr. stvaranje urbanih toplinskih otoka, UHI (engl. *Urban Heat Island*). Urbani toplinski otok je efekt kojeg karakterizira bitno viša temperatura zraka u urbanom području u odnosu na okolno ruralno područje (Wong, Lai i Hart, 2016.). Kako globalna temperatura raste, tako su sve izraženiji i problemi vezani uz pojavu toplinskih valova kao i njihov nepoželjan utjecaj na ljude (Founda i Santamouris, 2017.).

U svrhu predviđanja budućih klimatskih uvjeta koriste se različiti klimatski modeli (globalni i regionalni) pomoću kojih se vrše numeričke simulacije buduće klime za određene klimatske scenarije. Klimatski scenarij je vjerojatni prikaz budućih klimatskih faktora napravljen za istraživanje posljedica antropogenog utjecaja na klimatski sustav. Ovaj scenarij, uz ljudski faktor, uključuje i prirodnu klimatsku varijabilnost, a temelji se na opsežnim procjenama sila forsiranja, emisijama plinova, alternativnim pristupima modeliranju i povratnim informacijama (Jakovčić, 2012). Primjerice, klimatski scenariji tipa RCP (*Representative Concentration Pathways*, Reprezentativne trajektorije koncentracija) zapravo su scenariji krivulje koncentracije stakleničkih plinova koje objavljuje Međuvladino tijelo za klimatske promjene, IPCC (engl. *Intergovernmental Panel on Climate Change*), a označavaju se brojem koji označava dodatno zagrijavanje u vatima po kvadratnom metru (W/m^2) koje se očekuje 2100. god. Očekivani porast srednje globalne temperature prema scenariju RCP 1.9 je ispod 1.5 °C i on predstavlja najbolji scenarij. RCP 2.6 je cilj prvotno dogovoren Pariškim sporazumom (UN, 2016), a bio bi ostvariv uz strogo poštivanje mjera za smanjenje emisija stakleničkih plinova. Točnije, u ovom scenariju bi se razina emisija CO_2 trebala početi smanjivati od 2020. na način da se ona spusti na nulu do 2100. god., emisija metana bi trebala biti upola manja od one u 2020. god., a emisija sumporovog dioksida pasti na otprilike 10 % od one količine koja je bila u razdoblju od 1980. – 1990. Scenarij RCP 3.4. je srednje rigorozan scenarij u kojem se također očekuje značajno smanjenje koncentracije stakleničkih plinova (tzv. „negativna emisija“). Scenarij RCP 4.5 predstavlja manje rigorozan scenarij, u njemu bi emisija stakleničkih plinova rasla do njihovog maksimuma oko 2040. god. i nakon toga bi se počela

smanjivati. U ovom scenariju bi se razina emisija CO_2 trebala početi smanjivati barem od 2045., kako bi do 2100. god. njegova razina bila upola manja od one koja bi bila 2050. god. Razina metana trebala bi prestati rasti barem do 2050. god. i pasti na 75 % one količine koja bi bila u 2040. godini, dok bi emisija sumporovog dioksida pala na otprilike 20 % od one koja je bila između 1980. i 1990. god. RCP 6.0 je scenarij u kojem bi emisija stakleničkih plinova rasla do njihovog maksimuma oko 2080. god. i nakon toga bi se počela smanjivati. Postoji i scenarij RCP 7 koji označava osnovni ishod, odnosno ishod u kojemu bi emisije stakleničkih plinova ostale takve kakve jesu. RCP 8.5 je scenarij u kojem bi emisija stakleničkih plinova rasla kroz cijelo 21. stoljeće i on predstavlja najgori mogući scenarij. Dakle, scenariji RCP 1.9, 2.6, 3.4, 4.5 i 6.0 predstavljaju različite ciljeve ublažavanja učinaka globalnog zatopljenja, dok su scenariji RCP 7 i 8.5 ishodi koji bi nas mogli dočekati, ako se ne poduzmu mjere za ublažavanje (Hausfather, 2018).

Kako bi se uočio utjecaj ovih klimatskih scenarija na samu klimu koriste se klimatski modeli. Klimatski modeli uzimaju u obzir dolazno kratkovalno zračenje sa Sunca (uglavnom vidljivo i infracrveno) i izlazno dugovalno zračenje sa Zemlje, a neuravnoteženosti se očituju u promjeni temperature. Za prikaz komponenata klimatskog sustava i njihovih međudjelovanja koriste se globalni klimatski modeli (GCM). Oni se sastoje od modela opće cirkulacije atmosfere i/ili oceana, modela tla i leda te su uključeni ciklusi ugljika i sumpora. Sam se model temelji na zakonima fizike prikazanim matematičkim jednadžbama kao što su npr. Navier-Stokesove jednadžbe i termodinamičke jednadžbe koje opisuju procese u pojedinim komponentama klimatskog sustava uzimajući u obzir i njihova međudjelovanja. Ovakve jednadžbe, uz komponente morskog leda i tipa površine kopna, predstavljaju osnovu računalnih programa globalnih klimatskih modela. Konvekcija vlage i oblaci se pak odvijaju na puno manjoj skali od one globalnog modela pa se njihovo prisustvo u model uključuje u obliku parametrizacija. U klimatskom modelu Zemlja je podijeljena na trodimenzionalne ćelije (engl. *grid cell*). Jednadžbe koje definiraju npr. gibanje, očuvanje mase, energije i vlage diskretiziraju se (npr. korištenjem metode konačnih razlika ili spektralnim metodama) i rješavaju u svakoj ćeliji, a dobivena rješenja odnose se na cijelo područje koje ona obuhvaća. Ukupan broj

ćelija na površini Zemlje definira razlučivanje (rezoluciju) modela – što ih je više, to model ima veće razlučivanje. Obično je rezolucija u horizontalnoj ravnini 150 – 200 km u umjerenoj širini, dok je po vertikalnoj osi atmosfera podijeljena na slojeve (obično 30-ak slojeva) čije je razlučivanje veće pri površini nego u višim slojevima atmosfere. U klimatskim modelima je, osim prostorne diskretizacije, i vrijeme integracije modela diskretizirano, podijeljeno je na korake. Kako bi model započeo sa simulacijama, potrebno je zadati početno stanje komponenata klimatskog sustava, a zatim se jednadžbama računaju vrijednosti varijabli u sljedećem vremenskom koraku (npr. u sljedećih 10 min) što se dalje ponavlja sve dok se simulacije ne završe.

Budući da globalni klimatski modeli obuhvaćaju cijelu Zemlju i njihova je rezolucija još uvijek gruba, radi se dinamička prilagodba manjim skalama (engl. *dynamical downscaling*) – napravljeni su regionalni klimatski modeli (RCM) s ciljem pružanja informacija na finim skalama, manjim od onih GCM-a koje su prikladnije za proučavanje regionalnih pojava. Ovo se radi tzv. ugnježđivanjem. GCM opisuje učinak procesa velikih skala i njega koristimo kao rubne uvjete za regionalne klimatske modele koji pak uzimaju u obzir i procese manjih skala kao što su mezoskalni procesi, kompleksna topografija, obala itd. (Giorgi i sur., 2012). Globalni i regionalni klimatski modeli stalno se razvijaju kako bi mogli dati što zorniji prikaz klime. Trenutno je RegCM4 (Giorgi i sur., 2012) jedna od posljednjih verzija regionalnog klimatskog modela koja se može koristiti za bilo koji dio Zemlje na rezoluciji do oko 10 km (hidrostatički limit), njena dinamička jezgra je temeljena na jednadžbama prema Güttler i sur. (2017), a još sadrži i razne parametrizacije fizike, alate za predobradu i naknadnu obradu podataka (Güttler i sur., 2017). Slično modelu RegCM4, napravljen je i regionalni klimatski model SMHI-RCA4 (SMHI, 2011). Klimatski se modeli često koriste u praćenju klimatskih promjena i predviđanju budućeg stanja klime na nekom području.

1.2 Motivacija i cilj istraživanja; Dosadašnja istraživanja

Klimatske promjene donose jače zagrijavanje površine Zemlje na regionalnoj skali koje pospješuje intenzitet, frekvenciju i trajanje toplinskih valova u Europi (Beniston i sur., 2007). S obzirom na to da se Hrvatska nalazi u području jugoistočne Europe i Mediterana koje je prema posljednjem izvještaju IPCC-ja

(IPCC, 2021.) jedno od najranjivijih područja u Europi s obzirom na učinke klimatskih promjena, našla se u središtu raznih istraživanja. Većina nedavnih istraživanja (npr. IPCC, 2021) napravljena je za jedno veće područje (Europa ili jedan njen dio kao što je područje Mediterana, Alpe ili na području države), te se rezultati prikazuju u odnosu na davna povijesna razdoblja (najčešće 1961. – 1990. god. ili 1971. – 2000. god.).

Cilj ovog rada jest procijeniti kakvi će biti klimatski uvjeti u budućnosti u hrvatskim gradovima: Dubrovniku, Zadru, Rijeci, Zagrebu i Osijeku uspoređivanjem podataka srednje, maksimalne i minimalne dnevne temperature zraka iz dva vremenska razdoblja, P0 i P2. Podaci iz razdoblja P0 su oni iz bliske prošlosti – to referentno razdoblje ovdje je definirano kao 1991. – 2020. god., za razliku od mnogih istraživanja koja koriste drugačije (zastarjele) definicije, a promatra se odstupanje podataka iz budućnosti, (razdoblje P2): 2041. – 2070. god. u odnosu na razdoblje P0. Obzirom da su gradovi podložni efektu urbanih toplinskih otoka nije promatrano cijelo područje Republike Hrvatske (RH) već navedenih pet gradova s različitim geografskim i klimatskim obilježjima za klimatske scenarije RCP 4.5 i RCP 8.5.

Na temelju dosadašnjih istraživanja u Hrvatskoj se očekuje porast srednje, minimalne i maksimalne temperature te jači, češći i duži temperaturni ekstremi (Branković i sur., 2017), pa možemo očekivati da će i na razini gradova rezultat biti pozitivni trendovi.

2. Podaci i metode

2.1 Projekcija buduće klime

U ovom radu korišteni su izlazni podaci dvaju regionalnih klimatskih modela iz Koordiniranog eksperimenta regionalne klime dinamičkom prilagodbom (CORDEX), RegCM4 i SMHI-RCA4, s korakom mreže od 12.5 km, forsiranih s po dva različita GCM-a iz Pete generacije projekata međusobne usporedbe klimatskih modela, CMIP5 (engl. *Coupled Model Intercomparison Project, Phase 5*): EC (EC-EARTH; https://www.ec-earth.org/index.php/about) i MP (MPI-ESM-MR;http://www.mpimet.mpg.de/en/science/models/mpi-esm).

Korišteni regionalni klimatski modeli razlikuju se u broju vertikalnih nivoa te raznim shemama i parametrizacijama danih u tablici 2.1.1.

Tablica 2.1.1: Osnovne karakteristike regionalnih klimatskih modela RegCM4 i SMHI-RCA4 (Srnec, Gašparac i Güttler, 2019).

Regionalni klimatski model		**RCA4**	**RegCM4**
Institucija		**SMHI**	**DHMZ**
Karakteristike	Broj vertikalnih nivoa	40	23
	Atmosferski granični sloj	Cuxart i sur. 2000	Holtslag i sur. 1990
	Konvekcija	Kain i Fritsch 1990, 1993; Kain 2004; Jones i Sanchez 2002	Grell 1993
	Mikrofizika oborine	Rasch i Kristijansson 1998	Pal i sur. 2000
	Zračenje	Savijärvi 1990; Sass i sur. 1994	Kiehl i sur. 1996.
	Procesi na površini i u tlu	Samuelsson i sur. 2006	Dickinson i sur. 1993

Valja napomenuti da su ćelije modela pri površini Zemlje u modelu RegCM4 ili sastavljene od kopna ili od mora, što može rezultirati u većim odstupanjima ako se promatraju priobalna područja. U modelu SMHI-RCA4 su ćelije modela pri površini Zemlje sastavljene od određenog postotka kopna i mora (znači da možemo imati ćeliju sastavljenu od npr. 25 % mora i 75 % kopna), što daje preciznije rezultate za priobalna područja. Rezultati modela RegCM4 preuzeti su iz repozitorija Državnog hidrometeorološkog zavoda (DHMZ) (MZOE, 2017), a rezultati SMHI-RCA4 preuzeti su iz baze podataka Copernicus (Copernicus, 2018). Za razdoblje od 1991. do 2005. godine korištene su izmjerene vrijednosti koncentracija stakleničkih plinova, dok su za razdoblje od 2006. do 2070. godine korišteni scenariji koncentracija RCP 4.5 i RCP 8.5. Referentno razdoblje (P0) ovdje je definirano kao razdoblje između 1991. – 2020. godine, tako da ono predstavlja kombinaciju povijesnih (1991. – 2005.) i modeliranih podataka (2006. – 2020.), a promatra se klima u budućnosti, odnosno u razdoblju P2 (2041. – 2070.) dobivena iz navedenih kombinacija GCM i RCM. Razdoblje između razdoblja P0 i P2 naziva se P1 i odnosi se na razdoblje između 2021. – 2040. god. Rezultati ovih klimatskih modela promatrani su za pet hrvatskih gradova smještenih u različitim dijelovima zemlje: Dubrovnik, Zadar, Rijeka, Zagreb i Osijek, za njih su analizirani podaci srednje (*tas*), maksimalne (*tasmax*) i minimalne (*tasmin*) dnevne temperature zraka na 2 m visine. S obzirom na to da u klimatskom modelu postoji konačan broj točaka mreže, od kojih se svaka nalazi na određenoj geografskoj širini i dužini te svaka točka označava sredinu jedne ćelije modela, ove točke ne podudaraju se nužno s koordinatama promatranih gradova, već se za svaki grad promatrao „najbliži susjed“, odnosno svakom gradu je dodijeljena točka (središte ćelije) koja mu je najbliže. Kombinacija jednog RCM-a, jednog GCM-a i jednog scenarija RCP predstavlja jednu projekciju buduće klime.

2.2 Korekcija pristranosti modela (engl. Bias correction)

Realna situacija nije savršeno reprezentirana klimatskim modelima, odnosno postoje sustavna odstupanja između modeliranih i opaženih vrijednosti neke

varijable. Jedan od izvora nepouzdanosti je taj što je u modelu atmosfera reprezentirana konačnim brojem varijabli, a dodatna nepouzdanost proizlazi i iz shema parametrizacije te iz samog izbora parametara modela (Ho i sur., 2012). Upravo iz ovih razloga je bitno napraviti prilagodbu modeliranih podataka mjerenjima. U ovom radu prilagodba je napravljena metodom korekcije pristranosti modela (engl. *bias correction)*. Ovakva prilagodba modeliranih podataka mjerenjima predstavlja i jednu vrstu prilagodbe manjim skalama (engl. *downscaling*) zato što neka svojstva – kao na primjer topografija s efektima zasjenjivanja i usmjeravanja vjetra, obližnja jezera ili obale te iskorištenost zemljišta – nisu uključena u klimatske modele, odnosno to su procesi koje model ne može razlučiti (Met Office, 2018).

Metoda korekcije pristranosti modela predstavlja pronalaženje matematičke veze između modeliranih i mjerenih podataka koji su nam poznati kako bismo dobili informaciju o mogućim opaženim vrijednostima podataka u budućnosti, tj. kako bismo iz modeliranih podataka za budućnost dobili vrijednosti što bliže onima koje će biti opažene.

Postoje razne vrste ove metode – npr. linearno skaliranje, skaliranje varijance, mapiranje kvantila (Teutschbein i Seibert, 2012). U ovom radu napravljeno je mapiranje kvantila, što predstavlja metodu koja održava distribuciju očuvanom i daje informacije o ekstremnim vrijednostima. Neka X_0 predstavlja izmjerene, opažene vrijednosti neke varijable iz referentnog perioda (u prošlosti ili sadašnjosti), a X_m modelirane vrijednosti te varijable za isto razdoblje. Neka $X_0{}'$ predstavlja opažene, a $X_m{}'$ modelirane vrijednosti te varijable u nekom vremenu u budućnosti. Cilj je naći matematičku vezu između distribucija X_0 i X_m te pretpostaviti da ista ta veza vrijedi i između distribucija $X_0{}'$ i $X_m{}'$. Ovo omogućava nalaženje $X_0{}'$ na temelju poznatih X_0, X_m i $X_m{}'$:

$$X_0' = B(X_m'), \tag{2.2.1}$$

s funkcijom transfera $B(X_m')$:

$$B(X_m') = F_0^{-1}[F_m(X_m')], \tag{2.2.2}$$

gdje $F_m(.)$ predstavlja kumulativnu funkciju distribucije od X_m, a $F_o^{-1}(.)$ inverznu kumulativnu funkciju distribucije, tzv. funkciju kvantila, od X_o. Kumulativna funkcija vjerojatnosti predviđenih budućih opažanja tada je dana s:

$$F_{o'}(x) = F_o F_m^{-1}[F_{m'}(x)] \tag{2.2.3}$$

Dakle, metoda mapiranja kvantila nalazi matematičku vezu između modeliranih i mjerenih podataka iz prošlosti (ili sadašnjosti) te pretpostavlja tu istu vezu i u budućnosti. Drugim riječima, pretpostavlja se da su izvori pristranosti u budućnosti istovjetni onima u prošlosti.

Ovakva prilagodba napravljena je na mjesečnoj razini što znači da su uzeti opaženi i modelirani podaci iz određenog razdoblja posebno za svaki mjesec (tj. posebno za siječanj, posebno za veljaču itd.), tako da se po definiciji mjesečni srednjaci modeliranih podataka ispravljeni ovom metodom podudaraju s mjesečnim srednjacima izmjerenih vrijednosti.

Za početak su modelirane vrijednosti iz razdoblja P0 odvojene po mjesecima i sortirane uzlazno po vrijednosti. Isto je napravljeno i za opažene, odnosno mjerene vrijednosti iz razdoblja P0. Napravljeni su *q-q* dijagrami kojima su na os x postavljene modelirane, a na os y opažene vrijednosti i napravljena je linearna regresija, odnosno izračunati su članovi a i b iz jednadžbe pravca $y = ax + b$. Množenjem modeliranih vrijednosti iz razdoblja P0, P1 i P2 s a i dodavanjem člana b dobiveni su ispravljeni, tj. prilagođeni podaci iz modela uzimajući u obzir da je pretpostavljen istovjetan odnos i u budućnosti. Tako ispravljeni podaci kasnije se koriste u svim proračunima i analizama u ovom radu.

Nakon što je ovakva korekcija pristranosti modela napravljena za sve korištene projekcije buduće klime, odnosno za sve varijable (srednje, maksimalne i minimalne temperature zraka na 2 m visine), izračunati su i višegodišnji mjesečni srednjaci za njih u razdobljima P0 i P2 te su ove krivulje prikazane na istim dijagramima radi usporedbe. Izračunata je i razlika višegodišnjih mjesečnih srednjaka između podataka ova dva razdoblja za sve projekcije buduće klime. Zatim su prikazani vremenski nizovi varijabli kroz

cijelo promatrano razdoblje, 1991. – 2070., za koje su izračunati linearni trendovi izraženi u °C/10 god. i prikazani na karti Republike Hrvatske.

2.3 Klimatski indeksi

U ovom su radu izračunati i godišnji klimatski indeksi: *FD, ID, SU, TR, ETR* i *DTR*, njihovi srednjaci te im je određen pripadajući linearni trend.

Indeks *FD* (engl. *Frost Days*) predstavlja broj dana u godini pogodnih za razvoj mraza. Ako je TN_{ij} minimalna dnevna temperatura na *i*-ti dan u *j*-toj godini, onda je indeks *FD* definiran kao broj dana za koje vrijedi

$$TN_{ij} < 0°C \tag{2.3.1}$$

Slično indeksu *FD*, indeks *ID* (engl. *Icing Days*) predstavlja broj ledenih dana unutar godine. Neka je TX_{ij} maksimalna dnevna temperatura na *i*-ti dan u *j*-toj godini. Tada je *ID* jednak broju dana za koje vrijedi

$$TX_{ij} < 0°C \tag{2.3.2}$$

Indeks *SU* (engl. *Summer Days*) predstavlja broj ljetnih dana u godini. Definiran je kao broj dana u kojem je maksimalna dnevna temperatura veća od 25 °C:

$$TX_{ij} > 25°C \tag{2.3.3}$$

Indeks *TR* (engl. *Tropical Nights*), odnosno broj tropskih noći u godini kaže koliko je bilo dana s minimalnom dnevnom temperaturom većom od 20 °C:

$$TN_{ij} > 20°C \tag{2.3.4}$$

Indeks *DTR* (engl. *Daily Temperature Range*) predstavlja godišnji srednjak raspona dnevnih ekstremnih temperatura, definiran je kao omjer sume razlika maksimalne i minimalne temperature na *i*-ti dan u godini *j* i broja dana *I* u godini *j*, odnosno

$$DTR_j = \frac{\sum_{i=1}^{I}\left(TX_{ij} - TN_{ij}\right)}{I} \tag{2.3.5}$$

Indeks *ETR* (engl. *Extreme Temperature Range*) predstavlja raspon godišnjih ekstremnih temperatura, odnosno razliku godišnje maksimalne temperature

TXx u godini *k* i godišnje minimalne temperature *TNn* za isti mjesec (Climdex, 2021):

$$ETR_k = TXx_k - TNn_k \tag{2.3.6}$$

Ovdje valja napomenuti da se minimalna dnevna temperatura zraka obično javlja prije izlaska Sunca, između 05:00 i 07:00 h ujutro. Nakon izlaska Sunca temperatura raste, a maksimum se postiže obično između 14:00 i 15:00 h u sunčanim uvjetima. Nakon zalaska Sunca temperatura se smanjuje i kroz noć se spušta ponovno do minimuma prije izlaska Sunca. Prema tome, minimalna temperatura uglavnom nam daje informaciju o temperaturi netom prije izlaska Sunca, a maksimalna o temperaturi tijekom najtoplijeg dijela dana (Zaninović i sur., 2008).

2.4 Procjena statističke značajnosti trendova

Zadnji korak bio je procijeniti statističku značajnost izračunatih trendova. Za procjenu statističke značajnosti trendova korišten je Mann-Kendallov test (Mann, 1945; Kendall, 1975; Gilbert, 1987) kojim su računate *p*-vrijednosti, a provjerena je statistička značajnost trendova na nivou značajnosti od 95 %.

Test započinje postavljanjem dviju hipoteza: H_o koja kaže da u podacima ne postoji trend i H_a koji govori da u podacima postoji trend koji može biti pozitivan ili negativan. Pretpostavlja se da je H_o istinit, a ta se tvrdnja odbacuje tek ako trend uvjerljivo postoji iznad određene granice sumnje. Podaci trebaju biti sortirani kronološki, npr. $x_1, x_2, \ldots, x_n$ gdje indeksi $1, 2, \ldots, n$ označavaju vrijeme. Računa se Mann-Kendallov rezultat *S* kao

$$S = \sum_{k-1}^{n-1} \sum_{j-k+1}^{n} sgn(x_j - x_k), \qquad j > k, \tag{2.4.1}$$

gdje funkcija $sgn(x_j - x_k)$ predstavlja indikator koji poprima vrijednosti 1, 0 ili -1. Primjerice, ako je $sgn(x_j - x_k) = 1$, to znači da je razlika $x_j - x_k > 0$, odnosno da je vrijednost podatka u vremenu *j* veća od one u vremenu *k*. Dakle

pozitivan *S* govori da su vrijednosti podataka dobivenih u kasnijim trenucima obično veće od onih iz ranijeg vremena, a negativan *S* da su vrijednosti iz ranijeg vremena veće. Nakon toga računa se varijanca Mann-Kendallovog rezultata *VAR(S)*:

$$VAR(S) = \frac{1}{18}\left[n(n-1)(2n+5) - \sum_{u-1}^{g} t_u(t_u-1)(2t_u+5)\right] \tag{2.4.2}$$

Ovdje g predstavlja broj grupa podataka s istim vrijednostima, a t_u je broj podataka u u-toj grupi. Sljedeće što se računa jest statistika Mann-Kendall-ovog testa, Z_{MK}:

$$Z_{MK} = \begin{cases} \dfrac{S-1}{\sqrt{VAR(S)}} & ako\ je\ S > 0 \\ 0 & ako\ je\ S = 0 \\ \dfrac{S+1}{\sqrt{VAR(S)}} & ako\ je\ S < 0 \end{cases} \tag{2.4.3}$$

Pozitivna vrijednost Z_{MK} govori da se vrijednosti podataka povećavaju s vremenom, a negativna da se smanjuju. Hipoteza H_o se odbacuje i prihvaća se H_a ako vrijedi $|Z_{MK}| \geq Z_{1-\alpha/2}$, gdje je $Z_{1-\alpha/2}$ 100(1-α/2)-ti percentil standardne normalne distribucije, a α faktor greške tipa 1 za kojeg vrijedi $0 < \alpha < 0.5$. Faktor pogreške α predstavlja nivo značajnosti testa, odnosno toleriranu vjerojatnost da će Mann-Kendallov test pogrešno odbaciti H_o hipotezu i on se u ovom slučaju odabire u navedenom intervalu. Trend je statistički značajan na nekom nivou značajnosti α kad je njegova p-vrijednost manja od α, odnosno trend je statistički značajan ako $p < \alpha$ (SPC for Excel, 2017). S obzirom na to da se u ovom radu provjerava statistička značajnost trendova na nivou značajnosti od 95 %, možemo reći da je trend statistički značajan ako $p < 0.05$.[1]

[1] Za obradu i prikaz podataka korišteni su skup računalnih operatora CDO (eng. *Climate Data Operators*; https://code.mpimet.mpg.de/projects/cdo/) i programski paket Python (Anaconda; https://www.anaconda.com/).

3. Rezultati i diskusija

Prije početka same analize podataka napravljena je provjera podataka s ciljem provjeravanja njihove kvalitete, gdje je otkriveno nekoliko grešaka u izlaznim podacima RegCM4 modela u kombinaciji s EC globalnim klimatskim modelom za varijablu *tas* u oba scenarija. Riječ je o nekoliko izoliranih vrijednosti srednje temperature s nefizikalnim iznosima koje su izostavljene iz analize i umjesto kojih je napravljena linearna interpolacija. Također, u setu izmjerenih podataka nedostajalo je nekoliko dana mjerenja iz Rijeke, te nekoliko mjeseci mjerenja iz Osijeka (koji se podudaraju s ratnim razdobljem, odnosno dijelom Domovinskog rata), a koji su za potrebe korekcije pristranosti modela izuzeti iz analize zajedno sa svojim parom modeliranih vrijednosti. Nakon ove pripreme napravljena je korekcija pristranosti modela, odnosno modelirane vrijednosti srednjih, maksimalnih i minimalnih temperatura prilagođene su mjerenjima. Ovako ispravljeni podaci koriste se u svim daljim proračunima i analizama u ovom radu. Korekcijom pristranosti modela dobiveni su dijagrami odnosa modeliranih i mjerenih podataka iz razdoblja P0 s pravcima linearnih regresija. S obzirom na to da se korekcija pristranosti modela radila posebno za svaki od pet gradova, svaki od dva RCM-a, svaki od dva GCM-a, za svaki od dva scenarija, za svaku od ukupno tri varijable i svaki od 12 mjeseci ukupno je dobiveno $5 \cdot 2 \cdot 2 \cdot 2 \cdot 3 \cdot 12 = 1440$ dijagrama. Ovi dijagrami prikazani su na ukupno 60 slika danih u digitalnom prilogu „Pristranost“. Na tim dijagramima vidljiva su neka odstupanja točaka od pravca linearne regresije što se uglavnom pojavljuju samo za najviše i najniže vrijednosti temperatura u nekom mjesecu, ali podudaranje mjerenih i modeliranih vrijednosti je uglavnom vrlo dobro. Može se zaključiti da kombinacija odabranih regionalnih i globalnih klimatskih modela ima dovoljno dobre performanse za daljnju analizu podataka.

Nakon korekcije pristranosti modela izračunati su višegodišnji mjesečni srednjaci varijabli, njihova razlika između razdoblja P2 i P0, a potom su nacrtani vremenski nizovi varijabli s pravcima linearnih trendova i izračunatim trendovima izraženim u °C/10 god., kasnije prikazanih i na kartama Hrvatske (slike 3.1.1, 3.1.2, 3.2.1, 3.2.2, 3.3.1 i 3.3.2). Ovdje se može primijetiti da

korištenje GCM EC daje manje razlike u trendu *tas*, *tasmax* i *tasmin* između dva scenarija. Nakon toga su izračunati navedeni klimatski indeksi te je analogna analiza provedena i za njih. Nacrtani su njihovi vremenski nizovi s ucrtanim linearnim trendovima i izračunatim trendovima izraženim u °C/10 god. koji su zatim prikazani na kartama Hrvatske (slike 3.2.3, 3.2.4, 3.2.5, 3.2.6, 3.3.3, 3.3.4, 3.3.5, 3.3.6, 3.1, 3.2, 3.3 i 3.4). Na vremenskim nizovima varijabli i klimatskih indeksa su pravci trendova koji su prošli Mann-Kendallov test označeni punom linijom, a oni koji nisu označeni su isprekidanom crtom. Na prikazima linearnih trendova na kartama Hrvatske postaje za koje je trend indeksa prošao Mann-Kendallov test značajnosti označene su zvjezdicom, dok postaje za koje trend nije prošao test značajnosti ta oznaka nije prikazana. Niže slijedi diskusija dobivenih rezultata po varijablama.

3.1 Srednja temperatura zraka

Pogledamo li slike A1 a) – A10 a), odnosno prikaz višegodišnjih mjesečnih srednjaka, očekivano možemo uočiti porast srednjih mjesečnih temperatura iz razdoblja P2 u odnosu na razdoblje P0 u oba scenarija, za sve kombinacije klimatskih modela. Ovaj je porast uglavnom nešto veći za scenarij RCP 8.5 nego za RCP 4.5. Kako bismo saznali u kojim mjesecima možemo očekivati najveće povećanje temperature, gledamo prikaze razlika višegodišnjih mjesečnih srednjaka iz razdoblja P2 i P0, sa slika A1 b) – A10 b). Sa slika A1 – A10 možemo uočiti da razne kombinacije RCM-a i GCM-a daju različite rezultate, odnosno postoje određena odstupanja između rezultata koje daju različite kombinacije modela. Primjerice, na slici A1 vidimo da kombinacija RegCM4-EC daje najveće povećanje srednje temperature zraka u rujnu, a RegCM4-MP u ožujku za grad Dubrovnik, dok kombinacija SMHI-EC pokazuje najveći porast srednje temperature u svibnju, a SMHI-MP u lipnju (slika A2). Ovi su rezultati sistematski prikazani u tablici 3.1.1 za scenarij RCP 4.5 odnosno u tablici 3.1.2 za scenarij RCP 8.5. Unatoč razlici među kombinacijama regionalnih i globalnih klimatskih modela, u većini slučajeva najveća se povećanja srednje temperature zraka pokazuju u toplim dijelovima godine.

Tablica 3.1.1: Mjeseci s najvećim porastom temperature u scenariju RCP 4.5 i razlika višegodišnjih mjesečnih srednjaka iz razdoblja P2 u odnosu na razdoblje P0.

RCP 4.5		Dubrovnik	Osijek	Rijeka	Zadar	Zagreb
tas	RegCM4-EC	IX., 1.76 °C	VII., 2.18 °C	VIII., 2.12 °C	IX., 1.99 °C	VII., 2.27 °C
	RegCM4-MP	III., 2.34 °C	VII., 1.87 °C	III., 2.31 °C	III., 1.99 °C	VII., 1.97 °C
	SMHI-EC	V., 1.93 °C	VIII., 1.83 °C	VI., 1.89 °C	V., 1.55 °C	VIII., 2.04 °C
	SMHI-MP	VI., 1.85 °C	VI., 2.44 °C	VI., 2.06 °C	VI., 1.51 °C	VI., 2.34 °C
tasmax	RegCM4-EC	VII., 1.67 °C	VII., 2.37 °C	VIII., 2.10 °C	VIII., 1.88 °C	VII., 2.36 °C
	RegCM4-MP	III., 2.23 °C	VII., 1.85 °C	III., 2.37 °C	III., 2.21 °C	III., 1.88 °C
	SMHI-EC	V., 1.98 °C	VIII., 1.84 °C	VIII., 1.98 °C	V., 1.64 °C	VIII., 2.15 °C
	SMHI-MP	VI., 1.86 °C	VI., 2.58 °C	VI., 2.15 °C	VI., 1.64 °C	VI., 2.53 °C
tasmin	RegCM4-EC	VIII., 1.84 °C	VII., 2.12 °C	VIII., 2.06 °C	IX., 2.04 °C	VII., 2.21 °C
	RegCM4-MP	III., 2.43 °C	VII., 2.02 °C	III., 2.26 °C	III., 2.00 °C	VII., 2.09 °C
	SMHI-EC	V., 1.71 °C	VIII., 1.58 °C	VI., 1.87 °C	VI., 1.39 °C	VIII., 1.75 °C
	SMHI-MP	VI., 1.80 °C	XII., 2.02 °C	VIII., 1.82 °C	VII., 1.54 °C	XII., 1.83 °C

Tablica 3.1.2: Mjeseci s najvećim porastom temperature u scenariju RCP 8.5 i razlika višegodišnjih mjesečnih srednjaka iz razdoblja P2 u odnosu na razdoblje P0.

RCP 8.5		Dubrovnik	Osijek	Rijeka	Zadar	Zagreb
tas	RegCM4-EC	IV., 2.39 °C	IV., 2.65 °C	IV., 2.51 °C	X., 2.38 °C	IV., 2.43 °C
	RegCM4-MP	II., 3.53 °C	II., 3.30 °C	II., 3.55 °C	II., 2.99 °C	II., 3.43 °C
	SMHI-EC	IX., 1.75 °C	X., 1.99 °C	IX., 2.39 °C	IX., 1.83 °C	VIII., 2.18 °C
	SMHI-MP	VI., 2.83 °C	VI., 3.06 °C	IX., 2.54 °C	VI., 2.20 °C	VI., 2.76 °C
tasmax	RegCM4-EC	IV., 2.63 °C	IV., 2.93 °C	IV., 2.62 °C	IV., 2.37 °C	IV., 2.59 °C
	RegCM4-MP	II., 3.23 °C	II., 3.42 °C	II., 3.56 °C	II., 2.62 °C	II., 3.53 °C
	SMHI-EC	IX., 1.78 °C	VIII., 1.86 °C	IX., 2.61 °C	IX., 1.86 °C	IX., 2.22 °C
	SMHI-MP	VI., 2.81 °C	VI., 3.06 °C	IX., 2.60 °C	VI., 2.31 °C	II., 2.86 °C
tasmin	RegCM4-EC	IX., 2.39 °C	IV., 2.38 °C	XI., 2.64 °C	X., 2.44 °C	IV., 2.34 °C
	RegCM4-MP	II., 3.57 °C	II., 3.47 °C	II., 3.53 °C	II., 3.13 °C	II., 3.47 °C
	SMHI-EC	IX., 1.77 °C	X., 2.19 °C	IX., 2.22 °C	IX., 1.80 °C	X., 2.09 °C
	SMHI-MP	VI., 2.73 °C	VI., 2.61 °C	IX., 2.52 °C	IX., 2.23 °C	IX., 2.42 °C

Iz prikaza vremenskih nizova varijabli s ucrtanim pravcima linearnih trendova (slike B1 – B5) možemo procijeniti kojom bi brzinom rasla srednja temperatura zraka u ovim gradovima za dva odabrana scenarija. Vidljivo je

povećanje srednje temperature zraka kroz cijelo promatrano razdoblje, 1991. – 2070., za sve gradove i sve kombinacije klimatskih modela i scenarija. Dobiveni su veći trendovi za scenarij RCP 8.5 nego za scenarij RCP 4.5. Valja napomenuti i da su ovdje svi trendovi statistički značajni na nivou značajnosti od 95 %.

Na Slici 3.1.1. prikazane su karte Republike Hrvatske s ucrtanim promatranim postajama i podacima linearnih trendova izraženih u °C/10 god. za srednju godišnju temperaturu zraka u scenariju RCP 4.5 za različite kombinacije RCM-GCM, a na slici 3.1.2. prikazane su za scenarij RCP 8.5. Sve postaje označene su zvjezdicom jer su njihovi trendovi statistički značajni i ponovno se vide izraženiji linearni trendovi u scenariju RCP 8.5 nego u onom RCP 4.5. Može se primijetiti da RegCM4 daje projekciju brzine rasta *tas* koja je veća u promatranim gradovima iz priobalnog područja u odnosu na one u kontinentalnom području, dok model SMHI RCM-a pokazuje malo jači signal zagrijavanja u gradovima iz kontinentalnog područja u odnosu na one iz priobalnog područja.

Dakle, prema ovim simulacijama možemo očekivati sve veću srednju godišnju temperaturu bez obzira na postaju, scenarij koji se promatra i kombinacije RCM i GCM koje se koriste. Prema napravljenim simulacijama, za scenarij RCP 4.5 porast srednje godišnje temperature zraka u promatranim gradovima je između 0.18 i 0.27 °C svakih 10 godina, a za scenarij RCP 8.5 ovo je povećanje veće, između 0.26 i 0.39 °C/10 god. Ako se ostvare uvjeti scenarija RCP 4.5 ili više, u Dubrovniku bi se u budućnosti, u razdoblju P2, mogao očekivati porast srednje godišnje temperature zraka između 0.21 i 0.39 °C svakih 10 godina, u Osijeku između 0.18 i 0.37 °C/10 god., u Rijeci 0.23 – 0.39 °C/10 god., u Zadru između 0.18-0.37 °C/10 god., a u Zagrebu između 0.20 i 0.38 °C svakih 10 godina, s time da veće vrijednosti odgovaraju scenariju RCP 8.5. Sumarno su ti rezultati prikazani u tablici 3.1.3.

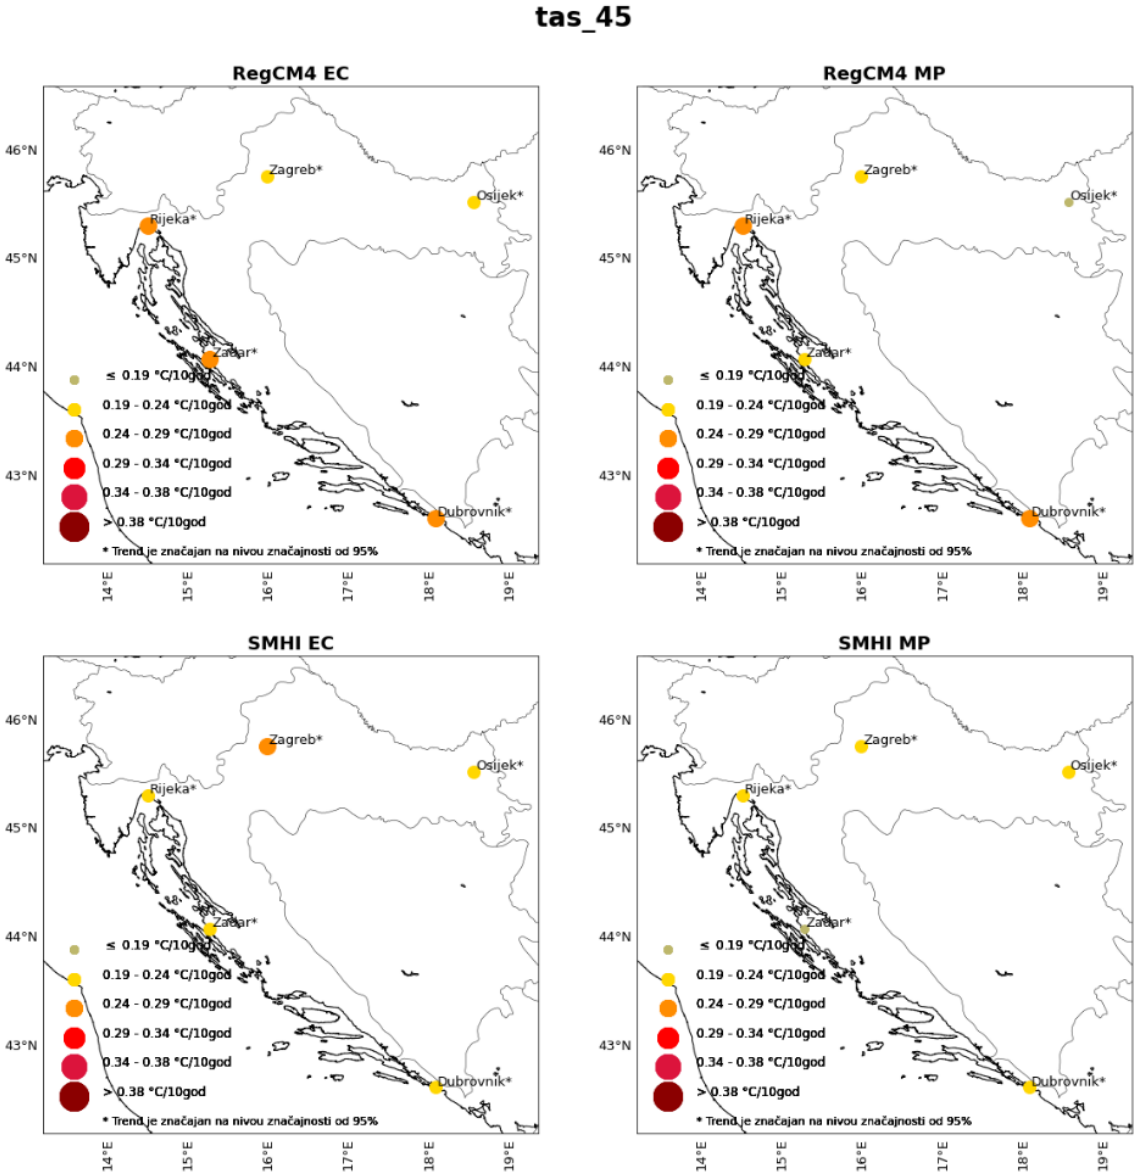

Slika 3.1.1: Karte Hrvatske s ucrtanim razmatranim postajama i intervalima trenda izraženim u °C/10 god. za godišnje srednjake srednjih dnevnih temperatura zraka na 2 m visine za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

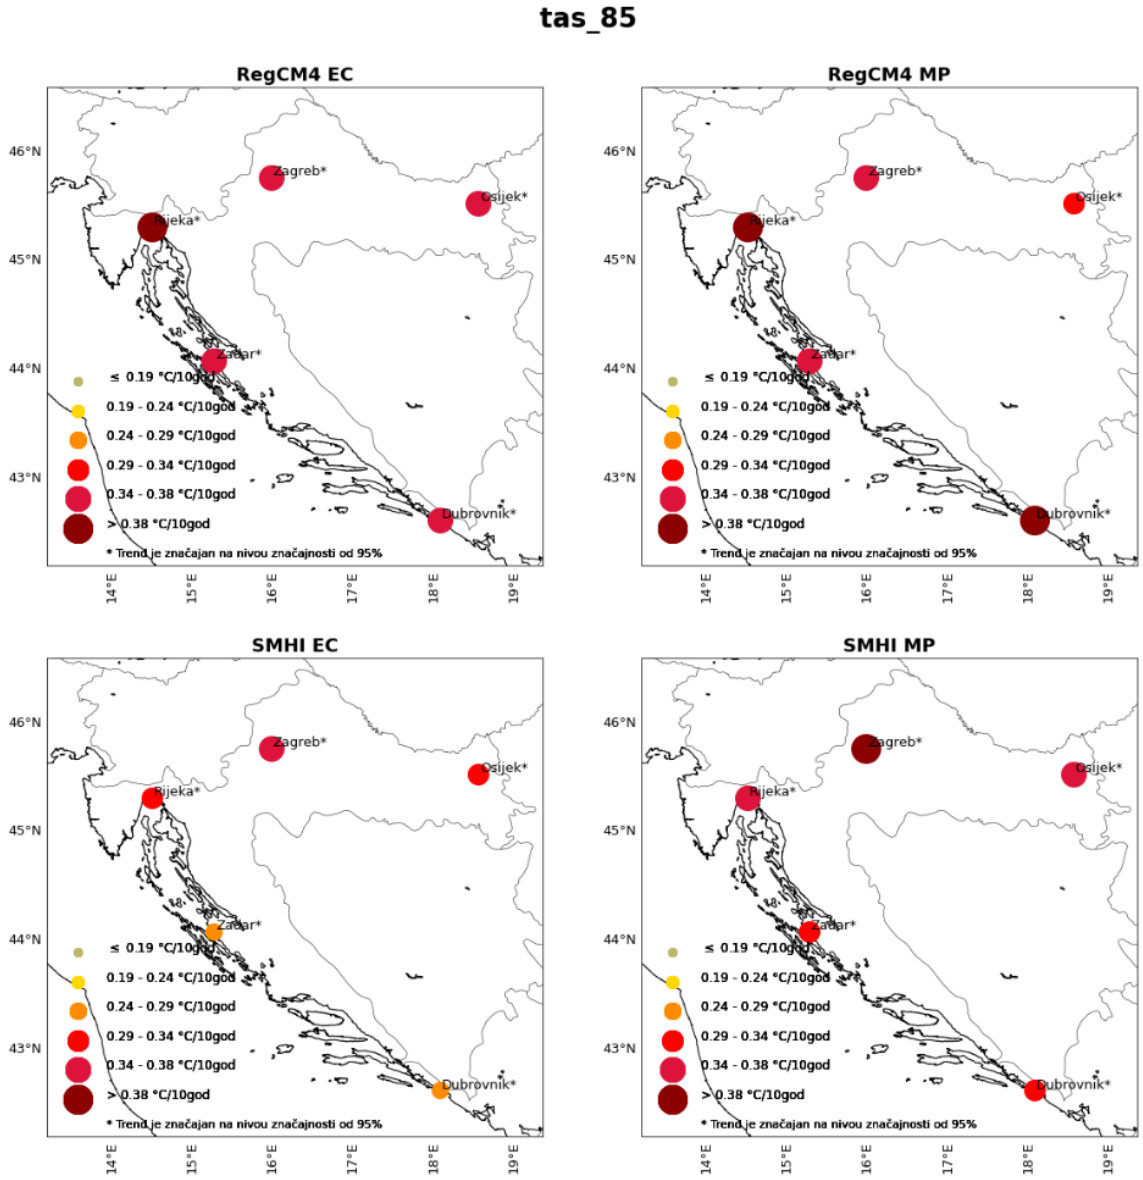

Slika 3.1.2: Karte Hrvatske s ucrtanim razmatranim postajama i intervalima trenda izraženim u °C/10 god. za godišnje srednjake srednjih dnevnih temperatura zraka na 2 m visine za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

Tablica 3.1.3: Linearni trendovi srednje, maksimalne i minimalne temperature u Dubrovniku, Zadru, Rijeci, Zagrebu i Osijeku prema simulacijama RCM RegCM4 i SMHI-RCA4 forsiranih GCM-ima EC i MP u scenarijima RCP 4.5 i RCP 8.5. Vrijednosti su dane u jedinicama °C/10 god.

	RCP 4.5			RCP 8.5		
	tas	tasmax	tasmin	tas	tasmax	tasmin
Dubrovnik	0.21 - 0.27	0.20 - 0.25	0.20 - 0.28	0.28 - 0.39	0.28 - 0.38	0.28 - 0.40
Zadar	0.18 - 0.25	0.18 - 0.25	0.18 - 0.27	0.26 - 0.37	0.26 - 0.38	0.27 - 0.38
Rijeka	0.23 - 0.27	0.23 - 0.27	0.20 - 0.27	0.33 - 0.39	0.34 - 0.41	0.31 - 0.40
Zagreb	0.20 - 0.25	0.20 - 0.25	0.21 - 0.24	0.35 - 0.38	0.34 - 0.39	0.35 - 0.37
Osijek	0.18 - 0.24	0.19 - 0.24	0.18 - 0.25	0.32 - 0.37	0.30 - 0.39	0.33 - 0.38

3.2 Maksimalna temperatura zraka

Iz prikaza višegodišnjih mjesečnih srednjaka maksimalne temperature zraka na 2 m visine (slike A1 – A10) može se primijetiti porast *tasmax* u razdoblju P2 u odnosu na razdoblje P0 u oba scenarija, za sve kombinacije klimatskih modela, što je i bilo očekivano. Taj je porast izraženiji u scenariju RCP 8.5 nego za RCP 4.5. Kao što je to bio slučaj i za *tas*, ni za *tasmax* se ne može pouzdano reći u kojem se mjesecu očekuje najveće povećanje maksimalne temperature, iako većina kombinacija modela ukazuje na najveće povećanje *tasmax* u toplijem dijelu godine (tablice 3.1.1 i 3.1.2).

Analiziranjem vremenskih nizova i linearnih trendova na slikama B1 – B5 saznajemo informacije o brzini porasta godišnjih srednjaka dnevnih maksimalnih temperatura u promatranim gradovima. Za sve kombinacije klimatskih modela i gradova, kroz cijelo promatrano razdoblje primjećuje se povećanje maksimalne temperature zraka koje je izraženije za scenarij RCP 8.5 nego za RCP 4.5 – što je i očekivano. Vrijednosti trendova prikazane su na kartama Hrvatske (slike 3.2.1 i 3.2.2.) gdje su ucrtane promatrane postaje i vrijednosti linearnih trendova izraženih u °C/10 god. u različitim kombinacijama klimatskih modela. Trendovi *tasmax* statistički su značajni za sve navedene kombinacije i veći za scenarij RCP 8.5 nego za RCP 4.5. Slično kao i za srednju temperaturu, pokazalo se da RegCM4 za buduće maksimalne temperature zraka na 2 m visine simulira nešto veći signal promjene u

promatranim gradovima iz priobalnog područja u odnosu na one u kontinentalnom području za razliku od SMHI RCM-a koji pokazuje jači signal zagrijavanja u gradovima iz kontinentalnog područja u odnosu na one iz priobalnog područja. Ponovo, dakle, uočavamo pozitivan trend, odnosno porast godišnjih srednjaka dnevne maksimalne temperature prema njenim simulacijama bez obzira na postaju, scenarij i kombinacije RCM i GCM koje se koriste. Prema napravljenim simulacijama, scenariju RCP 4.5 odgovara povećanje godišnjih srednjaka dnevne maksimalne temperature zraka u promatranim gradovima između 0.18 i 0.27 °C/10 god., a scenariju RCP 8.5 između 0.26 i 0.41 °C svakih 10 godina. Ako se ostvare uvjeti scenarija RCP 4.5 ili više, u Dubrovniku bi se u budućnosti, u razdoblju P2, mogao očekivati porast godišnjih srednjaka *tasmax* između 0.20 i 0.38 °C svakih 10 godina, u Osijeku između 0.19 i 0.39 °C/10 god., u Rijeci 0.23 – 0.41 °C/10 god., u Zadru između 0.18 – 0.38 °C/10 god., a u Zagrebu između 0.20 i 0.39 °C svakih 10 godina što je sumarno prikazano u tablici 3.1.3.

U Dodatku C prikazani su vremenski nizovi klimatskih indeksa *FD, ID, SU, TR, DTR* i *ETR* s ucrtanim pravcima linearnih trendova za cijelo promatrano razdoblje, 1991. – 2070., za sve gradove i sve kombinacije klimatskih modela i scenarija. Ako trend nije statistički značajan na nivou značajnosti od 95 %, označen je isprekidanom linijom. Promatranjem slika C1 – C10 može se uočiti negativan trend klimatskog indeksa *ID*, odnosno opadanje broja dana s maksimalnom temperaturom ispod 0 °C za sve gradove, u oba scenarija i u svim kombinacijama korištenih modela RCM i GCM. S druge strane, primjećuje se i pozitivan trend klimatskog indeksa *SU*, tj. povećanje broja dana s maksimalnom temperaturom iznad 25 °C koji je za sve klimatske projekcije statistički značajan. Prema napravljenim simulacijama, raspon promjene indeksa *ID* za scenarij RCP 4.5 je između +0.04 i -0.93 dana/10 god., a za scenarij RCP 8.5 smanjenje je izraženije i poprima vrijednosti, između -0.00 i -1.59 dana/10 god. Scenarij RCP 4.5 daje porast SU između 1.75 i 4.30 dana/10 god., a veći je za RCP 8.5 te iznosi 3.70 – 6.34 dana/10 god. Linearni trendovi indeksa *ID* i *SU* prikazani su na kartama na slikama 3.2.3. – 3.2.6. Klimatske projekcije pokazuju kako indeks *ID* ima jači negativni trend u Zagrebu i Osijeku za razliku od promatranih gradova iz priobalnih područja. Prostorna razdioba je još

izraženija pri scenariju RCP 8.5 s obzirom na to da se za njega očekuje još manje dana s maksimalnom temperaturom ispod 0 °C u promatranim kontinentalnim gradovima. Indeks *SU* ima statistički značajan pozitivan trend u svim promatranim projekcijama buduće klime za sve gradove i kombinacije modela. Trend je jači za RCP 8.5 scenarij, odnosno u klimatskim uvjetima koji odgovaraju tom scenariju možemo očekivati sve više dana s maksimalnom dnevnom temperaturom većom od 25 °C. Ako se ostvare uvjeti scenarija RCP 4.5 ili više, u Dubrovniku bi se u budućnosti, u razdoblju P2, mogao očekivati trend *ID* između -0.00 i -0.02 dana svakih 10 godina, u Osijeku između -0.17 i -1.58 dana/10 god., u Rijeci +0.04 do -0.16 dana/10 god., u Zadru između -0.01 i -0.05 dana/10 god., a u Zagrebu između -0.24 i -1.59 dana svakih 10 godina, od čega su samo za Zagreb i Osijek trendovi statistički značajni. Dakle, vidimo da se očekuje sve manje dana s maksimalnom temperaturom ispod 0 °C, posebice u razmatranim gradovima smještenih u kontinentalnom području (Zagreb, Osijek) gdje su dobiveni statistički značajni trendovi indeksa *ID* za RCP 8.5 scenarij. Očekivani trend indeksa *SU* je u Dubrovniku između 3.16 i 6.34 dana/10 god., u Osijeku između 1.75 i 3.70 dana/10 god., u Rijeci 2.38 do 4.98 dana/10 god., u Zadru 1.82 – 5.39 dana/10 god., a u Zagrebu između 2.52 i 5.36 dana svakih 10 godina. Dakle, od ovih pet promatranih gradova, u gradu Dubrovniku očekuje se najbrži odnosno najveći porast broja dana s maksimalnom temperaturom iznad 25 °C. Ovi podaci su pregledno prikazani u tablici 3.2.1.

Tablica 3.2.1: Linearni trendovi klimatskih indeksa *FD, ID, SU* i *TR* u Dubrovniku, Zadru, Rijeci, Zagrebu i Osijeku prema simulacijama RCM RegCM4 i SMHI-RCA4 forsiranih GCM-ima EC i MP u scenarijima RCP 4.5 i RCP 8.5. Vrijednosti su dane u jedinicama dan/10 god.

	RCP 4.5			
	FD	ID	SU	TR
Dubrovnik	-0.02 - -0.32	-0.01 - -0.02	2.47 - 3.77	3.01 - 4.62
Zadar	-0.09 - -0.61	-0.01 - -0.04	1.82 - 3.93	3.69 - 5.01
Rijeka	-0.23 - -1.06	+0.04 - -0.15	2.38 - 4.30	4.17 - 4.28
Zagreb	-1.83 - -2.92	-0.24 - -0.83	2.52 - 3.54	1.99 - 2.53
Osijek	-1.31 - -3.22	-0.17 - -0.93	1.75 - 2.92	1.50 - 2.18
	RCP 8.5			
	FD	ID	SU	TR
Dubrovnik	-0.07 - -0.48	-0.00 - -0.02	4.33 - 6.34	5.35 - 6.49
Zadar	-0.19 - -1.34	-0.01 - -0.05	3.97 - 5.39	5.50 - 6.79
Rijeka	-0.77 - -2.18	-0.02 - -0.16	4.20 - 4.98	4.43 - 6.51
Zagreb	-3.77 - -4.90	-0.93 - -1.59	4.37 - 5.36	2.75 - 3.58
Osijek	-3.60 - -5.02	-1.01 - -1.58	3.70 - 5.65	2.03 - 3.21

Ovakve visoke temperature mogu pospješiti evaporaciju iz tla što (posebice) razdoblja s malo oborine čini još sušnijim nego što bi inače bili. Sušna razdoblja onda znatno utječu na poljoprivredu i razvoj biljaka, pa se može očekivati veća potreba za navodnjavanjem (C2ES, 2021). Nadalje, dugotrajne visoke temperature i sušna razdoblja povezani su s mnogim neželjenim posljedicama (npr. povećavani rizik od požara, negativan utjecaj na ljudsko zdravlje, problemi s opskrbom vode itd.), stoga je važno procijeniti očekivane promjene.

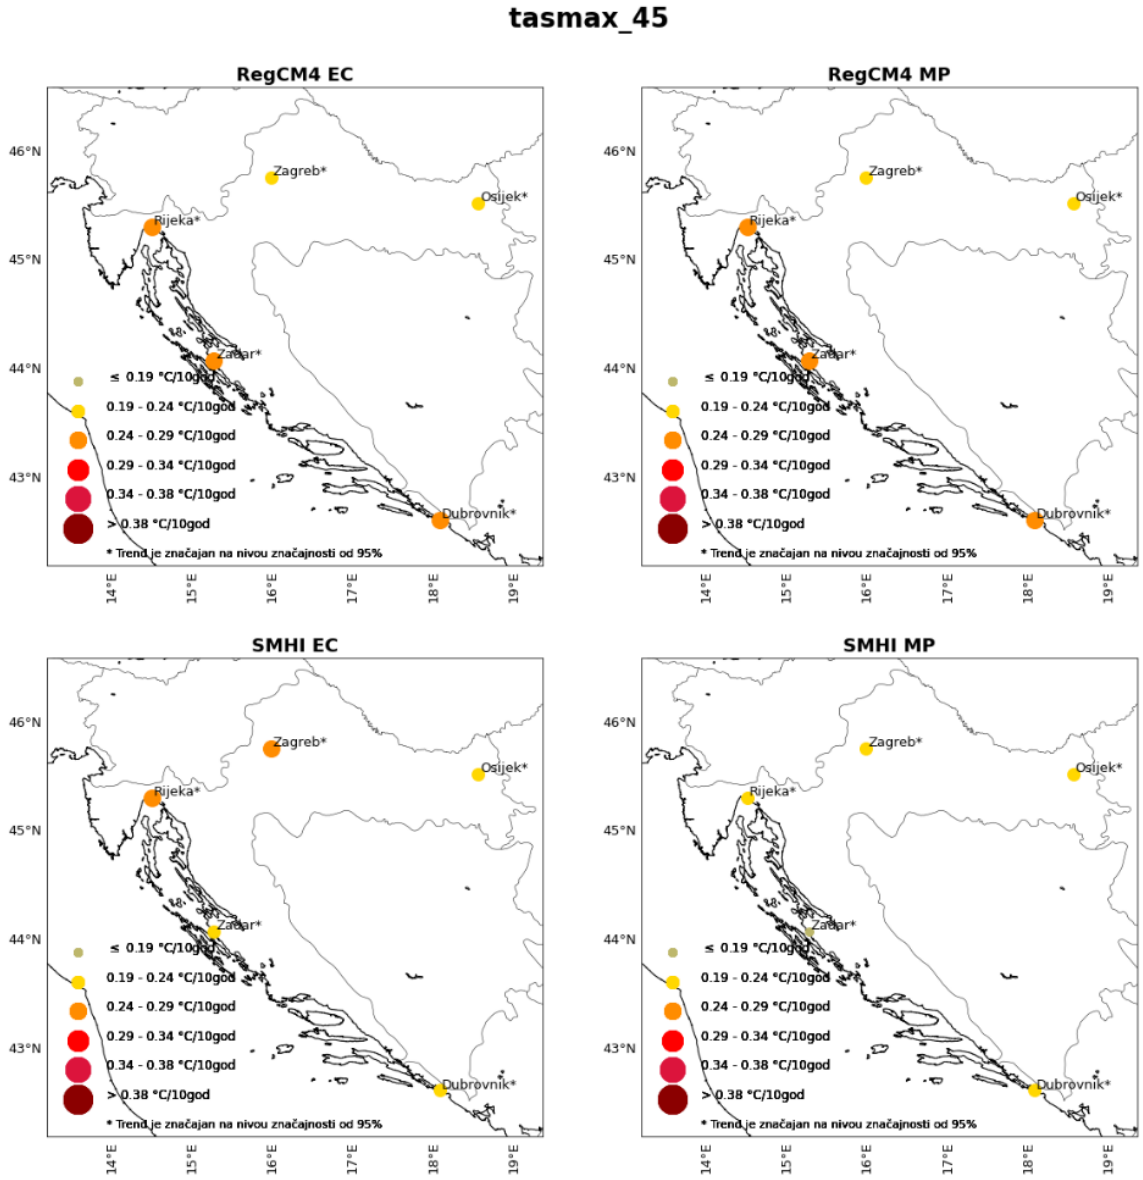

Slika 3.2.1: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za godišnje srednjake dnevnih maksimalnih temperatura zraka na 2 m visine za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

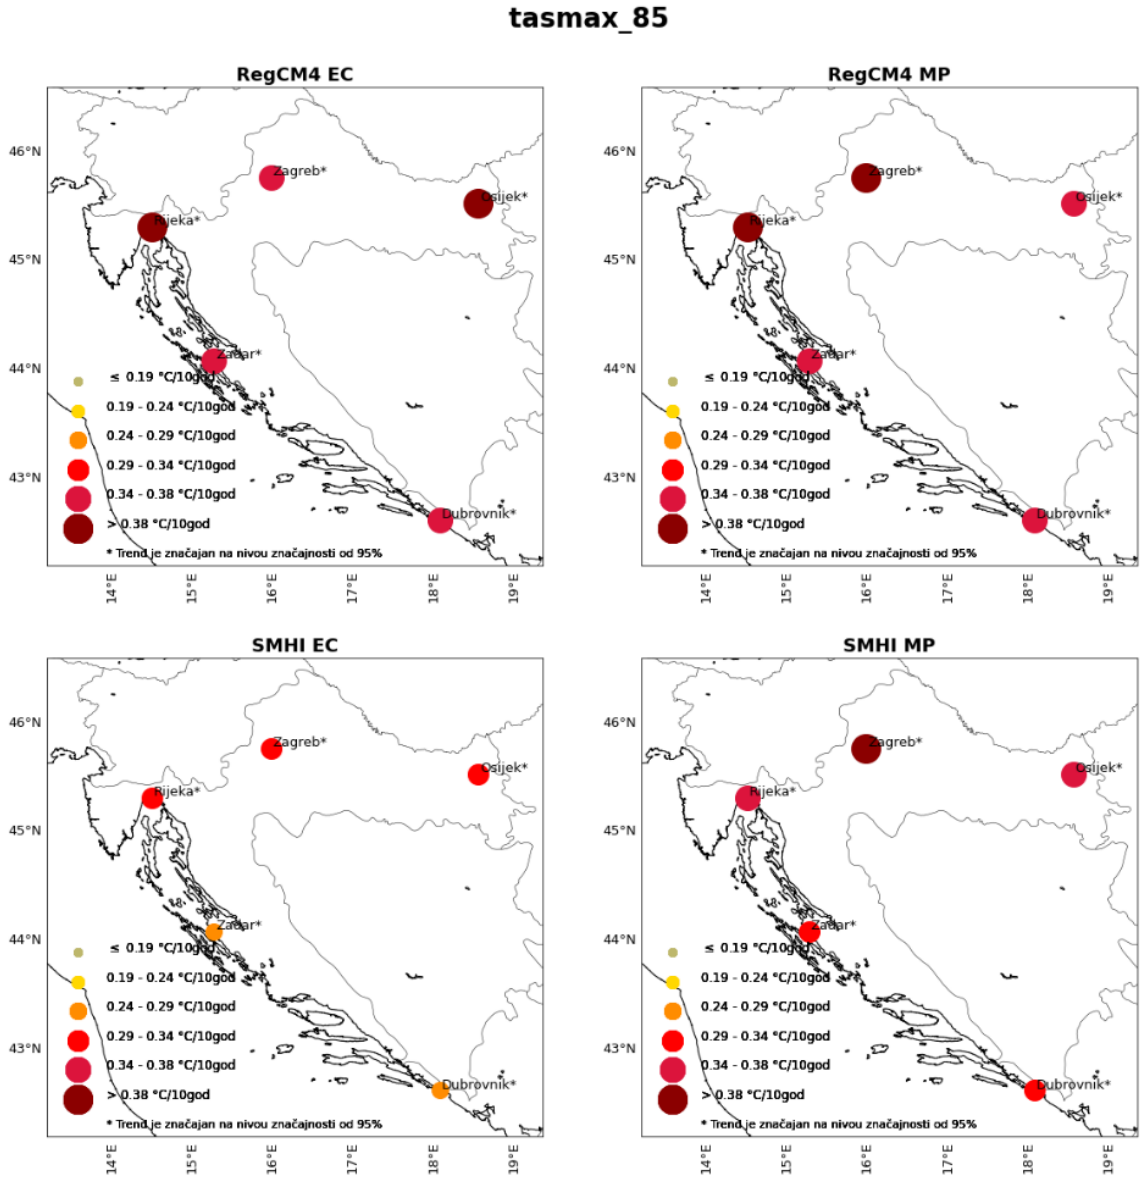

Slika 3.2.2: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za godišnje srednjake dnevnih maksimalnih temperatura zraka na 2 m visine za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

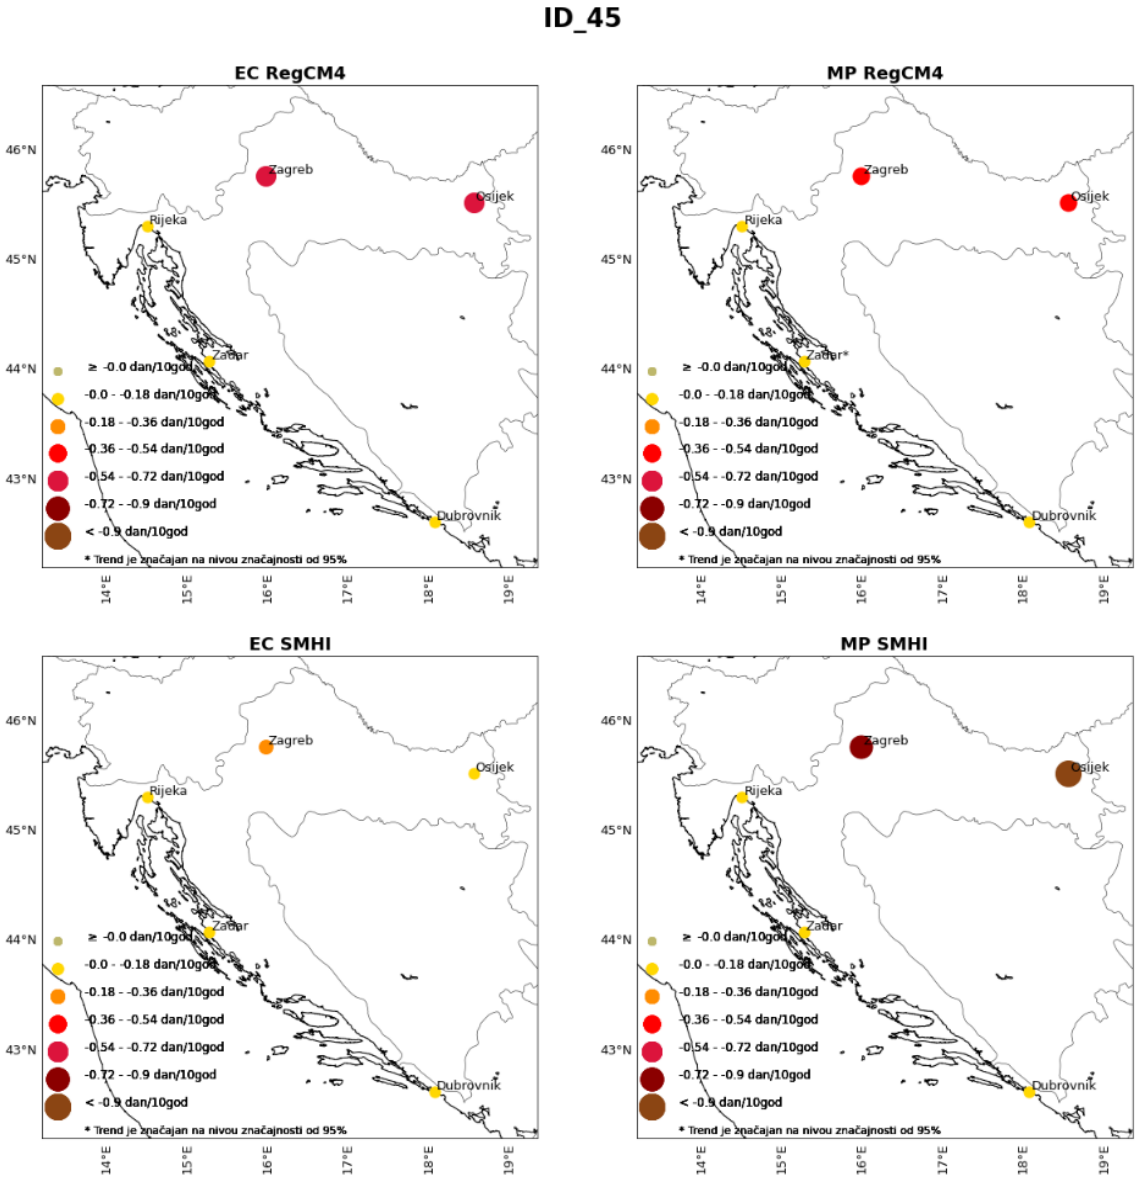

Slika 3.2.3: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *ID* za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

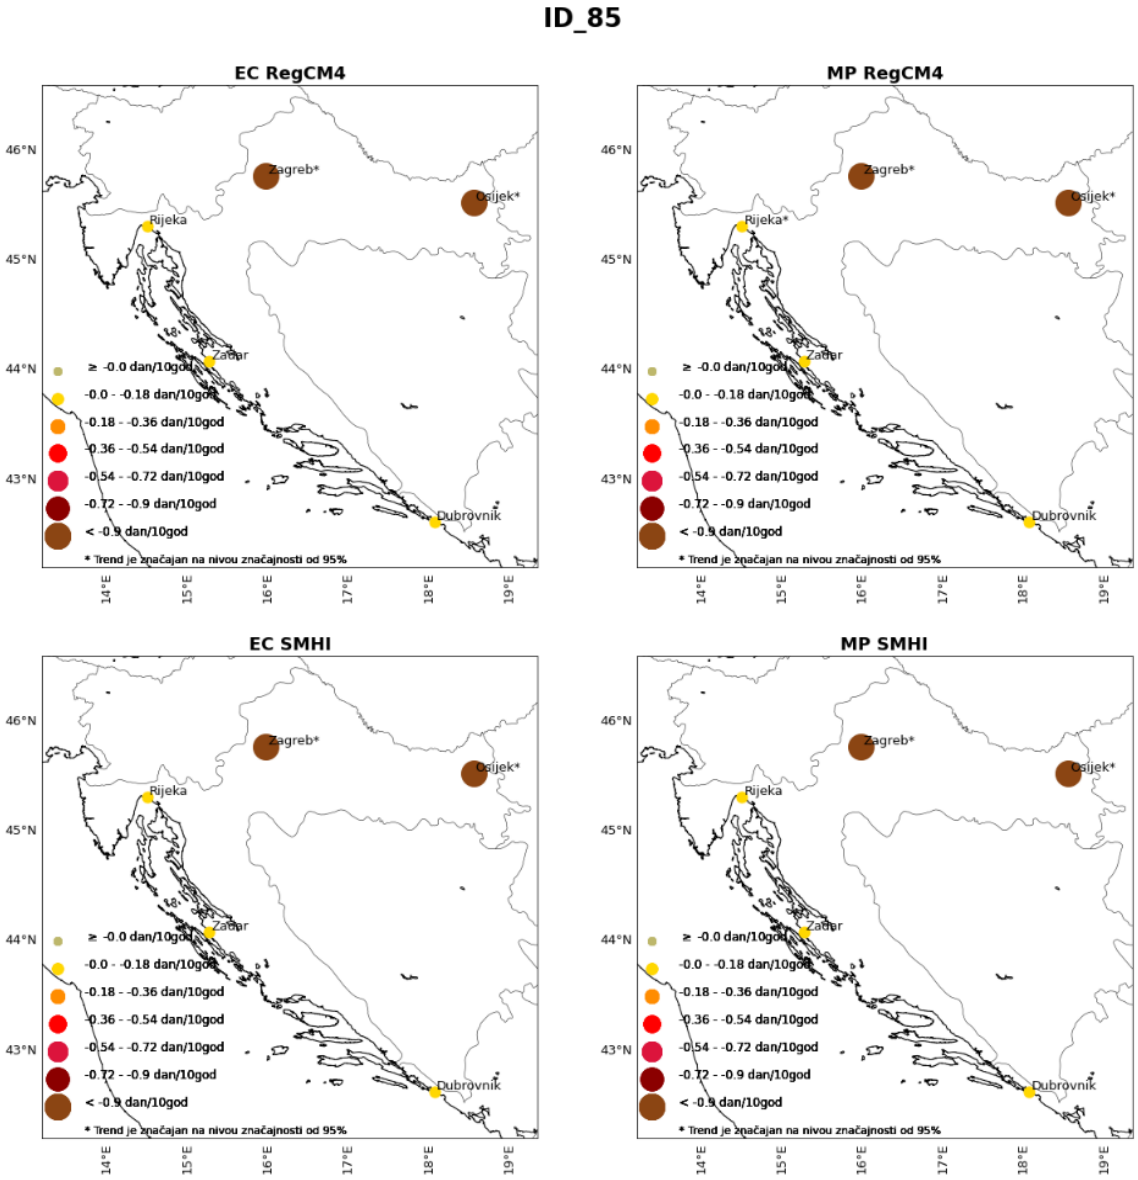

Slika 3.2.4: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *ID* za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

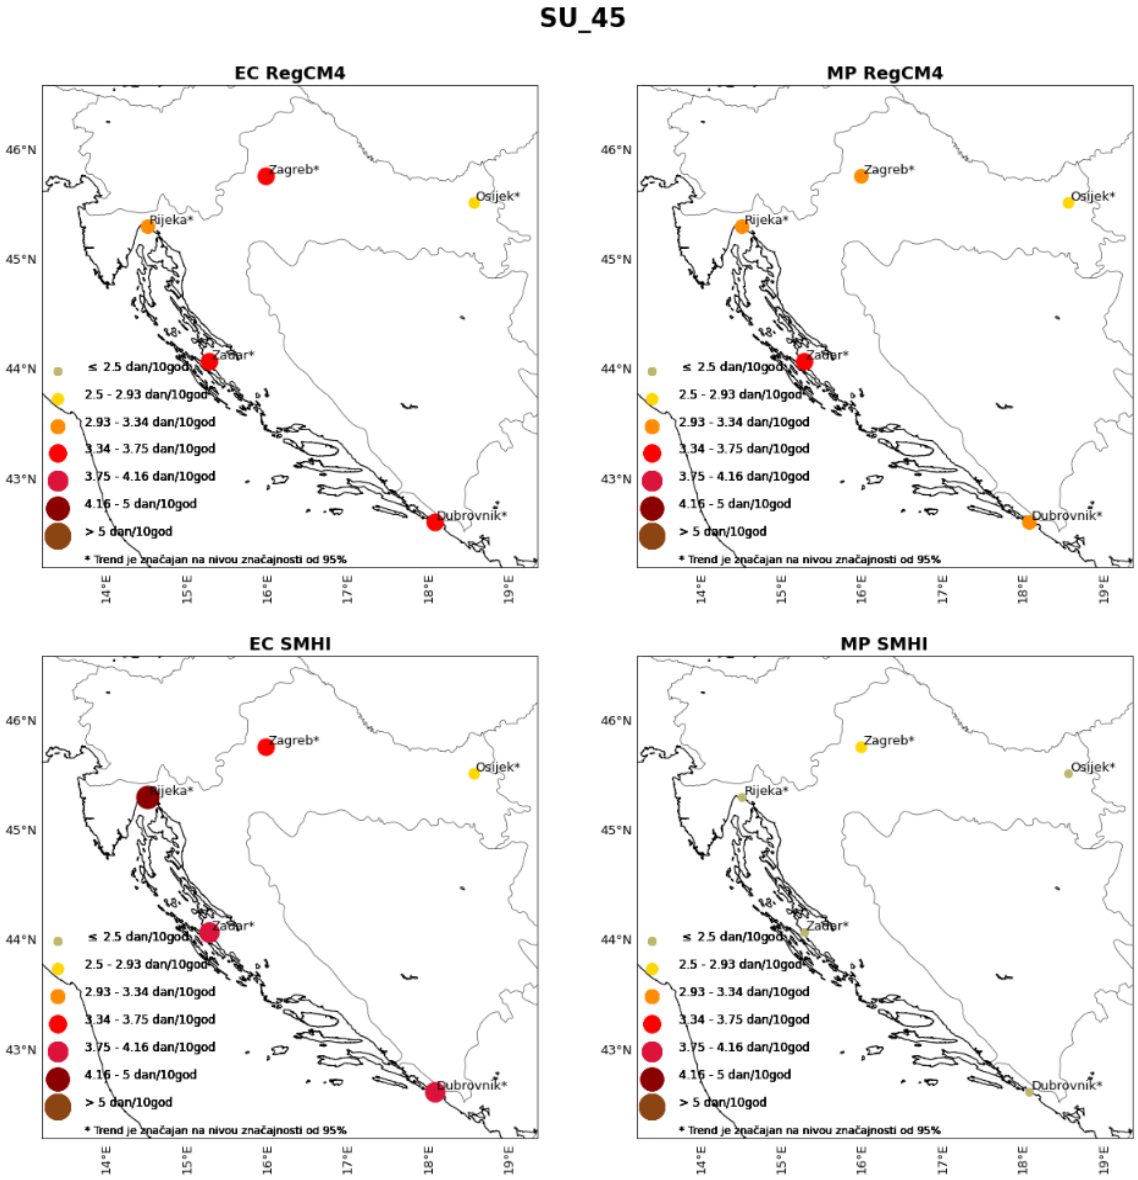

Slika 3.2.5: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *SU* za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

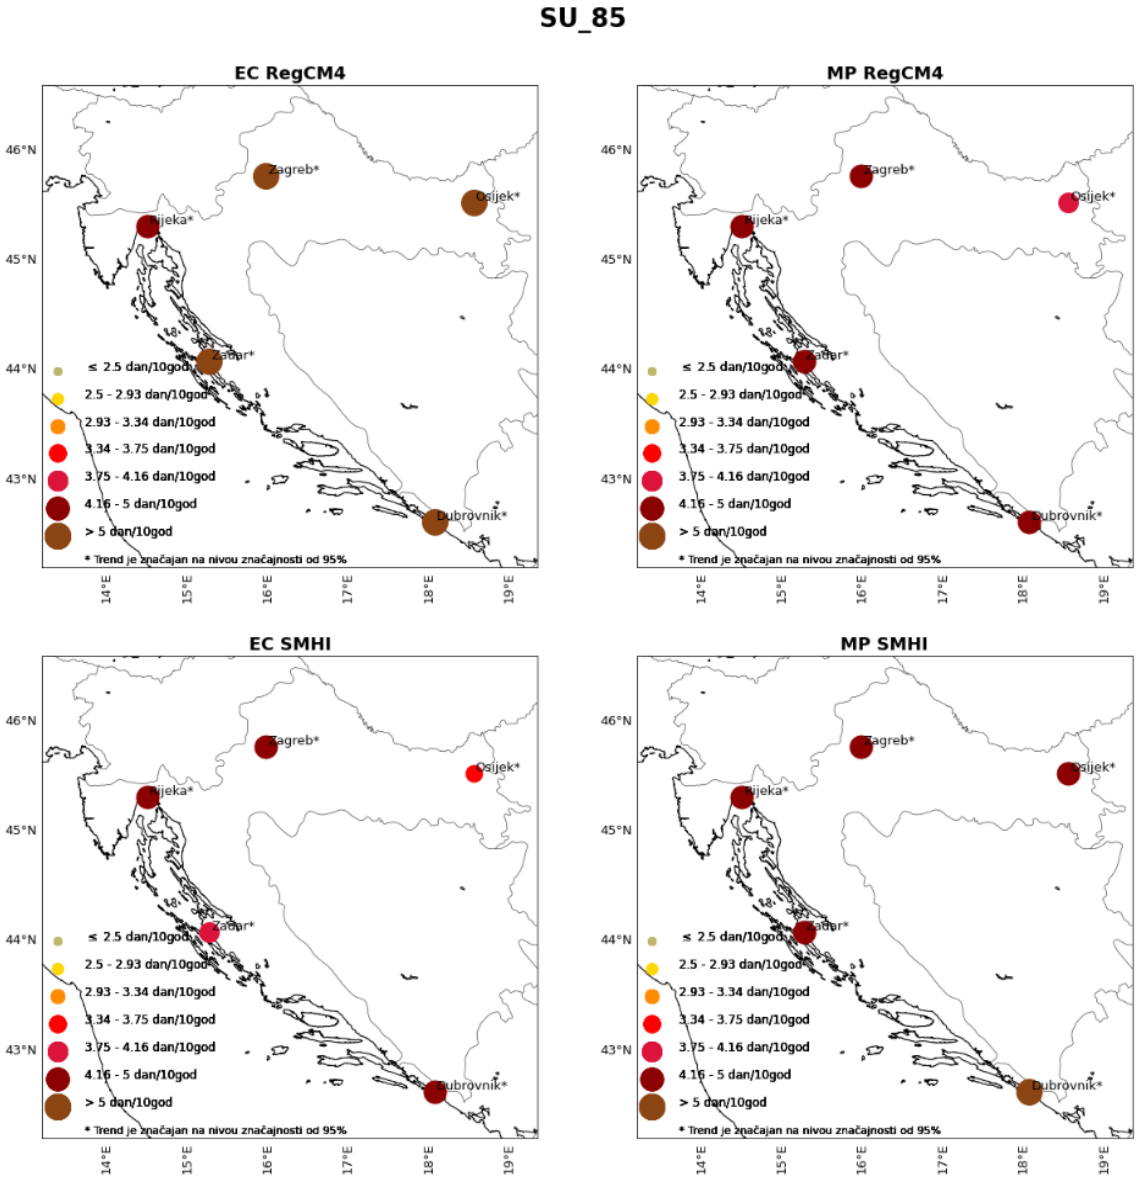

Slika 3.2.6: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *ID* za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

3.3 Minimalna temperatura zraka

Iz prikaza višegodišnjih mjesečnih srednjaka minimalne temperature zraka na 2 m visine (slike A1 – A10) može se primijetiti porast *tasmin* u razdoblju P2 u odnosu na razdoblje P0 u oba scenarija, za sve kombinacije klimatskih modela, što je i bilo očekivano. Taj je porast opet izraženiji u scenariju RCP 8.5 nego za RCP 4.5. Kao što je to bio slučaj za *tas* i *tasmax*, i za *tasmin* se pokazuje da su ova

povećanja uglavnom najveća u toplim dijelovima godine, ali opet postoje određena odstupanja između rezultata koje daju različite kombinacije RCM-a i GCM-a (tablice 3.1.1 i 3.1.2).

Na Slikama B1 – B5 nalaze se vremenski nizovi i linearni trendovi za sve kombinacije klimatskih modela i gradova. Kroz cijelo promatrano razdoblje primjećuje se povećanje godišnjih srednjaka dnevnih *tasmin* što je (očekivano) izraženije za scenarij RCP 8.5 nego za RCP 4.5. Svi izračunati trendovi su se pokazali statistički značajnima na nivou značajnosti od 95 %. Isti trendovi prikazani su na kartama Hrvatske na slikama 3.3.1 i 3.3.2. gdje su ucrtane promatrane postaje i vrijednosti trendova u različitim kombinacijama klimatskih modela. Sa slika se može uočiti da RegCM4 simulira veće promjene srednjih godišnjih minimalnih temperatura zraka u odnosu na SMHI. Još jednom uočavamo pozitivan trend, odnosno porast srednjih godišnjih minimalnih temperatura bez obzira na postaju, scenarij i kombinacije RCM-a i GCM-a. Prema napravljenim simulacijama za scenarij RCP 4.5, očekivana promjena srednjih godišnjih minimalnih temperatura zraka u promatranim gradovima je između 0.18 i 0.28 °C/10 god., a za scenarij RCP 8.5 povećanje je veće, između 0.27 i 0.40 °C /10 god. Prema tablici 3.1.3, ako se ostvare uvjeti scenarija RCP 4.5 ili više, u Dubrovniku bi se u budućnosti, u razdoblju P2, mogao očekivati porast srednjih godišnjih *tasmin* između 0.20 i 0.40 °C/10 god., u Osijeku između 0.18 i 0.38 °C/10 god., u Rijeci 0.20 – 0.40 °C/10 god., u Zadru između 0.18 – 0.38 °C/10 god., a u Zagrebu između 0.21 i 0.37 °C/10 god., s time da su veći trendovi povezani uz scenarij RCP 8.5, a manji uz RCP 4.5.

U Dodatku C prikazani su vremenski nizovi izračunatih klimatskih indeksa i pripadajući linearni trendovi kroz cijelo promatrano razdoblje, 1991. – 2070., za sve gradove i kombinacije klimatskih modela i scenarija. Isprekidane linije označavaju pravce trendova koji nisu statistički značajni. Slike C1 – C10 ukazuju na negativan trend klimatskog indeksa *FD*, odnosno smanjenje broja dana s minimalnom temperaturom ispod 0 °C u vremenu za sve gradove, za oba scenarija i u svim kombinacijama korištenih RCM-a i GCM-a. Uočavaju se i pozitivni trendovi klimatskog indeksa *TR*, odnosno povećanje broja dana s minimalnom temperaturom iznad 20 °C koji je za sve klimatske projekcije

statistički značajan. Prema napravljenim simulacijama, za scenarij RCP 4.5 se indeks *FD* u promatranim gradovima smanjuje brzinom između -0.02 i -3.22 dana/10 god., a za scenarij RCP 8.5 smanjenja je izraženije, između -0.07 i -5.02 dana/10 god. Za RCP 4.5 povećanje indeksa *TR* iznosi između 1.50 i 5.01 dana/10 god., a za RCP 8.5 od 2.03 do 6.79 dana/10 god. (slike 3.3.3. – 3.3.6). Klimatske projekcije indeksa *FD* pokazuju kako on ima izraženiji (negativni) trend u Zagrebu i Osijeku za razliku od promatranih gradova iz priobalnih područja, a trendovi su izraženiji za scenarij RCP 8.5. Trend indeksa *TR* je također veći za scenarij RCP 8.5, odnosno u tom scenariju možemo očekivati sve više dana s minimalnom temperaturom zraka većom od 20 °C. Trend indeksa *TR* pokazao se izraženijim u promatranim gradovima iz priobalnog područja, a nešto je blaži u promatranim gradovima kontinentalnog područja. Ako se ostvare uvjeti scenarija RCP 4.5 ili više, u Dubrovniku bi se u budućnosti, u razdoblju P2, mogao očekivati trend indeksa *FD* između -0.02 i -0.48 dana/10 god., u Osijeku između -1.31 i -5.02 dana/10 god., u Rijeci -0.23 do -2.18 dana/10 god., u Zadru između -0.09 i -1.34 dana/10 god., a u Zagrebu između -1.83 i -4.90 dana/10 god. Dakle, uočavamo da se očekuje sve manje dana s *tasmin* ispod 0 °C, posebice u promatranim gradovima smještenih u kontinentalnom području (Zagreb, Osijek) gdje imamo statistički značajne trendove indeksa *FD*. Očekivano, trendovi su izraženiji za scenarij RCP 8.5. Očekivanje trenda indeksa *TR* je u Dubrovniku između 3.01 i 6.49 dana/10 god., u Osijeku između 1.50 i 3.21 dana/10 god., u Rijeci 4.17 do 6.51 dana/10 god., u Zadru 3.69 – 6.79 dana/10 god., a u Zagrebu između 1.99 i 3.58 dana svakih 10 godina. Dakle, od ovih pet promatranih gradova, u Zadru se očekuje najbrži odnosno najveći porast broja dana s minimalnom temperaturom iznad 20 °C (tablica 3.1.3).

Veće temperature zraka povezane su s većim temperaturama tla, osim u zimskoj sezoni s prisutnošću snijega koji tada djeluje kao toplinski izolator (Soong i sur., 2020). Toplije tlo u zimskoj sezoni pospješuje razvoj nametnika koji prenose bolesti kao što su komarci ili krpelji (Patz i sur., 2003; McMichael i Lindgren, 2011), ali i nametnika na biljkama (Pritchard, 2011; Huang, 2016) koji onda mogu imati utjecaj i na poljoprivredu. Također, temperature iznad 0 °C sprječavaju nakupljanje snijega i leda na tlu što dovodi do slabije izolacije biljaka zimi. Sve više dana s minimalnom temperaturom većom od 20 °C govori o sve toplijim noćima. Visoke temperature doprinose sve češćim, dugotrajnijim i izraženijim toplinskim valovima. Više temperature igraju i bitnu ulogu u sve većoj opasnosti od požara (IPCC, 2021), ali i izravno utječu na zdravlje ljudi, posebice kroničnih bolesnika (McMichael i Lindgren, 2011).

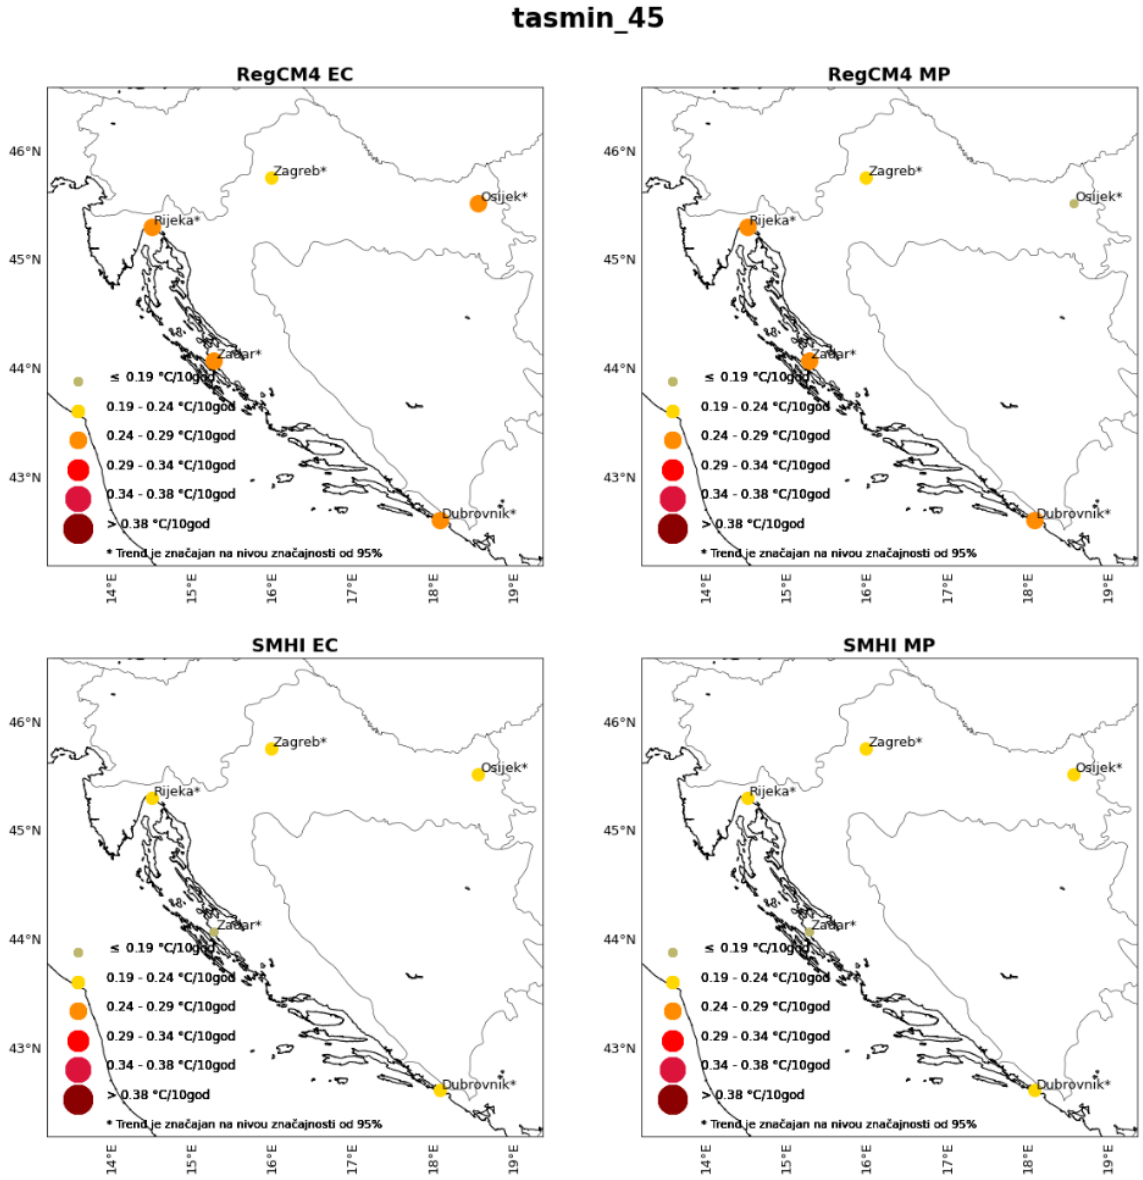

Slika 3.3.1: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za godišnje srednjake dnevnih minimalnih temperatura zraka na 2 m visine za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

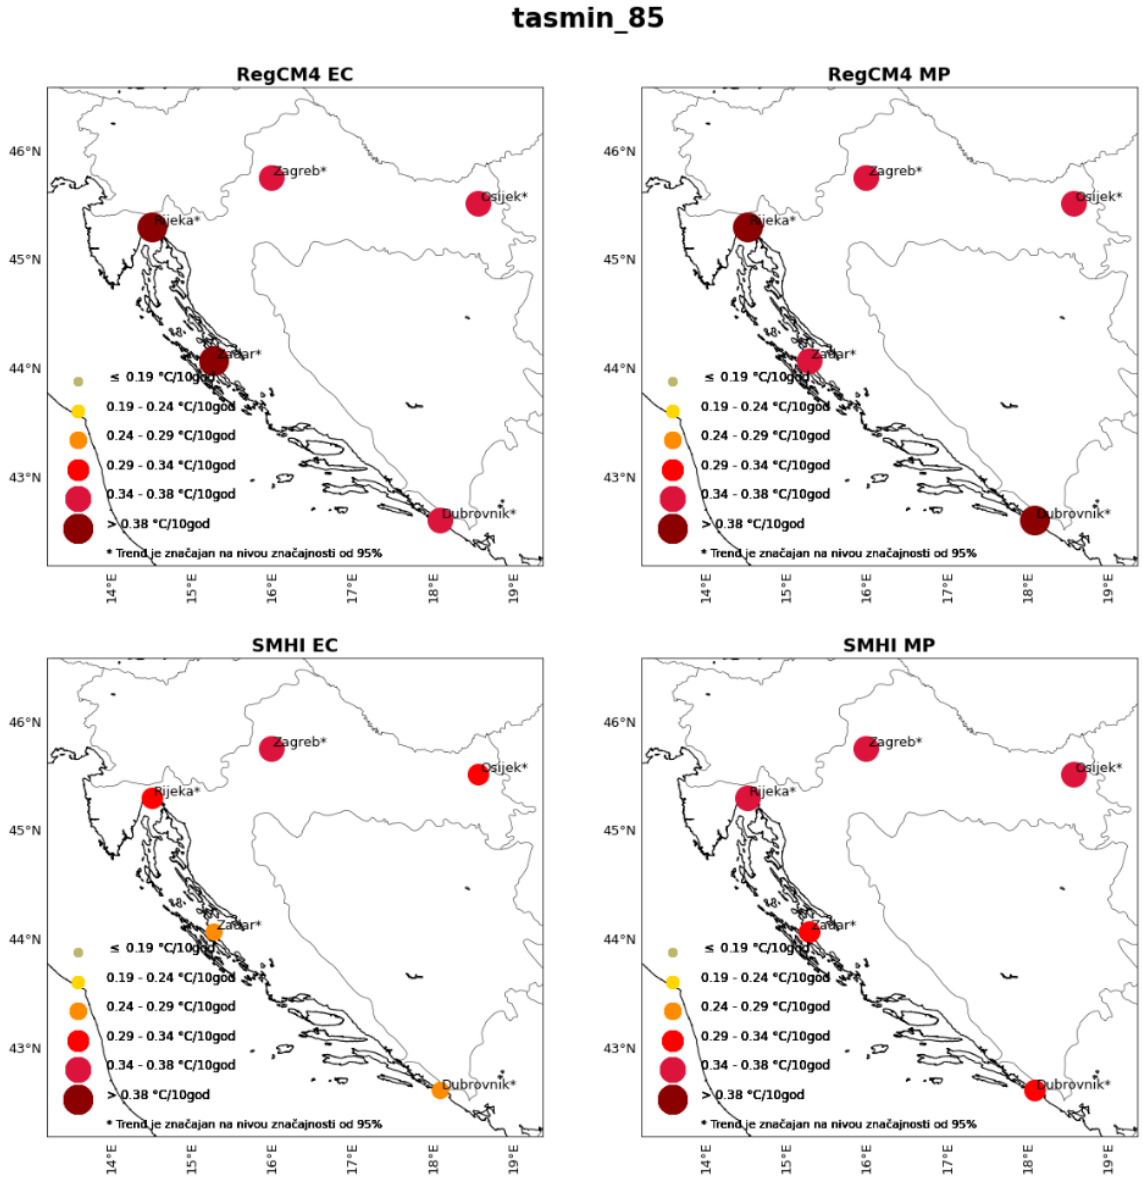

Slika 3.3.2: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za godišnje srednjake dnevnih minimalnih temperatura zraka na 2 m visine za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

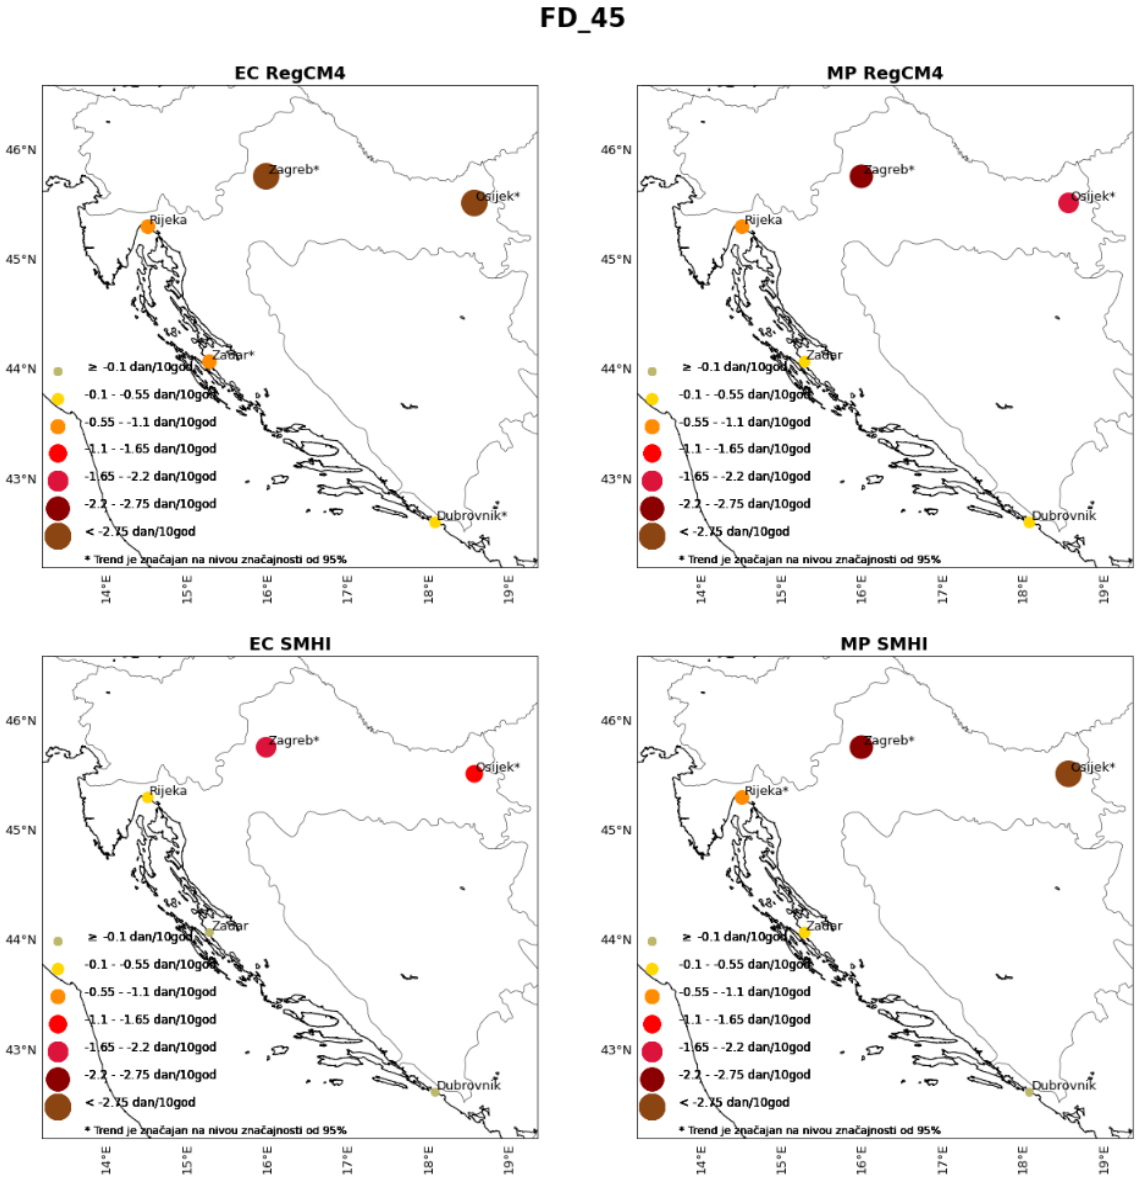

Slika 3.3.3: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *FD* za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

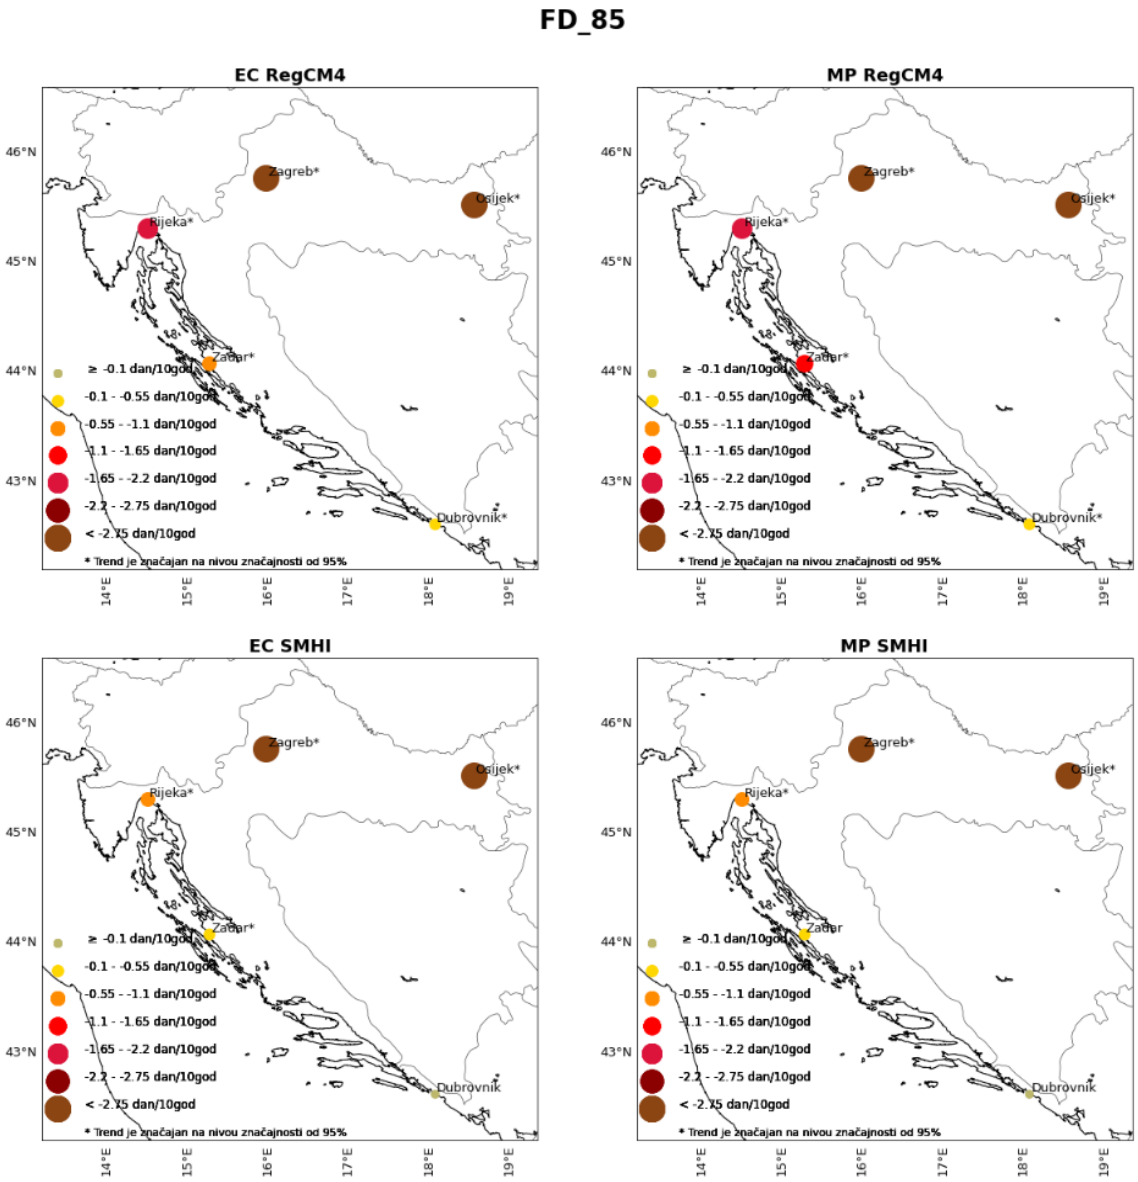

Slika 3.3.4: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *FD* za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

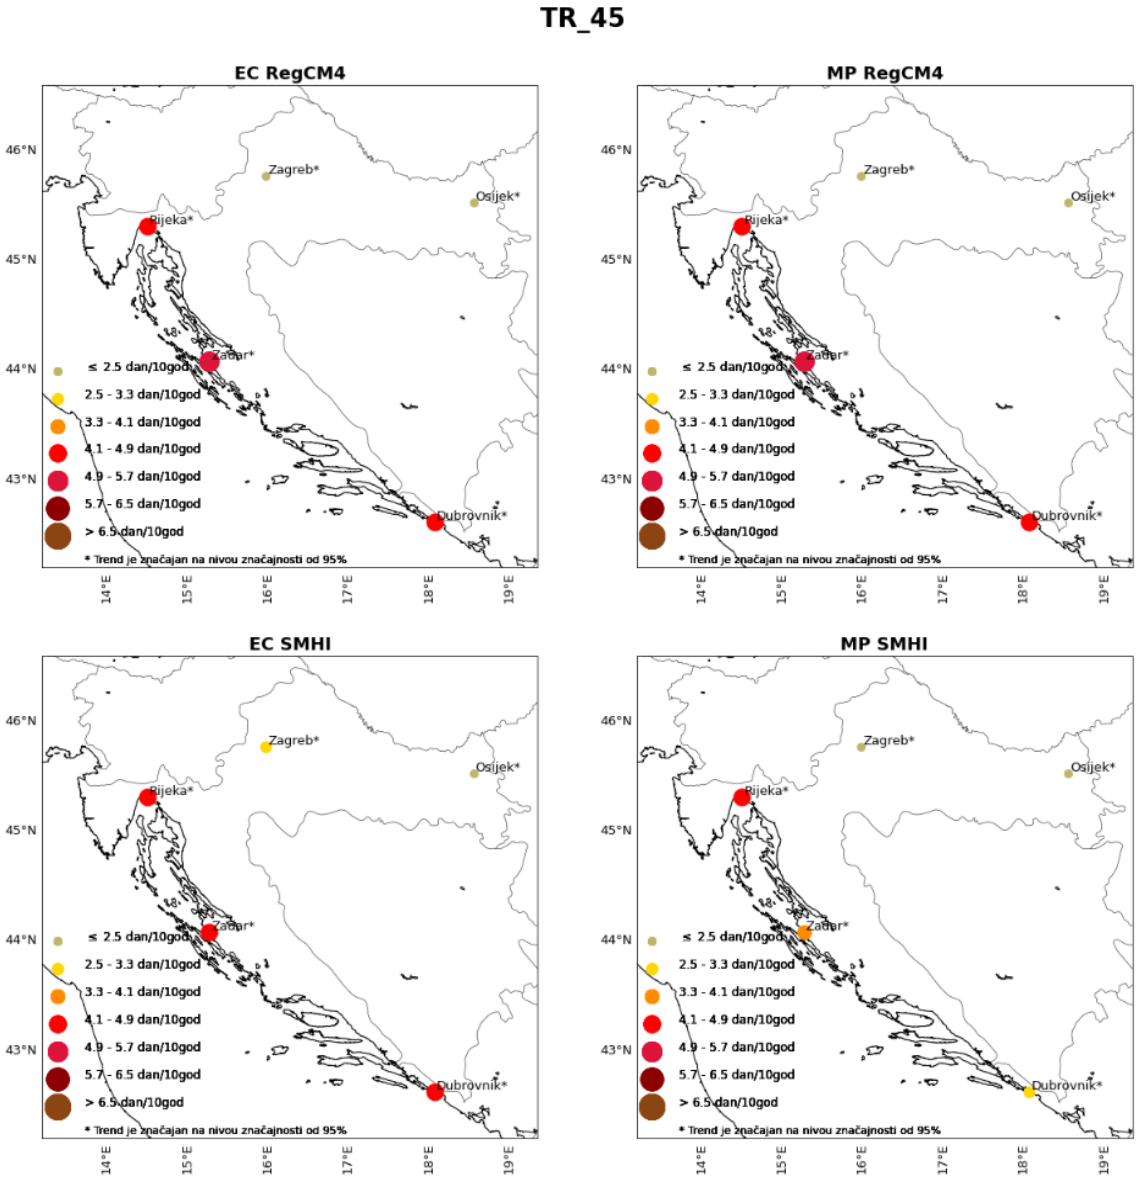

Slika 3.3.5: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *TR* za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

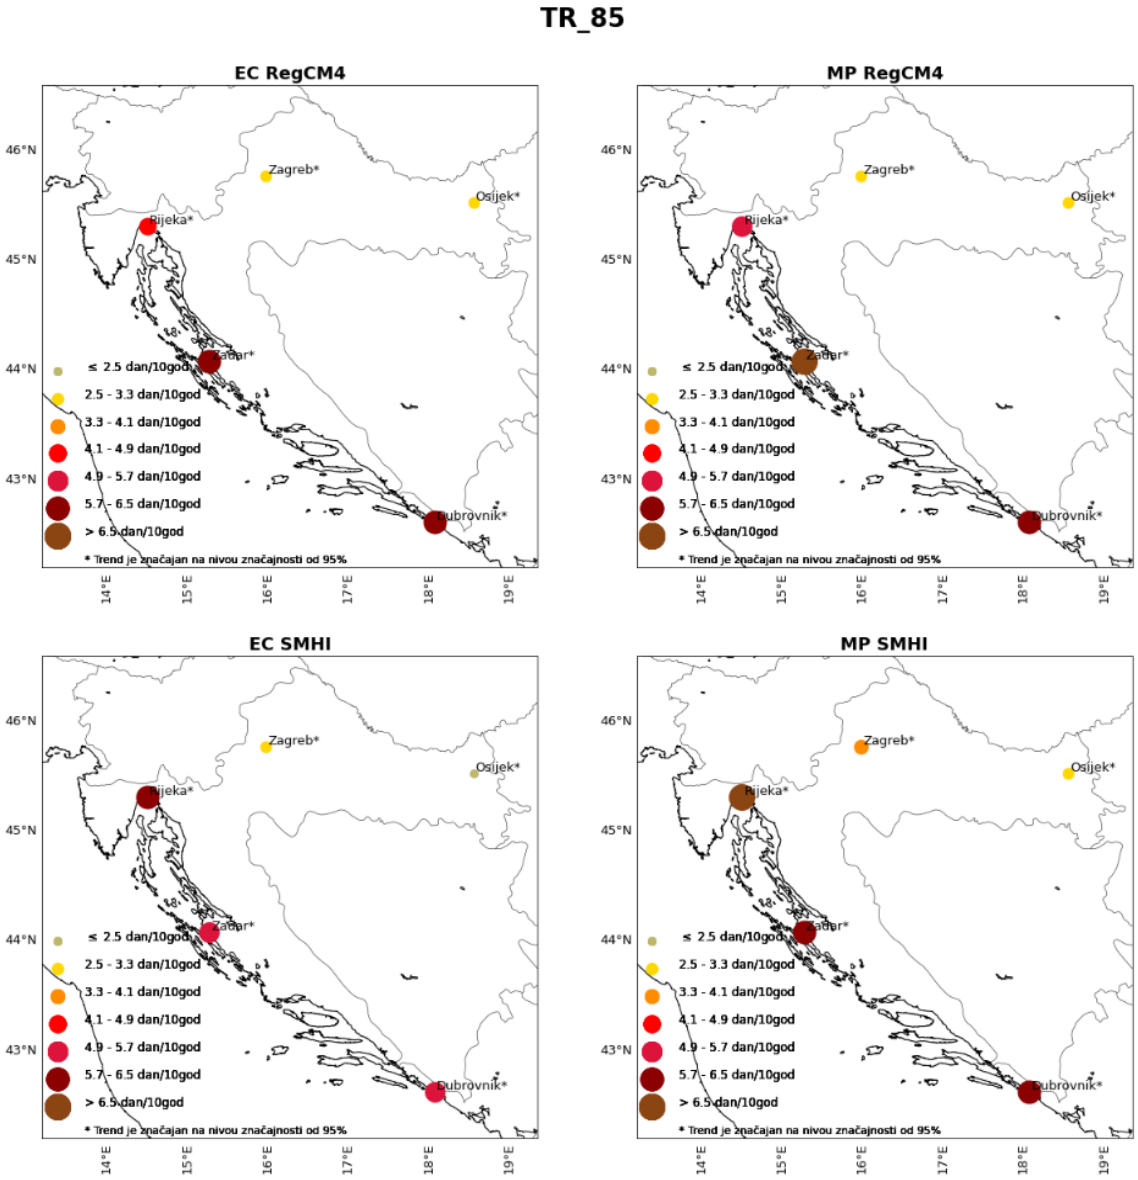

Slika 3.3.6: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *TR* za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

Izračunati su i klimatski indeksi koji govore o rasponu temperatura: *DTR* – godišnji srednjak raspona dnevnih ekstremnih temperatura, odnosno godišnji srednjak razlika između maksimalne i minimalne temperature u jednom danu i *ETR* – raspon godišnjih ekstremnih temperatura, tj. razlika između maksimalne i minimalne temperature u nekoj godini. Trendovi ovih indeksa prikazani su na slikama 3.1 – 3.4. Različite kombinacije RCM-a, GCM-a, gradova i scenarija daju

i različite rezultate te se za njih kod indeksa *DTR* ne primjećuje neki određeni obrazac ponašanja. Ipak, za scenarij RCP 4.5 indeks *ETR* raste za sve kombinacije RCM-a i GCM-a, a za scenarij RCP 8.5 se pak pokazalo kako RegCM4 najavljuje smanjenje *ETR*-a dok SMHI-RCA4 ukazuje na njegovo povećanje (tablica 3.1).

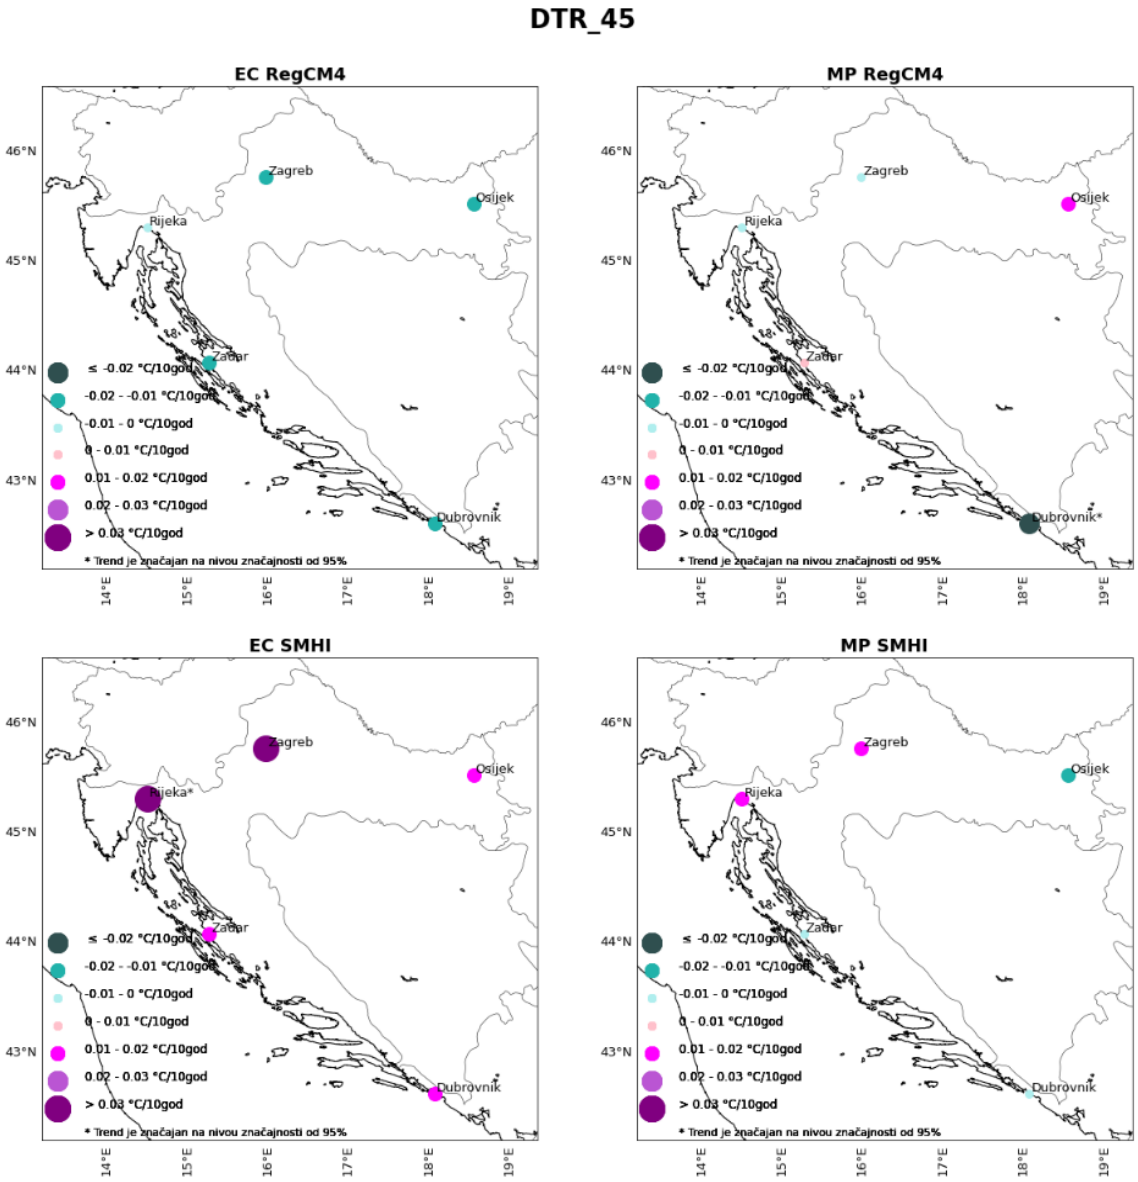

Slika 3.1: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *DTR* za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

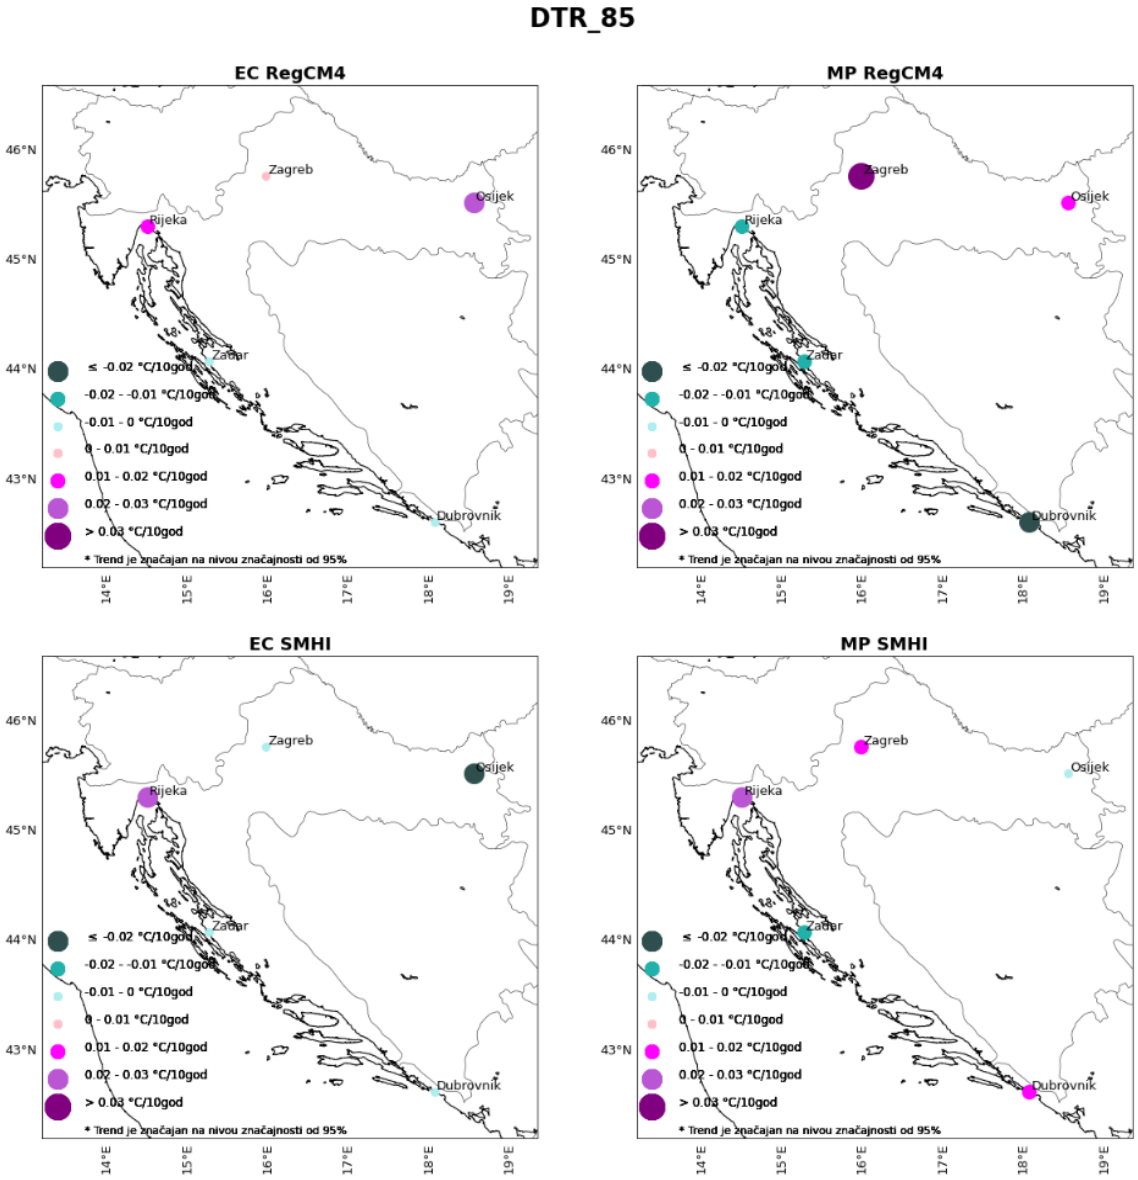

Slika 3.2: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *DTR* za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

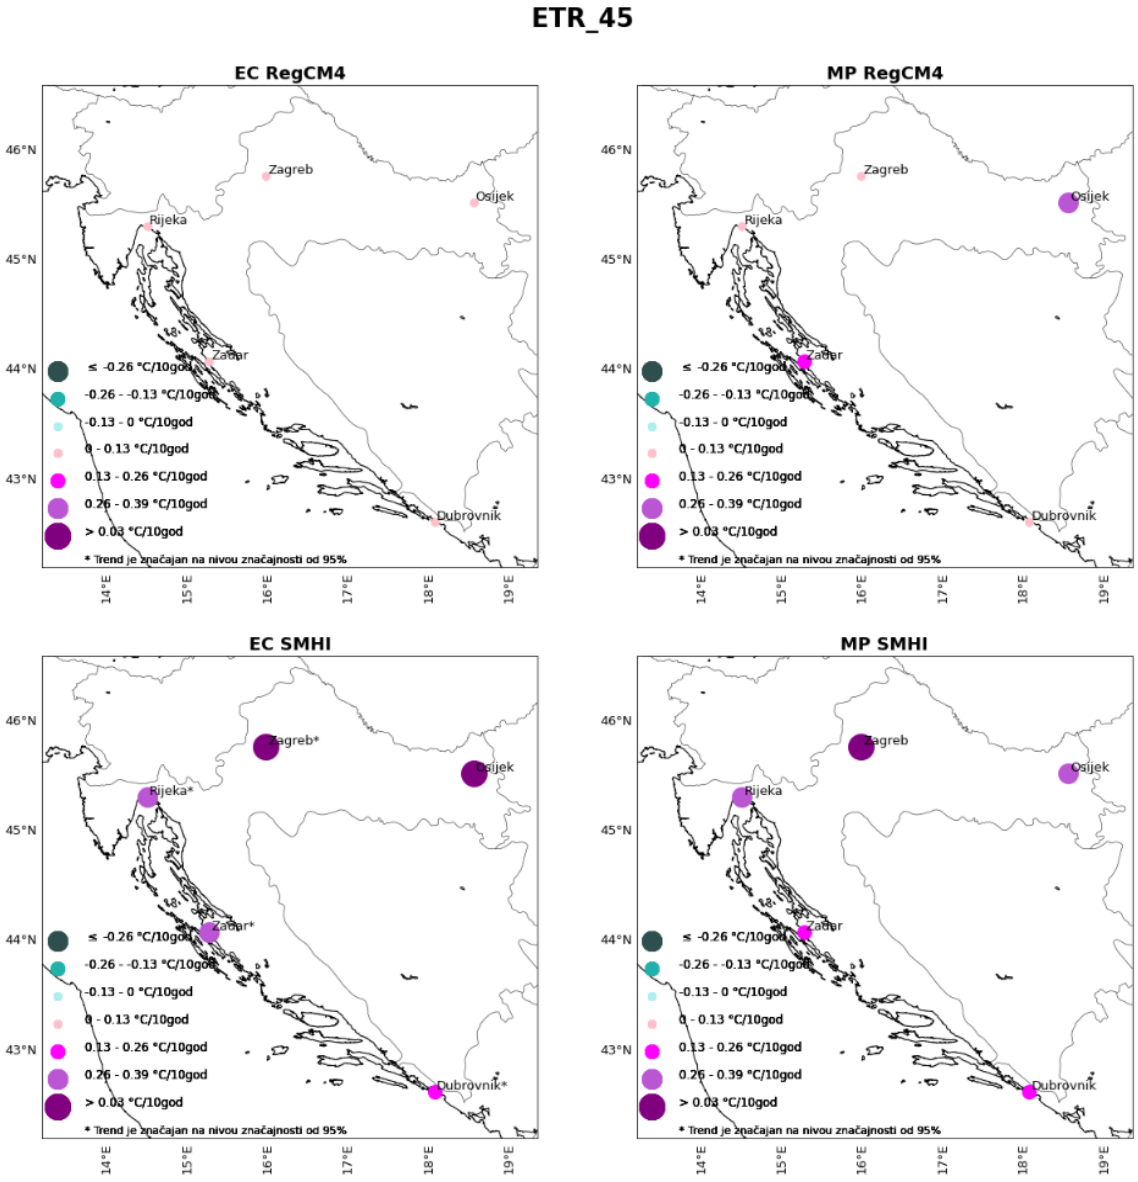

Slika 3.3: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *ETR* za scenarij RCP 4.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

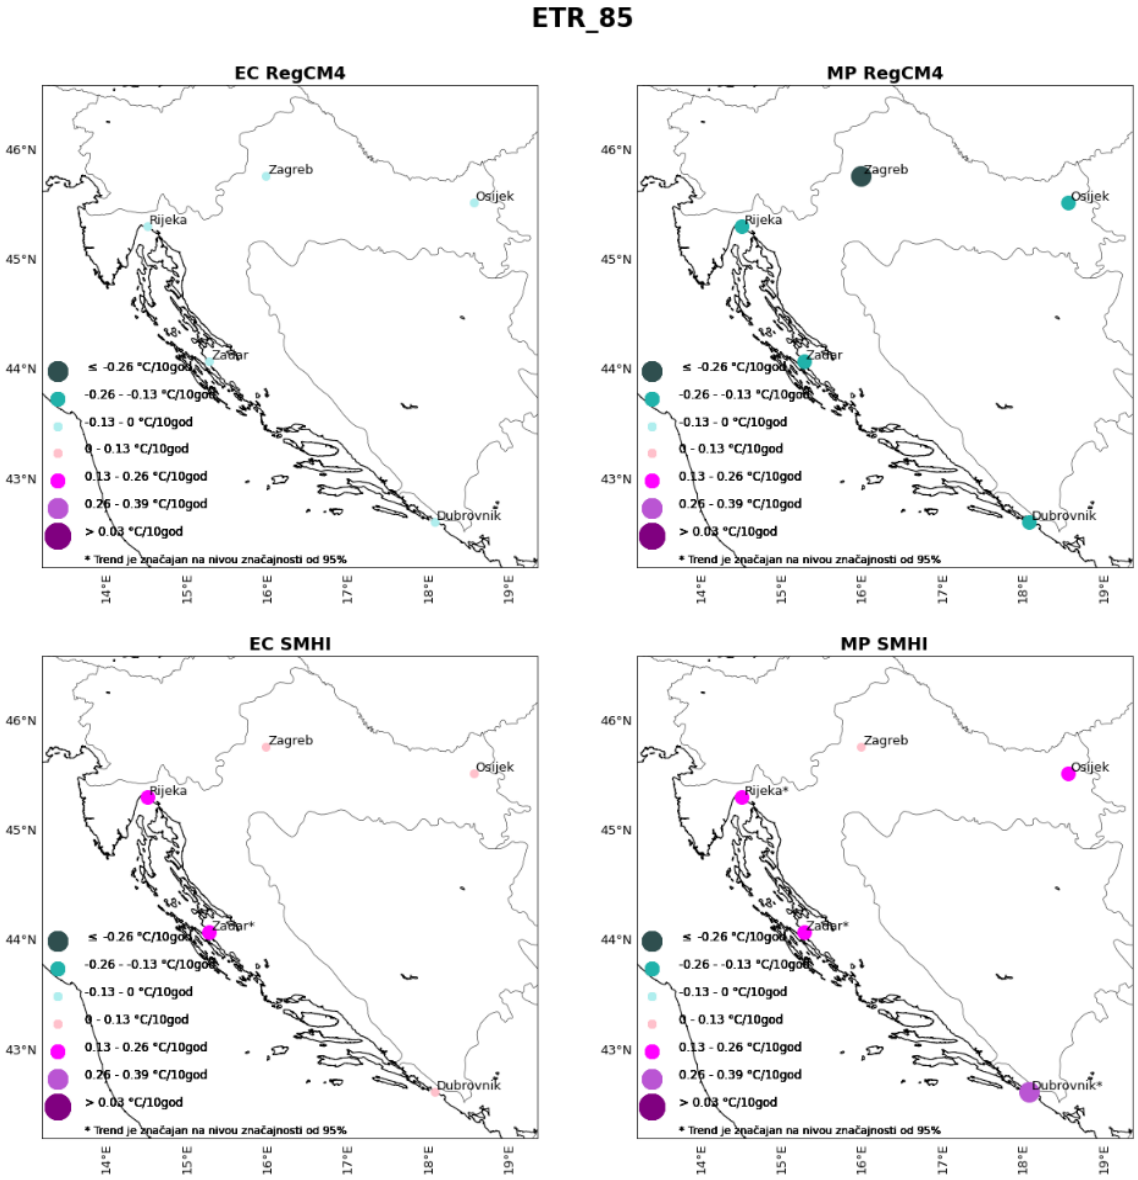

Slika 3.4: Karte Hrvatske s ucrtanim promatranim postajama i intervalima trenda izraženim u °C/10 god. za indeks *ETR* za scenarij RCP 8.5 i različite kombinacije RCM-GCM. Postaja na kojoj je trend značajan na nivou značajnosti od 95 % označena je zvjezdicom.

Tablica 3.1: Linearni trendovi indeksa *DTR* i *ETR* u Dubrovniku, Zadru, Rijeci, Zagrebu i Osijeku prema simulacijama RCM RegCM4 i SMHI-RCA4 forsiranih GCM-ima EC i MP u scenarijima RCP 4.5 i RCP 8.5. Vrijednosti su dane u jedinicama °C/10 god.

	RCP 4.5		RCP 8.5	
	DTR	ETR	DTR	ETR
Dubrovnik	+0.01 - -0.02	0.03 - 0.22	+0.02 - -0.02	+0.31 - -0.20
Zadar	+0.02 - -0.01	0.09 - 0.27	-0.00 - -0.01	+0.25 - -0.15
Rijeka	+0.05 - -0.01	0.03 - 0.37	+0.02 - -0.01	+0.25 - -0.07
Zagreb	+0.03 - -0.02	0.10 - 0.76	+0.03 - -0.01	+0.09 - -0.35
Osijek	+0.01 - -0.02	0.10 - 0.39	+0.02 - -0.02	+0.14 - -0.15

Vrijednosti trendova indeksa *DTR* i *ETR* su općenito vrlo niske što upućuje na male promjene raspona dnevnih, odnosno godišnjih temperatura. To nam s druge strane ukazuje da je očekivano povećanje minimalne i maksimalne temperature zraka podjednako (slike C1 – C5).

4. Zaključak

U ovom je radu istraženo buduće toplinsko opterećenje u Dubrovniku, Zadru, Rijeci, Zagrebu i Osijeku usporedbom podataka srednje, minimalne i maksimalne temperature zraka na 2 m visine te na temelju klimatskih indeksa *DTR, ETR, FD, ID, TR* i *SU*. Promatrano je stanje simulirane buduće klime, u razdoblju P2 (2041. – 2070. god.) u odnosu na dosadašnju, iz razdoblja P0 (1991. – 2020. god.). Analizirane su simulacije dvaju različitih regionalnih klimatskih modela, RegCM4 i SMHI-RCA4, horizontalne rezolucije 12.5 km u kombinaciji sa po dva CMIP5 globalna klimatska modela, EC-EARTH i MPI-ESM-MR, za dva različita scenarija buduće klime, RCP 4.5 i RCP 8.5.

Iz navedenih se simulacija, prema očekivanjima, primjećuje značajno povećanje srednjih, maksimalnih i minimalnih temperatura zraka na 2 m visine u razdoblju P2 u odnosu na P0 u svim kombinacijama klimatskih modela, promatranih gradova i scenarija. Ovo povećanje je statistički značajno i veće je za scenarij RCP 8.5 nego za RCP 4.5. Računanjem višegodišnjih mjesečnih srednjaka varijabli *tas*, *tasmax* i *tasmin* pokazalo se da je najveće povećanje navedenih temperatura uglavnom u toplim dijelovima godine. Nadalje, od promatranih pet gradova, u Dubrovniku i Rijeci je simuliran najbrži porast *tas*, *tasmax* i *tasmin* pa se prema dobivenim rezultatima u tim gradovima može očekivati najizraženiji porast toplinskog opterećenja u budućnosti. U Dubrovniku bi se u budućnosti, u razdoblju P2, mogao očekivati porast srednje godišnje temperature zraka između 0.21 i 0.39 °C/10 god., veći godišnji srednjak maksimalne dnevne temperature zraka za 0.20 – 0.38 °C/0 god. te porast godišnjeg srednjaka minimalne dnevne temperature zraka između 0.20 i 0.40 °C svakih 10 godina. U Osijeku bi srednja temperatura mogla porasti između 0.18 i 0.37 °C/10 god., maksimalna između 0.19 i 0.39 °C/10 god., a minimalna između 0.18 i 0.38 °C/ 10 god. Rijeka bi mogla imati srednju temperaturu veću za 0.23 – 0.39 °C/10 god., maksimalnu za 0.23 – 0.41 °C/10 god. i minimalnu 0.20 – 0.40 °C/10 god., a u Zadru bi se *tas* povećavao za 0.18 – 0.37 °C/10 god. i *tasmax* i *tasmin* za 0.18 – 0.38 °C svakih 10 godina. U Zagrebu bi se mogao očekivati porast srednje godišnje temperature zraka između 0.20 i

0.38 °C svakih 10 godina, maksimalne između 0.20 i 0.39 °C/10 god. i minimalne 0.21 – 0.37 °C/10 god. s time da svugdje veće vrijednosti odgovaraju scenariju RCP 8.5.

Za sve promatrane gradove pokazan je porast broja dana s maksimalnom temperaturom zraka iznad 25 °C (indeks *SU*), a najveći porast je dobiven za Dubrovnik. Također se pokazao i porast broja dana s minimalnom temperaturom zraka iznad 20 °C (indeks *TR*) koji je najizraženiji u gradovima u priobalnom području (posebice Rijeci i Zadru), a nešto blaži u promatranim gradovima kontinentalnog područja. Ovakvi klimatski uvjeti pridonose pojavi suša te su povezani s većom potrebom za navodnjavanjem. Stoga se navodnjavanje nameće kao problem za koji će biti potrebno naći adekvatna rješenja u budućnosti, posebno ako se uzmu u obzir klimatske projekcije prema kojima se mogu očekivati sve intenzivnija i dugotrajnija sušna razdoblja. Osim toga, visoke temperature imaju negativan utjecaj na ljudsko zdravlje, posebice kroničnih bolesnika (McMichael i Lindgren, 2011). S obzirom na to da bi i noći i dani postali topliji, mogu se očekivati i sve češći, dugotrajniji i izraženiji toplinski valovi što povećava veći rizik od požara (IPCC, 2021). Također, rezultati ukazuju na očekivano smanjenje dana s minimalnom temperaturom ispod 0 °C (indeks *FD*) i maksimalnom temperaturom ispod 0 °C (indeks *ID*). Najizraženije smanjenje je dobiveno za gradove kontinentalnih predjela, tj. za Zagreb i Osijek, dok gradovi u obalnom području ne pokazuju tako značajno smanjenje tih indeksa, ali tamo je ionako vrlo mali broj takvih dana pa se niti ne očekuje značajan negativan trend. Pri temperaturi većoj od 0 °C onemogućeno je zadržavanja snijega i leda na tlu što uzrokuje slabiju izolaciju biljaka zimi (Soong i sur., 2020) i veći rizik od negativnog utjecaja hladnoće. S druge strane, toplije tlo u zimskoj sezoni podržava razvoj raznih nametnika koji prenose bolesti kao što su krpelji i komarci (Patz i sur., 2003; McMichael i Lindgren, 2011), ali i nametnika na biljkama (Pritchard, 2011; Huang, 2016). Negativne posljedice takvih uvjeta su višestruke, od zdravstvenih, gospodarskih i ekonomskih.

Iznosi trendova godišnjih srednjaka raspona dnevnih ekstremnih temperatura (indeks *DTR*; godišnji srednjak razlike između maksimalne i

minimalne dnevne temperature) i trendova raspona godišnjih ekstremnih temperatura (indeks *ETR*; razlika između maksimalne i minimalne godišnje temperature) su mali što ukazuje na to da se ne očekuju značajne promjene u rasponu dnevnih, odnosno godišnjih temperatura. Taj nam rezultat s druge strane ukazuje na podjednak porast minimalne i maksimalne temperature zraka, tj. upućuje na podjednaku stopu povećavanja minimalnih i maksimalnih temperatura zraka.

Prilagodba modeliranih i izmjerenih vrijednosti je ukazala na njihovo dobro podudaranje što opravdava upotrebu ovih modela za istraživanje. Ipak, potrebno je naglasiti da se rezultati različitih kombinacija RCM-a i GCM-a nisu uvijek podudarali. Primjerice, ne može se pouzdano reći u kojem mjesecu se očekuje najveće povećanje srednje, minimalne i maksimalne temperature jer se ne uočavaju pravilnosti, kombinacije modela daju različite vrijednosti. Ipak, u većini slučajeva ovaj se porast pokazao najvećim u toplijem dijelu godine.

Također, rezultati na temelju modela RegCM4 govore o većim trendovima *tas* i *tasmax* u priobalnom području u odnosu na one u kontinentalnom području, dok se korištenjem SMHI RCM-a pokazao jači signal zagrijavanja u gradovima iz kontinentalnog područja u odnosu na one iz priobalnog. Dakle, ovaj rezultat nije robustan s obzirom na izbor modela. Stoga možemo zaključiti da se svakako očekuje pozitivan trend *tas* i *tasmax*, ali ne možemo zaključiti hoće li on biti izraženiji u priobalnom ili kontinentalnom dijelu Hrvatske. Porast *tasmin* je prema rezultatima modela RegCM4 veći od onoga koji daje model SMHI. Za scenarij RCP 8.5 se pokazalo kako RegCM4 simulira smanjenje indeksa *ETR*, dok SMHI daje povećanje istog indeksa. Rezultati su ovisni i o izboru globalnog modela. Primjerice, korištenje globalnog modela EC pak daje manje razlike u trendu *tas*, *tasmax* i *tasmin* između dva promatrana scenarija. Na temelju ovih rezultata možemo zaključiti da će toplinsko opterećenje rasti u promatranim gradovima. Ipak, svakako bi trebalo analizirati i uzeti u obzir i simulacije drugih kombinacija regionalnih i globalnih klimatskih modela ili pak njihovog ansambla kako bi se napravila detaljnija analiza.

Popis kratica

C2ES	Centar za klimatska i energetska rješenja (Center for Climate and Energy Solutions)
CDO	Skup računalnih operatora za obradu klimatskih podataka (engl. *Climate Data Operators*)
CMIP5	Peta generacija projekta međusobne usporedbe klimatskih modela (engl. *Coupled Model Intercomparison Project, Phase 5*)
CORDEX	Koordinirani eksperiment regionalne klime dinamičkom prilagodbom (engl. *Coordinated Regional Climate Downscaling Experiment*)
DHMZ	Državni hidrometeorološki zavod
DTR	Indeks dnevnog raspona temperature(engl. *Daily Temperature range*)
EC (EC-EARTH)	Globalni klimatski model europskog (nizozemskog) konzorcija
ETR	Indeks ekstremnog raspona temperature (engl. *Extreme Temperature range*)
FD	Indeks mraznih dana (engl. *Frost Days*)
GCM	Globalni klimatski model (engl. *Global Climate Model*)

GO-ESSP	Globalna organizacija za znanstvene portale o sustavu Zemlje (engl. *The Global Organization of Earth System Science Portals*)
ICTP	Međunarodni centar za teorijsku fiziku, Trst, Italija (engl. *International Centre for Theoretical Physics*)
ID	Indeks ledenih dana (engl. *Icing Days*)
IPCC	Međuvladino tijelo za klimatske promjene (engl. *Intergovernmental Panel on Climate Change*)
MP (MPI-ESM-MR)	Globalni klimatski model njemačkog instituta za meteorologiju Max-Planck (njem. *Max-Planck Institut für Meteorologie*, MPI, Hamburg, Njemačka)
P0	Vremensko razdoblje između 1991. – 2020. god., referentno vremensko razdoblje
P1	Vremensko razdoblje između 2021. – 2040. god.
P2	Vremensko razdoblje između 2041. – 2070. god.
RCM	Regionalni klimatski model (engl. *Regional Climate Model*)
RCP	Reprezentativne trajektorije koncentracije stakleničkih plinova (engl. *Representative Concentration Pathways*)
RegCM4	Naziv regionalnog klimatskog modela ICTP-ja
RH	Republika Hrvatska

S	Mann-Kendallov rezultat
SMHI (SMHI-RCA4)	Regionalni atmosferski klimatski model Rossbijevog centra (engl. *Swedish Meteorological and Hydrological Institute-Rossby Centre Regional Atmospheric Climate Model*)
SU	Indeks ljetnih dana (engl. *Summer Days*)
tas	Srednja dnevna temperatura zraka na 2 m visine
tasmax	Maksimalna dnevna temperatura zraka na 2 m visine
tasmin	Minimalna dnevna temperatura zraka na 2 m visine
TR	Indeks tropskih noći (engl. *Tropical Nights*)
UHI	Urbani toplinski otok (engl. *Urban Heat Island*)
UN	Ujedinjeni narodi (engl. *United Nations*)
VAR	Varijanca
WCRP	Svjetski program za istraživanje klime (engl. *World Climate Research Programme*)
Z_{MK}	Statistika Mann-Kendallovog testa

Literatura

Beniston, M., Stephenson, D. B., Christensen, O. B., Ferro, C. A. T., Frei, C., Goyette, S., Halsanes, K., Holt, T., Jylhä, K., Koffi, B., Palutikof, J., Schöll, R., Semmler, T., Woth, K. (2007) Future extreme events in European climate: an exploration of regional climate model projections. Climatic Change, 81, 71–95. Dostupno na: https://doi.org/10.1007/s10584-006-9226-z [9. ožujka 2021.]

Branković, Č., Güttler, I., Srnec, L., Stilinović, T. (2017) *Strategija prilagodbe klimatskim promjenama: Podaktivnost 2.2.1. Rezultati klimatskog modeliranja na sustavu HPC VELEbit za potrebe izrade nacrta Strategije prilagodbe klimatskim promjenama Republike Hrvatske do 2040. I s pogledom na 2070. I Akcijskog plana*. Projekt, ugovor TF/HR/P3-M1-O1-0101. Zagreb: Središnja agencija za financiranje i ugovaranje programa i projekata Europske unije (SAFU); Ministarstvo zaštite okoliša i energetike (MZOE); EPTISA Adria d.o.o.; Državni hidrometeorološki zavod (DHMZ).

Center for Climate and Energy Solutions: Drought and Climate Change (2021) Dostupno na: https://www.c2es.org/content/drought-and-climate-change/ [15. rujna 2021.]

Climdex: Indices (2021) Dostupno na: https://www.climdex.org/learn/indices/ [10. kolovoza 2021.]

Copernicus: CORDEX regional climate model data on single levels (2018) Dostupno na: https://cds.climate.copernicus.eu/cdsapp#!/dataset/projections-cordex-domains-single-levels?tab=form [2. kolovoza 2021.]

Cuxart, J., Bougeault, P., Redelsperger, J. L. (2000) A turbulence scheme allowing for mesoscale and large-eddy simulations. *Quarterly Journal of the Royal Meteorological Society,* 126(562), 1–30.

Dickinson, R. E., Henderson-Sellers, A., Kennedy, P. J. (1993) Biosphere-Atmosphere Transfer Scheme (BATS) version 1E as coupled to the NCAR Community Climate Model. *NCAR Tech. rep.* TN-387+STR, 72 pp.

Državni zavod za statistiku republike Hrvatske (2020) *Hrvatska u brojkama 2020* [online]. Zagreb: Državni zavod za statistiku Republike Hrvatske. Dostupno na: https://www.dzs.hr/Hrv_Eng/CroInFig/croinfig_2020.pdf [22. rujna 2021.]

EC EARTH (2021) about EC-Earth. Dostupno na: https://www.ec-earth.org/index.php/about [24. rujna 2021.]

Encyclopedia Britannica: "Greenhouse effect" (2020) Dostupno na: https://www.britannica.com/science/greenhouse-effect [2. kolovoza 2021.]

Founda, D., Santamouris, M. (2017) Synergies between Urban Heat Island and Heat Waves in Athens (Greece), during an extremely hot summer (2012). *Scientific reports [online], 7(1).* Dostupno na: https://www.nature.com/articles/s41598-017-11407-6#citeas [22. rujna 2021.]

Gilbert, R. O. (1987*) Statistical Methods for Environmental Pollution Monitoring.* New York: Wiley.

Giorgi, F., Coppola, E., Solmon, F., Mariotti, L., Sylla, M. B., Bi, X., Elguindi, N., Diro, G. T., Nair, V., Giuliani, G., Cozzini, S., Güttler, I., O'Brien, T. A., Tawfik, A. B., Shalaby, A., Zakey, A. S., Steiner, A. L., Stordal, F., Sloan, L. C., Brankovic, C. (2012) RegCM4: Model description and preliminary tests over multiple CORDEX domains. Clim Res [online], 52, 7–29. Dostupno na: https://doi.org/10.3354/cr01018 [30. lipnja 2021.]

Grell, G. A. (1993) Prognostic evaluation of assumptions used by cumulus parameterizations. *Monthly Weather Review*, 121(3), 764–787.

Güttler, I., Srnec, L., Branković, Č., Kalinski, V. (2017.) Regionalno klimatsko modeliranje: Iskustva u korištenju VELEbita. Zagreb: Državni hidrometeorološki zavod. Dostupno na: https://www.srce.unizg.hr/files/srce/docs/dogadjanja/DEI2017/prezentacije/e-infra/guettler_etal_2017_srce_v20170405_v2.pdf [30. lipnja 2021.]

Hausfather, Z. (2018) Explainer: How 'Shared Socioeconomic Pathways' explore future climate change. Ujedinjeno Kraljevstvo, London: Carbon

Brief. Dostupno na: https://www.carbonbrief.org/explainer-how-shared-socioeconomic-pathways-explore-future-climate-change [30. lipnja 2021.]

Ho, C. K., Stephenson, D. B., Collins, M., Ferro, C. A. T., Brown, S. J. (2012) Calibration Strategies: A Source of Additional Uncertainty in Climate Change Projections. Bulletin of the American Meteorological Society, 93(1), 21–26. Dostupno na: https://doi.org/10.1175/2011BAMS3110.1 [8. rujna 2021.]

Holtslag, A. A. M., de Bruijn, E. I. F., Pan, H. L. (1990). A high resolution air mass transformation model for short-range weather forecasting. *Monthly Weather Review*, 118(8), 1561–1575.

Huang, J. (2016) Effects of soil temperature and snow cover on the mortality of overwintering pupae of the cotton bollworm, Helicoverpa armigera (Hübner) (Lepidoptera: Noctuidae). *International Journal of Biometeorology*, 60(7), 977-989.

ICTP: Regional model: REGCM4 (2021) Dostupno na: https://www.ictp.it/research/esp/models/regcm4.aspx [30. lipnja 2021.]

IPCC: Masson-Delmotte, V., Zhai, P., Pirani, A., Connors, S. L., Péan, C., Berger, S., Caud, N., Chen, Y., Goldfarb, L., Gomis, M. I., Huang, M., Leitzell, K., Lonnoy, E., Matthews, J. B. R., Maycock, T. K., Waterfield, T., Yelekçi, O., Yu, R. i Zhou, B. (ur.) (2021) *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change.* Cambridge University Press. In Press.

Jakovčić, P. (2012) *Projekcije klimatskih promjena u Europi prema jednom od scenarija emisije stakleničkih plinova.* Diplomski rad. Zagreb: Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet.

Jones, C. G., Sanchez, E. (2002) The representation of shallow cumulus convection and associated cloud fields in the Rossby Centre atmospheric model. *HIRLAM Newsletter*, 41.

Kain, J. S., Fritsch, J. M. (1990) A one-dimensional entraining/detraining plume model and its application in convective parameterization. *Journal of the Atmospheric Sciences*, 47(23), 2784–2802.

Kain, J. S., Fritsch, J. M. (1993) Convective parameterizations for mesoscale models: The Kain-Fritsch scheme. U: Emanuel, K. A., Raymond, D. J. (ur.), *The representation of cumulus convection in numerical models.* Boston: American Meteorological Society, str. 1-246.

Kain, J. S. (2004) The Kain–Fritsch Convective Parameterization: An Update. *Journal of Applied Meteorology and Climatology*, 43(1), 170–181.

Kiehl, J. T., Hack, J. J., Bonan, G. B., Boville, B. A., Briegleb, B. P., Williamson, D. L., Rasch, P. J. (1996). *Description of the NCAR Community Climate Model (CCM3)* (No. NCAR/TN-420+STR). University Corporation for Atmospheric Research.

Kendall, M. G. (1975) *Rank Correlation Methods*. Fourth edition. London: Charles Griffin.

Mann, H. B. (1945). Nonparametric Tests Against Trend. Econometrica [online], 13(3), 245–259. Dostupno na: https://doi.org/10.2307/1907187 [10. rujna 2021.]

Max-Planck Institut für Meteorologie (2021) MPI-ESM. Dostupno na: http://www.mpimet.mpg.de/en/science/models/mpi-esm/ [24. rujna 2021.]

McMichael, A. J., Lindgren, E. (2011) Climate change: present and future risks to health, and necessary responses. *Journal of Internal Medicine* [online], 270(5), 401-413. Dostupno na: https://onlinelibrary.wiley.com/doi/full/10.1111/j.1365-2796.2011.02415.x [20. rujna 2021.]

Met Office: UKCP18 Guidance: Bias correction (2018) Dostupno na: https://www.metoffice.gov.uk/binaries/content/assets/metofficegovuk/pdf/research/ukcp/ukcp18-guidance---how-to-bias-correct.pdf [8. rujna 2021.]

MZOE (2017) RegCM4, Projekt programa Prijelazni instrument tehničke pomoći EU: Jačanje kapaciteta Ministarstva zaštite okoliša i energetike za prilagodbu klimatskim promjenama te priprema Nacrta Strategije prilagodbe klimatskim promjenama (Broj ugovora: TF/HR/P3-M1-O1-010), Ministarstvo zaštite okoliša i energetike (MZOE), Zagreb.

Patarčić, M. (2021) Klima i klimatske promjene. Zagreb: Državni hidrometeorološki zavod. Dostupno na: https://meteo.hr/klima.php?section=klima_modeli&param=klima_promjene [30. lipnja 2021.]

Pal, J. S., Small, E. E., Eltahir, E. A. B. (2000) Simulation of regional scale water and energy budgets: Influence of a new moist physics scheme within RegCM. *Journal of Geophysical Research*, 105(D24), 29579–29594.

Patz, J. A., Githeko, A. K., McCarty, J. P., Hussein, S., Confalonieri, U., de Wet, N. (2003) CHAPTER 6 Climate change and infectious diseases. U: Campbell-Lendrum, D. H., Corvalan, C. F., Eloi, K. L., Scheraga, J. D., Woodward, A. (2003) *Climate Change and Human Health: risks and responses*, Geneva: World Health Organization (WHO), str. 103-132.

Pritchard, S. G. (2011) Soil organisms and global climate change. *Plant Pathology* [online], 60, 82–99. Dostupno na: https://bsppjournals.onlinelibrary.wiley.com/doi/epdf/10.1111/j.1365-3059.2010.02405.x [20. rujna 2021.]

Rasch, P. J., Kristjánsson, J. E. (1998) A comparison of the CCM3 model climate using diagnosed and predicted condensate parameterizations. *Journal of Climate*, 11(7), 1587–1614.

Samuelsson, P., Gollvik, S., Ullerstig, A. (2006) The land-surface scheme of the Rossby Centre regional atmospheric climate model (RCA3). *Report in Meteorology,* 122.

Sass, B. H., Rontu, L., Savijärvi, H., Räisänen, P. (1994) HIRLAM-2 Radiation scheme: Documentation and tests. *Hirlam technical report No 16.*

Savijärvi, H. (1990) A fast radiation scheme for mesoscale model and short-range forecast models. *Journal of Applied Meteorology,* 29, 437–447.

SMHI: Rossby Centre regional atmospheric model, RCA4 (2011) Dostupno na: https://www.smhi.se/en/research/research-departments/climate-research-at-the-rossby-centre/rossby-centre-regional-atmospheric-model-rca4-1.16562 [7. studeni 2021.]

Soong, J. L., Phillips, C. L., Ledna, C., Koven, C. D., Torn, M. S. (2020) CMIP5 Models Predict Rapid and Deep Soil Warming Over the 21st Century. *Journal of Geophysical Research: Biogeosciences [online],* 125(2), 2169-8953. Dostupno na: https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2019JG005266 [20. rujna 2021.]

SPC for Excel: Interpretation of Alpha and p-Value (2017) Dostupno na: https://www.spcforexcel.com/knowledge/basic-statistics/interpretation-alpha-and-p-value [20. rujna 2021.]

Srnec, L., Gašparac, G., Güttler, I. (2019) Interpretacija analize klimatskih promjena za planske potrebe upravljanja vodama. Zagreb: Državni hidrometeorološki zavod, Sektor za meteorološka istraživanja i razvoj, Služba za klimatologiju. Dostupno na: https://www.voda.hr/sites/default/files/dokumenti/interpretacija_analize_klimatskih_promjena_za_planske_potrebe_upravljanja_vodama.pdf [8. rujna 2021.]

Teutschbein, C., Seibert, J. (2012) Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. Journal of Hydrology, 456-457, 12–29. Dostupno na: https://doi.org/10.1016/j.jhydrol.2012.05.052 [8. rujna 2021.]

United Nations (UN) (2016). *Paris Agreement*. Paris: United Nations, pp.1-27.

United Nations (UN), Department of Economic and Social Affairs, Population Division (2019) World Urbanization Prospects 2018: Highlights (ST/ESA/SER.A/421) [online] https://population.un.org/wup/Publications/Files/WUP2018-Highlights.pdf [22. rujna 2021.]

Wong, P. P., Lai, P.C., Hart, M. (2016) Microclimate Variation of Urban Heat in a Small Community. *Procedia Environmental Sciences [online], 36, 180–183.* Dostupno na: https://www.sciencedirect.com/science/article/pii/S1878029616302328 [22. rujna 2021.]

Zaninović, K., Gajić-Čapka, M., Perčec Tadić, M., Vučetić, M., Milković, J., Bajić, A., Cindrić, K., Cvitan, L., Katušin, Z., Kaučić, D., Likso, T., Lončar, Ž., Mihajlović, D., Pandžić, K., Patarčić, M., Srnec, L., Vučetić, V. (2008) Klimatski atlas Hrvatske / Climate atlas of Croatia 1961–1990., 1971–2000. Zagreb: Državni hidrometeorološki zavod. Dostupno na: https://klima.hr/razno/publikacije/klimatski_atlas_hrvatske.pdf [17. rujna 2021.]

Dodatak A: Višegodišnji mjesečni srednjaci

U ovom dodatku su dani prikazi višegodišnjih mjesečnih srednjaka *tas*, *tasmax* i *tasmin* za sve promatrane gradove i kombinacije klimatskih modela. Zelenom bojom označene su vrijednosti iz referentnog razdoblja P0, one su jednake u oba scenarija i upravo odgovaraju višegodišnjim mjesečnim srednjacima mjerenja iz istog razdoblja. Vrijednosti iz razdoblja P2 označene su plavom bojom u slučaju scenarija RCP 4.5 i crvenom u slučaju scenarija RCP 8.5.

a)

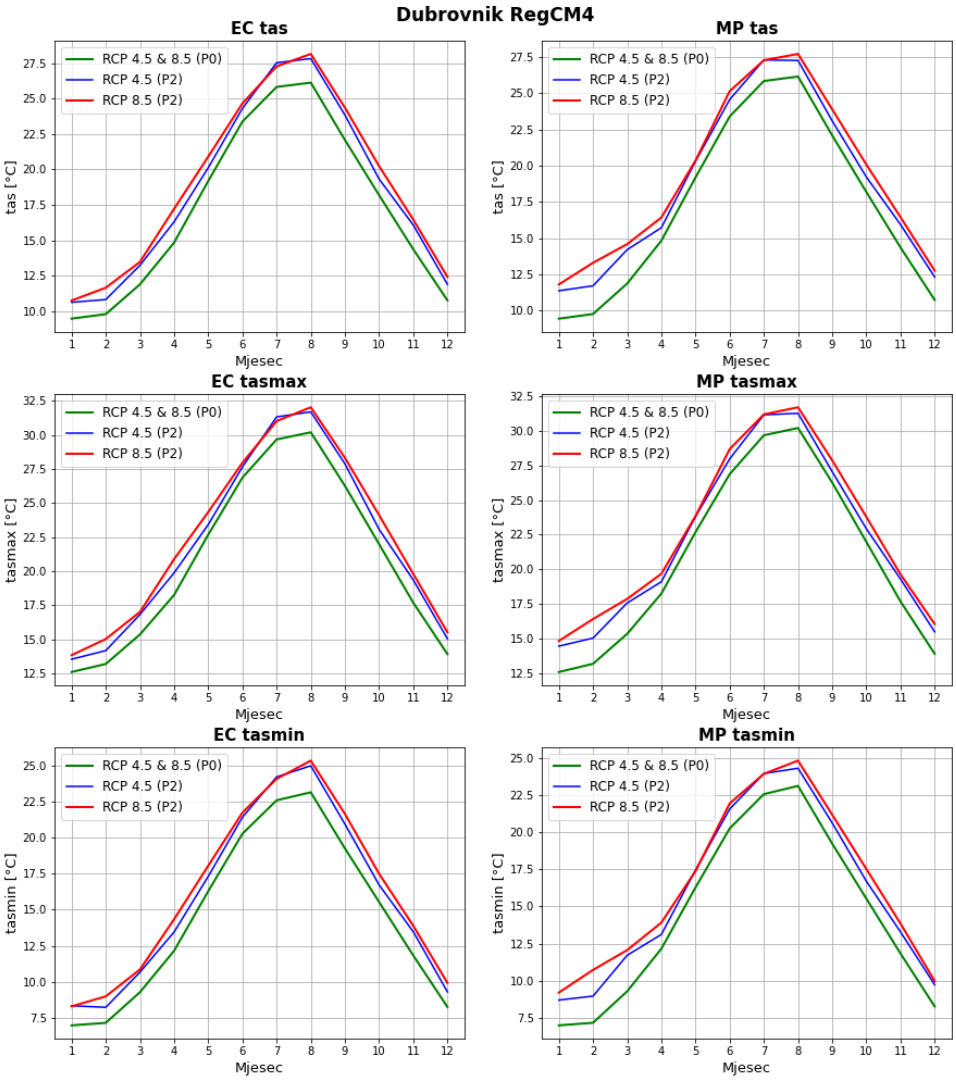

b)

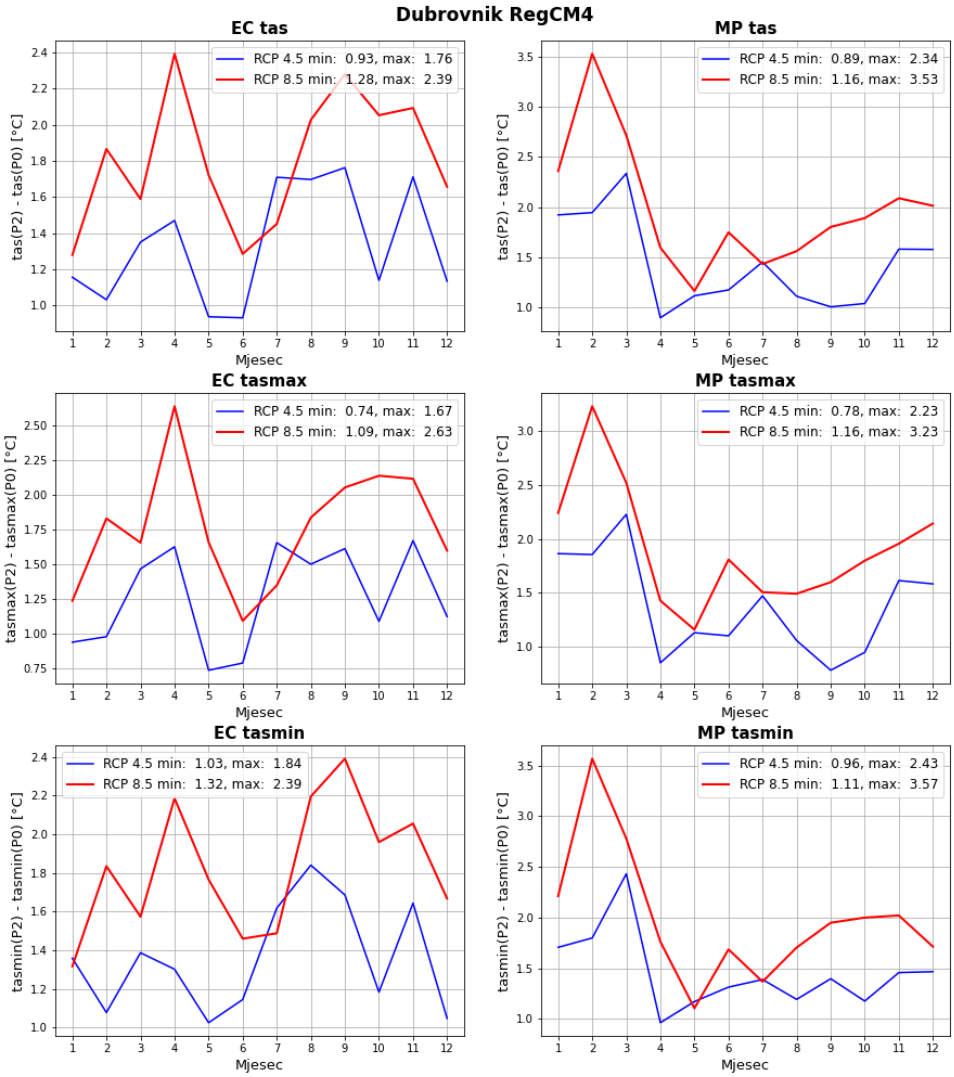

Slika A1: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om RegCM4 forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Dubrovnik. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

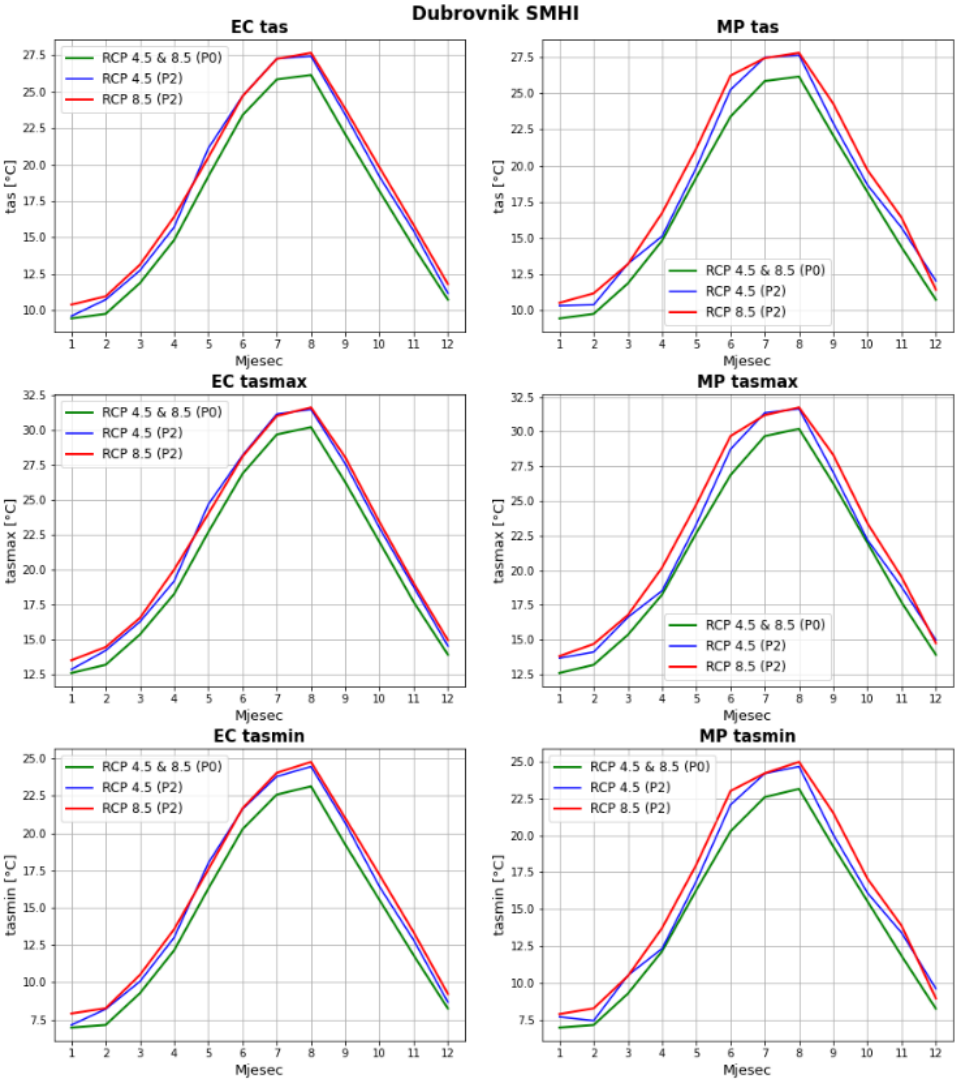
Dubrovnik SMHI
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec

b)

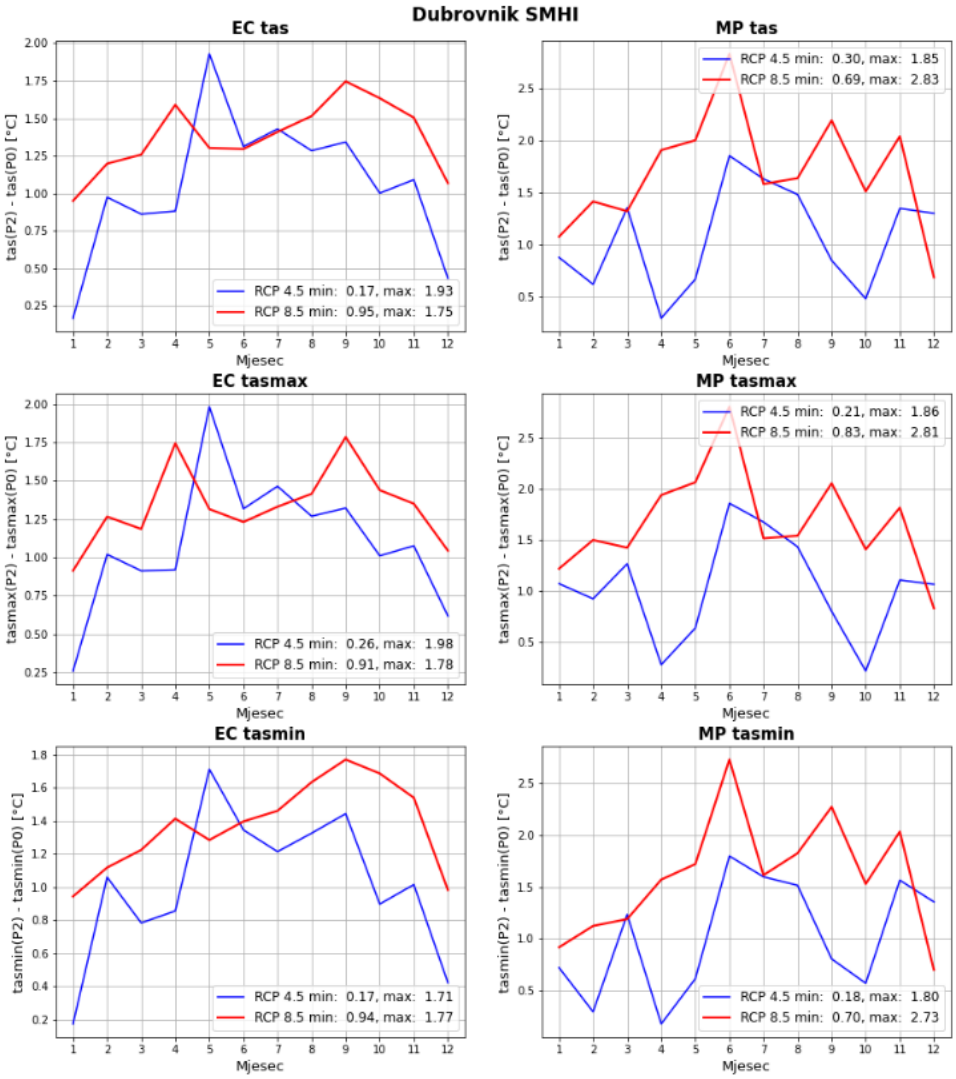

Slika A2: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om SMHI forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Dubrovnik. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

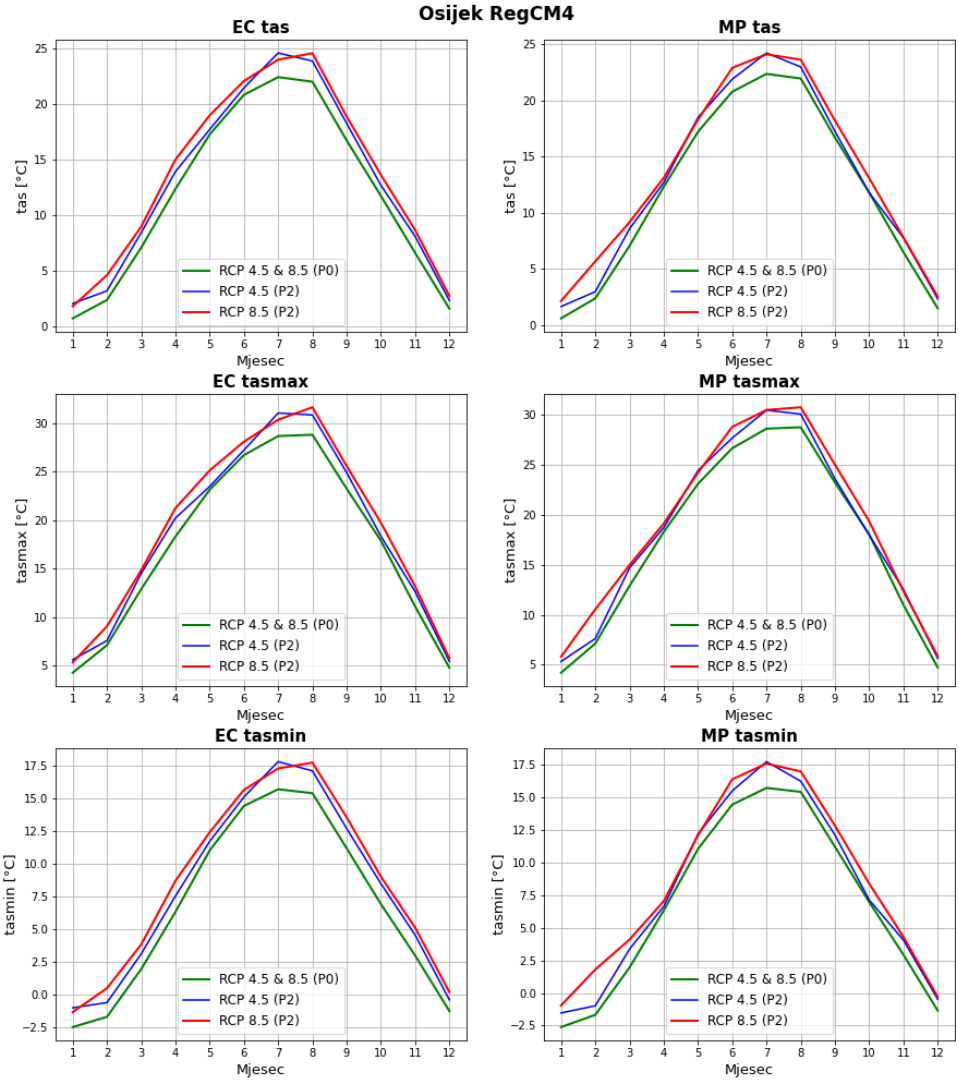
Osijek RegCM4
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)

b)

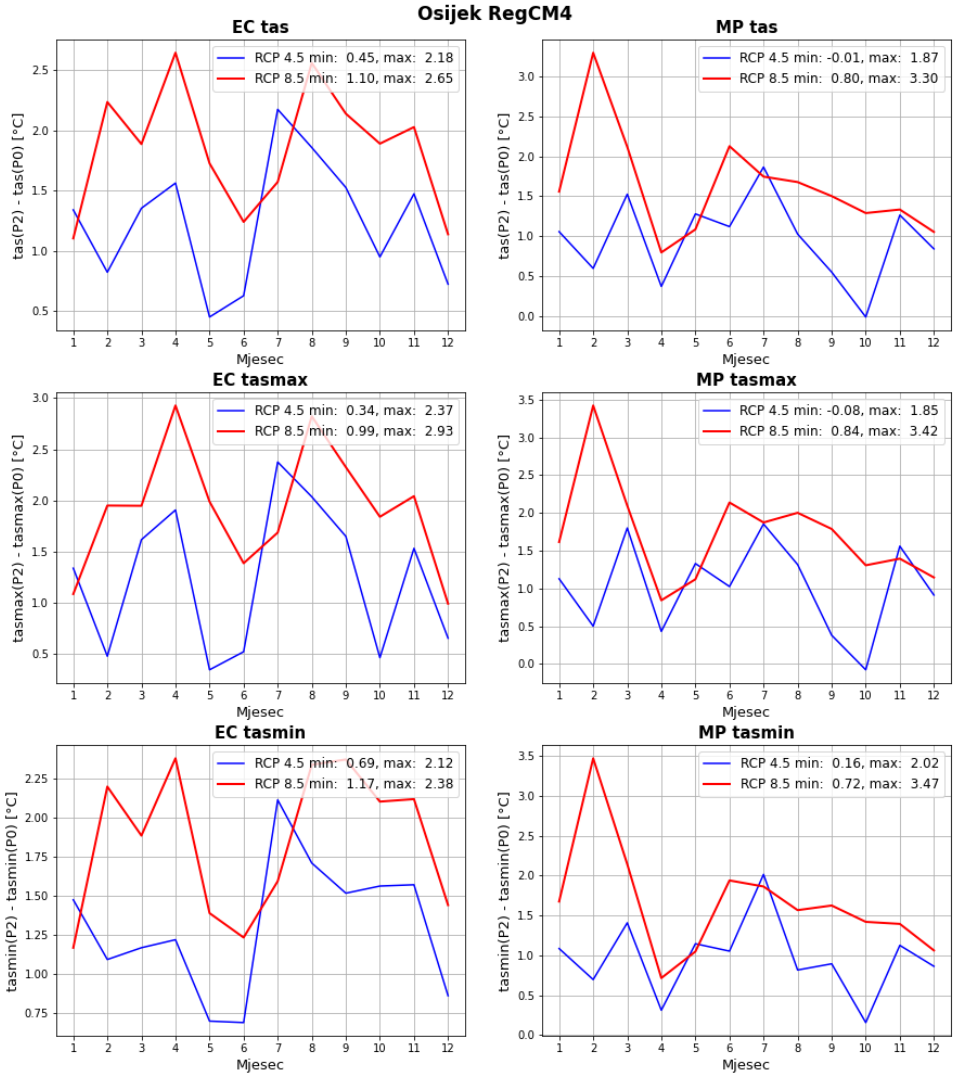

Slika A3: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om RegCM4 forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Osijek. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

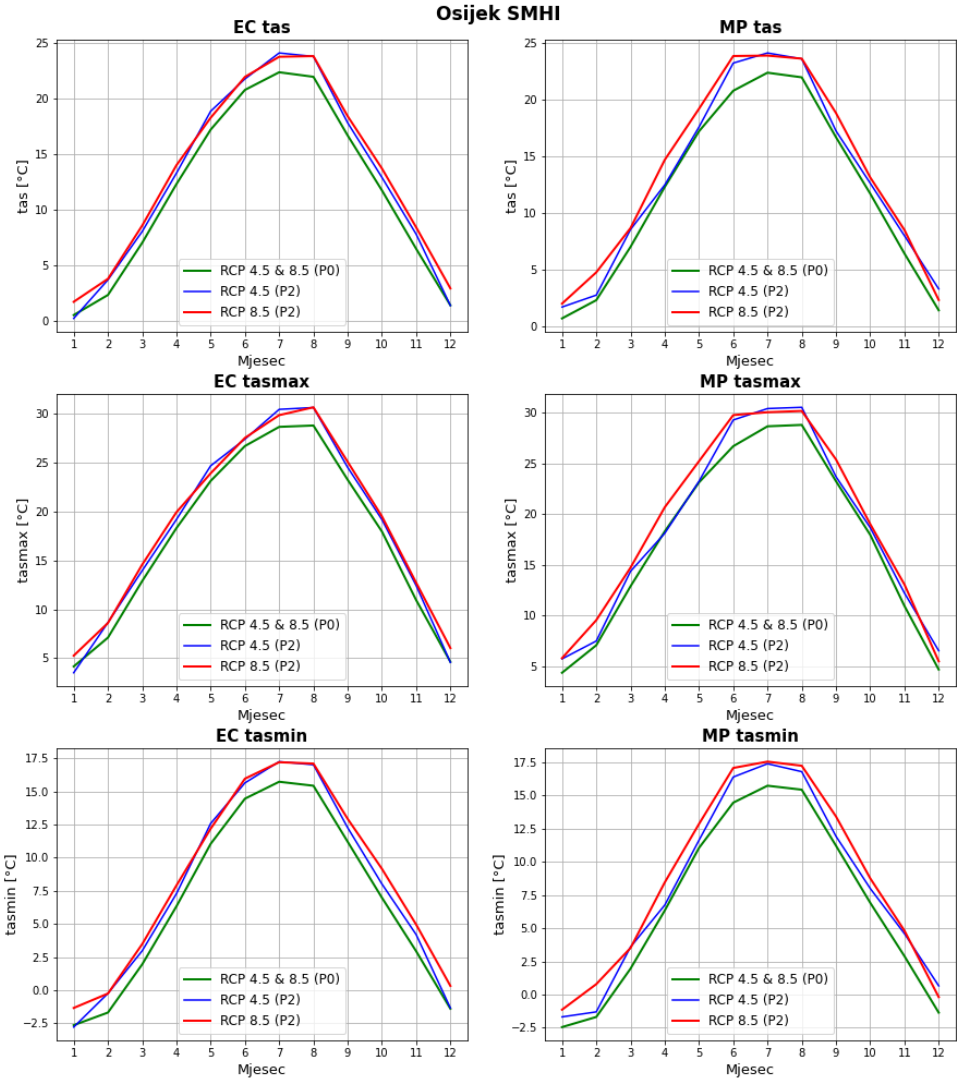
Osijek SMHI
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)

b)

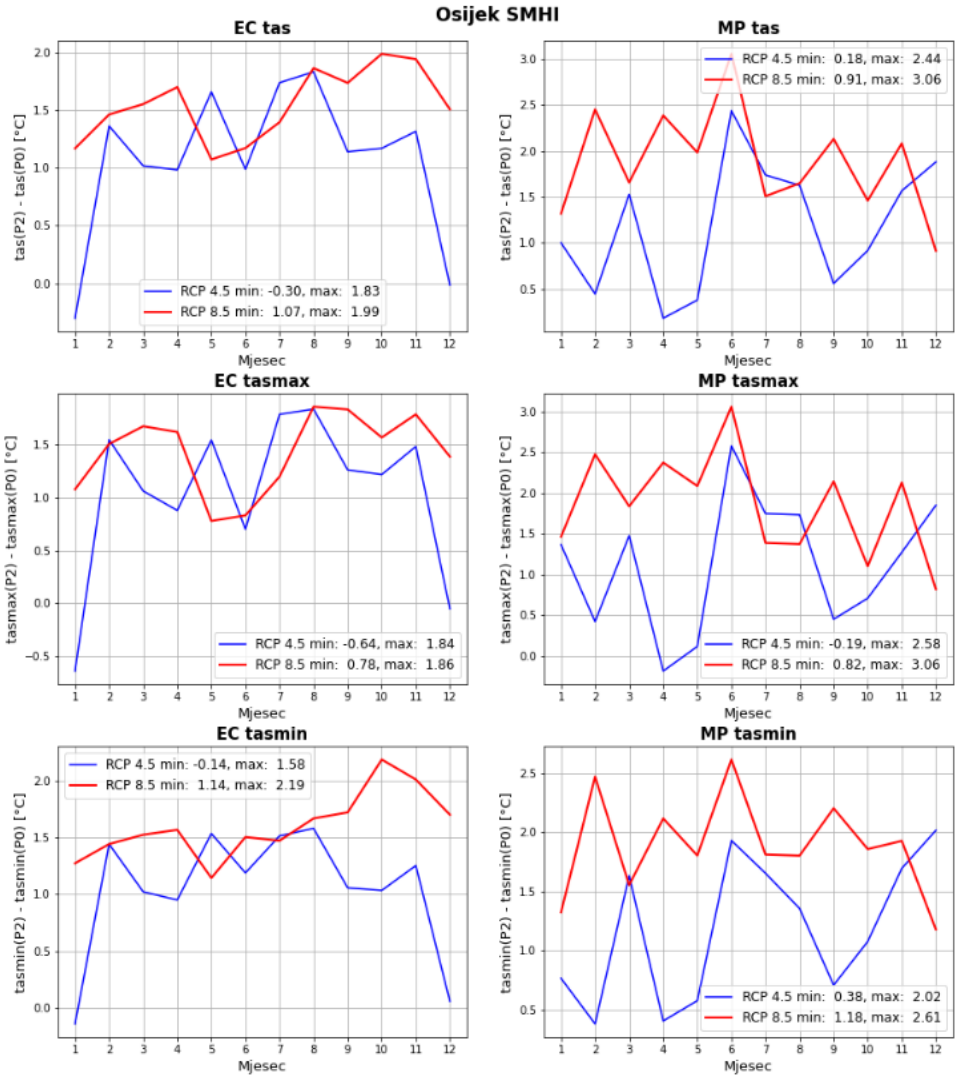

Slika A4: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om SMHI forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Osijek. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

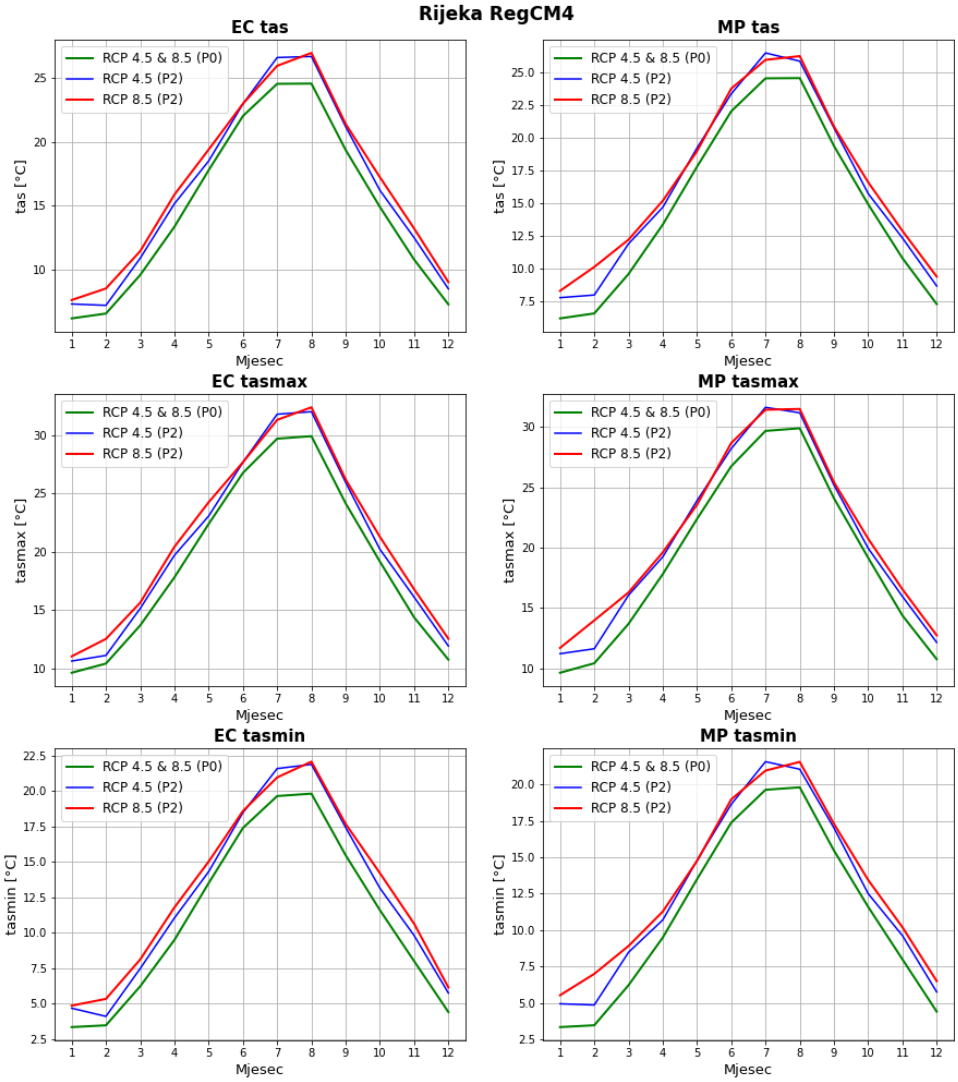
Rijeka RegCM4
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec

b)

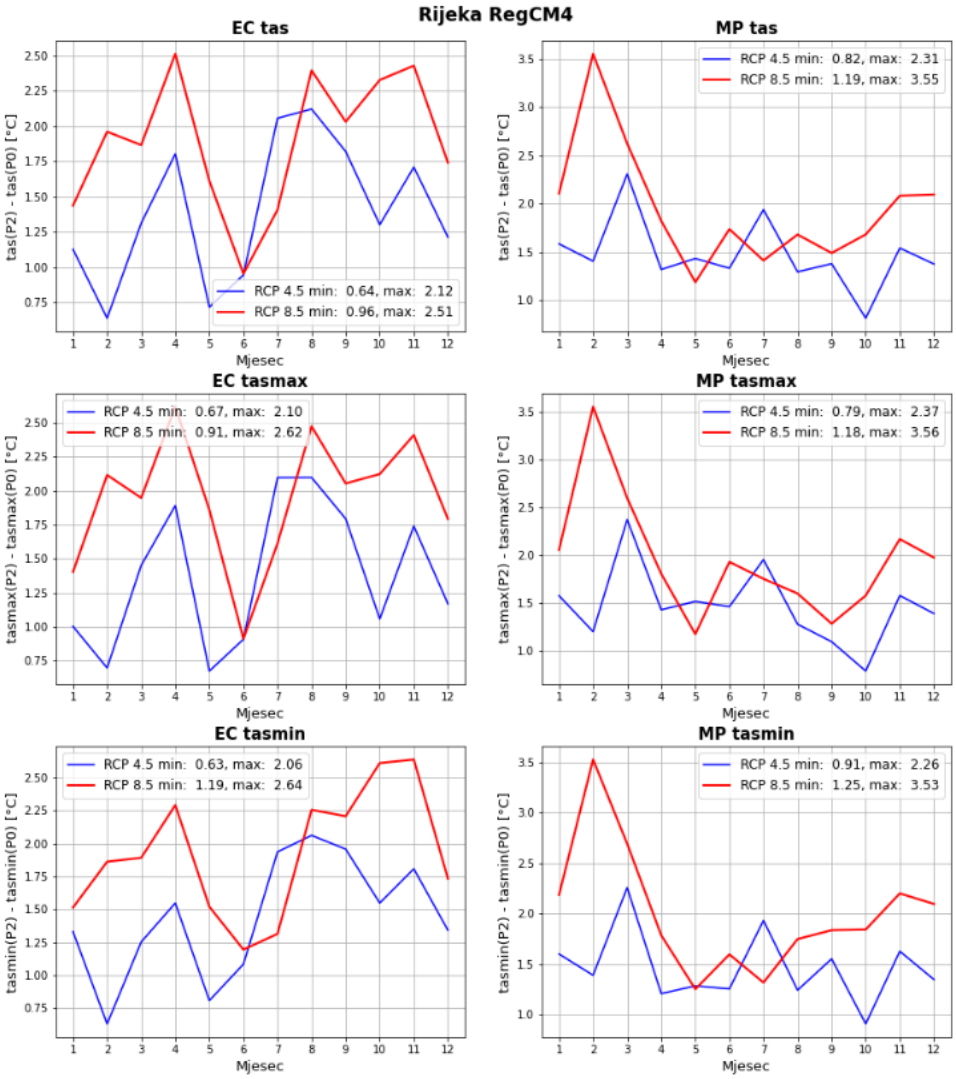

Slika A5: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om RegCM4 forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Rijeku. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

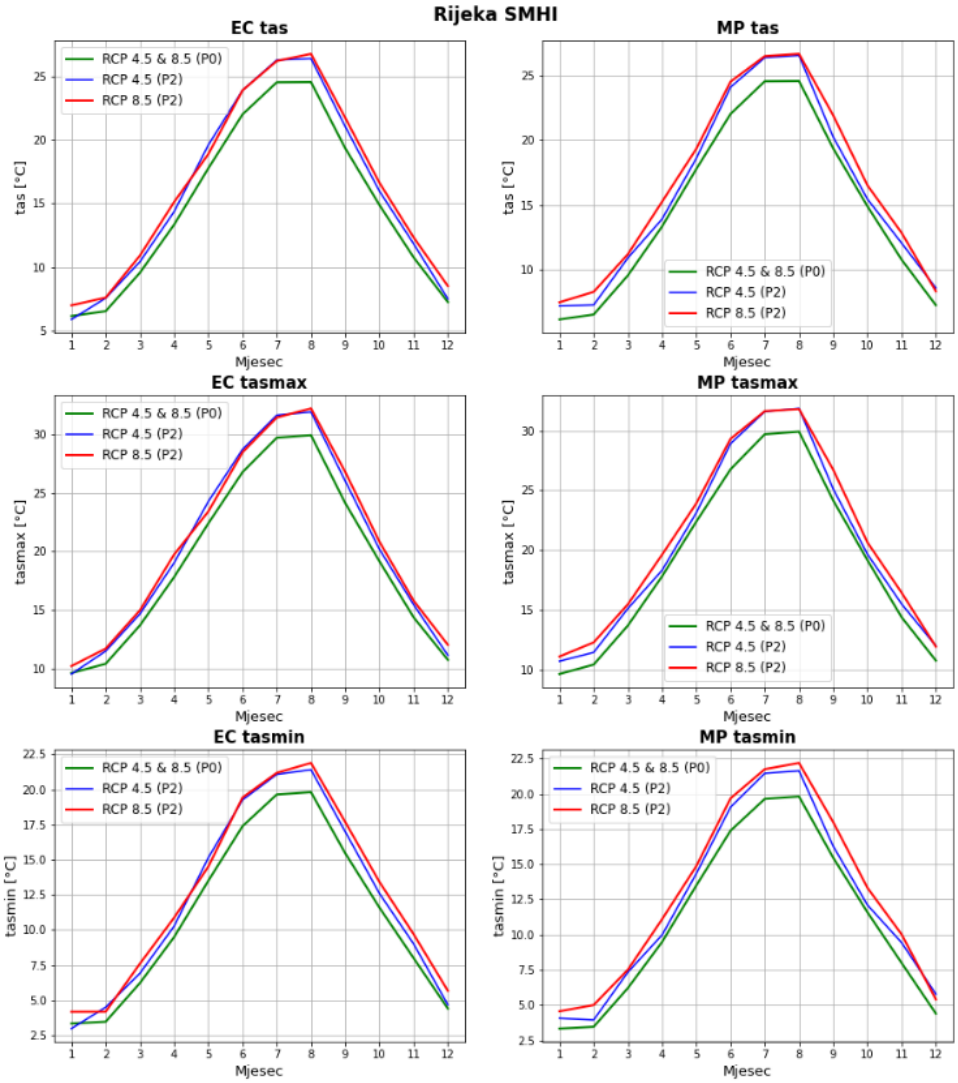
Rijeka SMHI
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec

b)

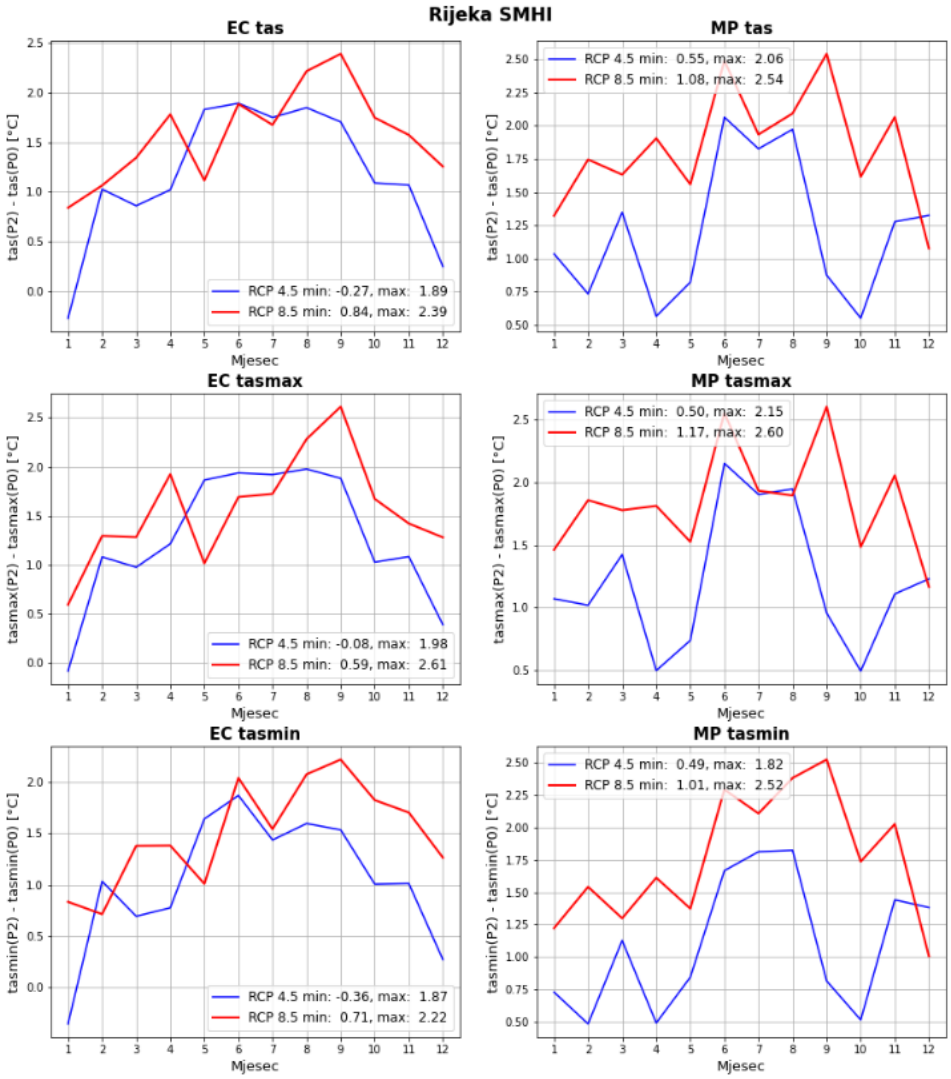

Slika A6: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om SMHI forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Rijeku. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

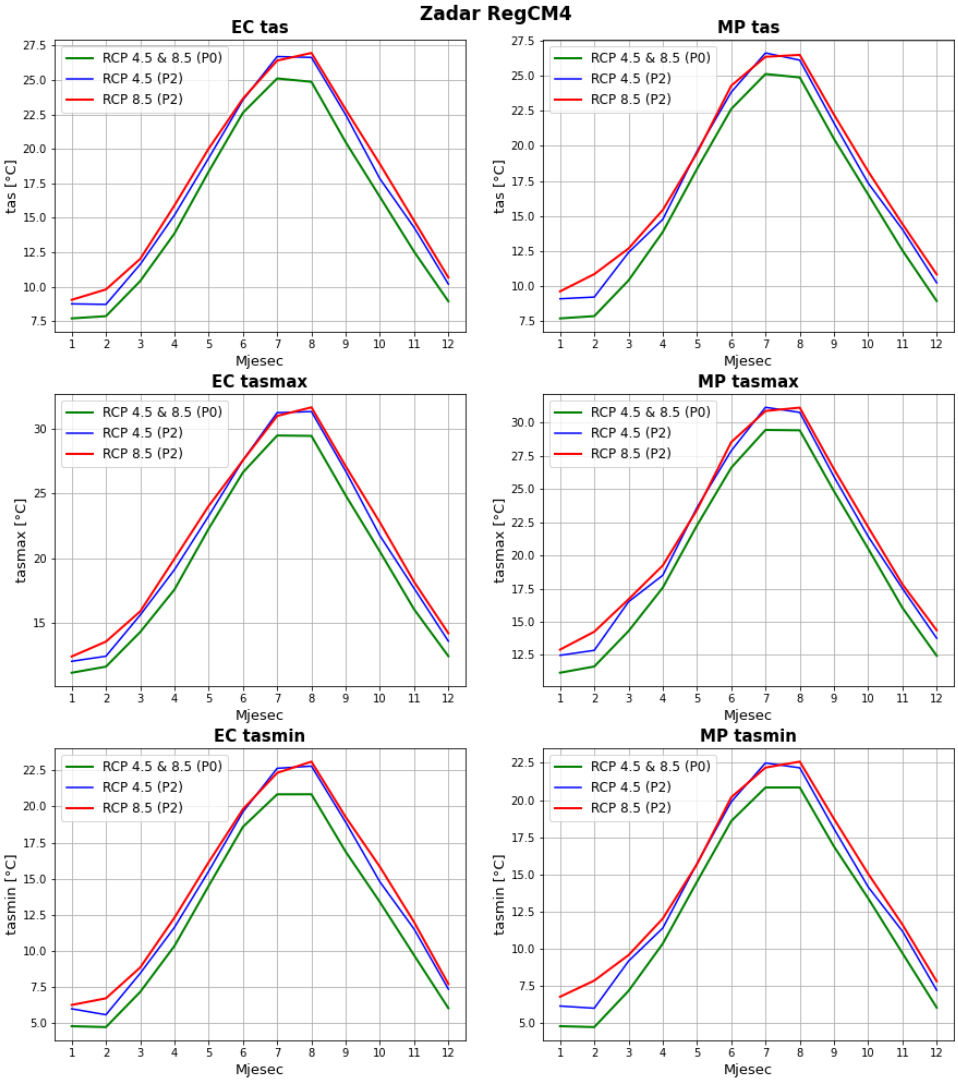
Zadar RegCM4
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec

b)

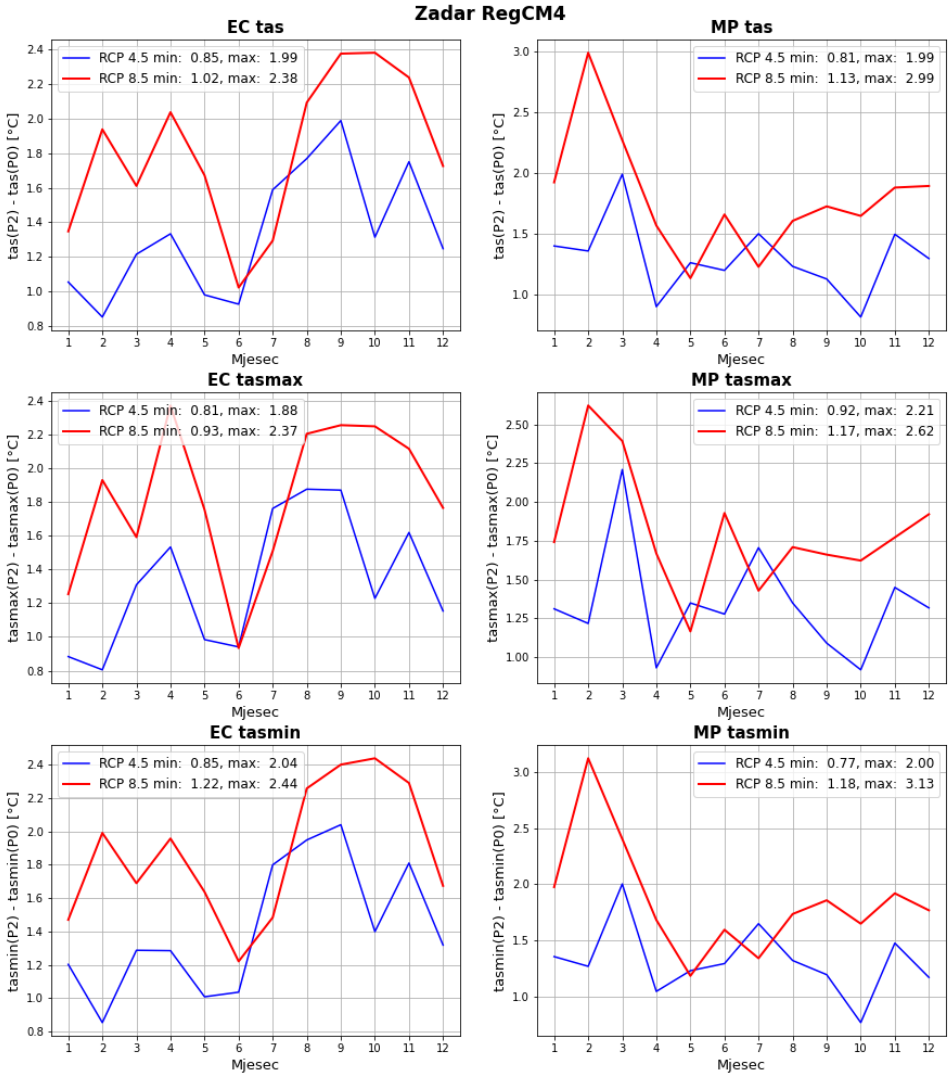

Slika A7: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om RegCM4 forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Zadar. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

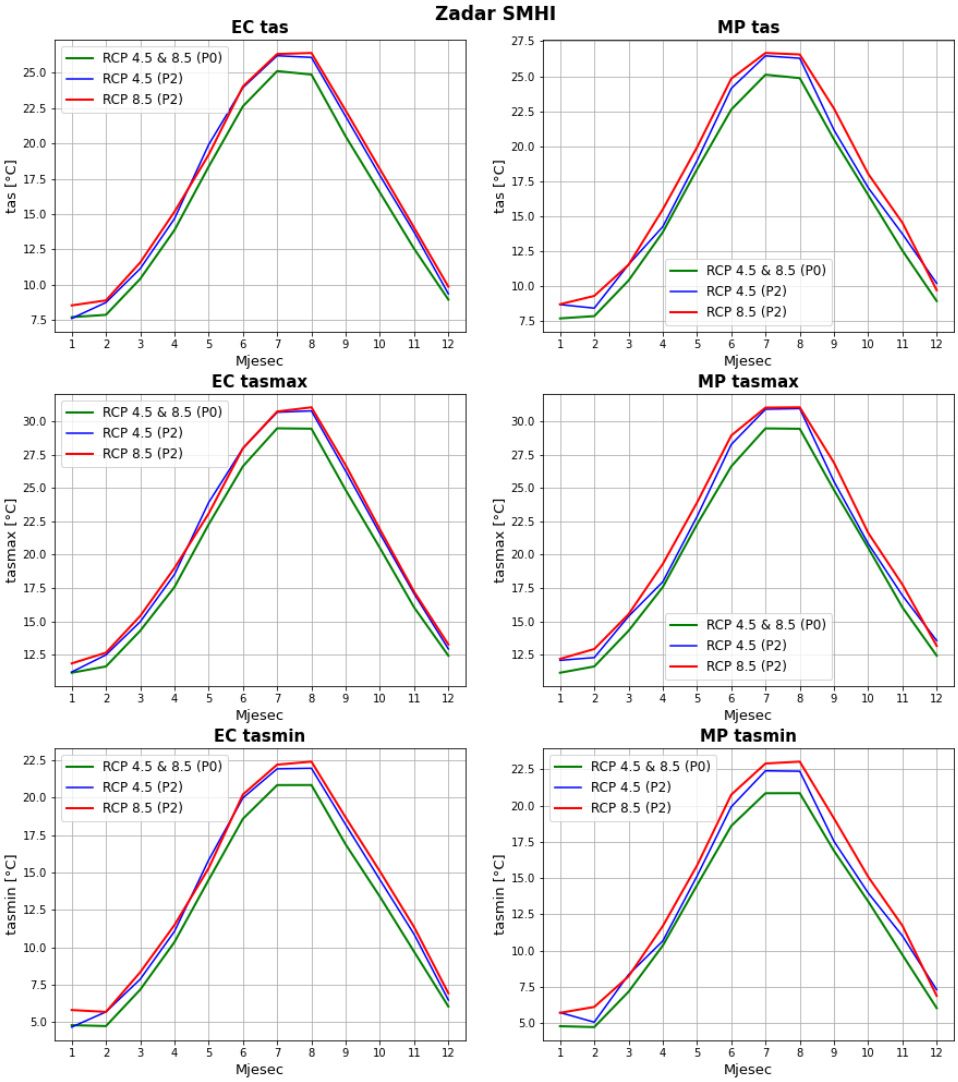
Zadar SMHI
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec

b)

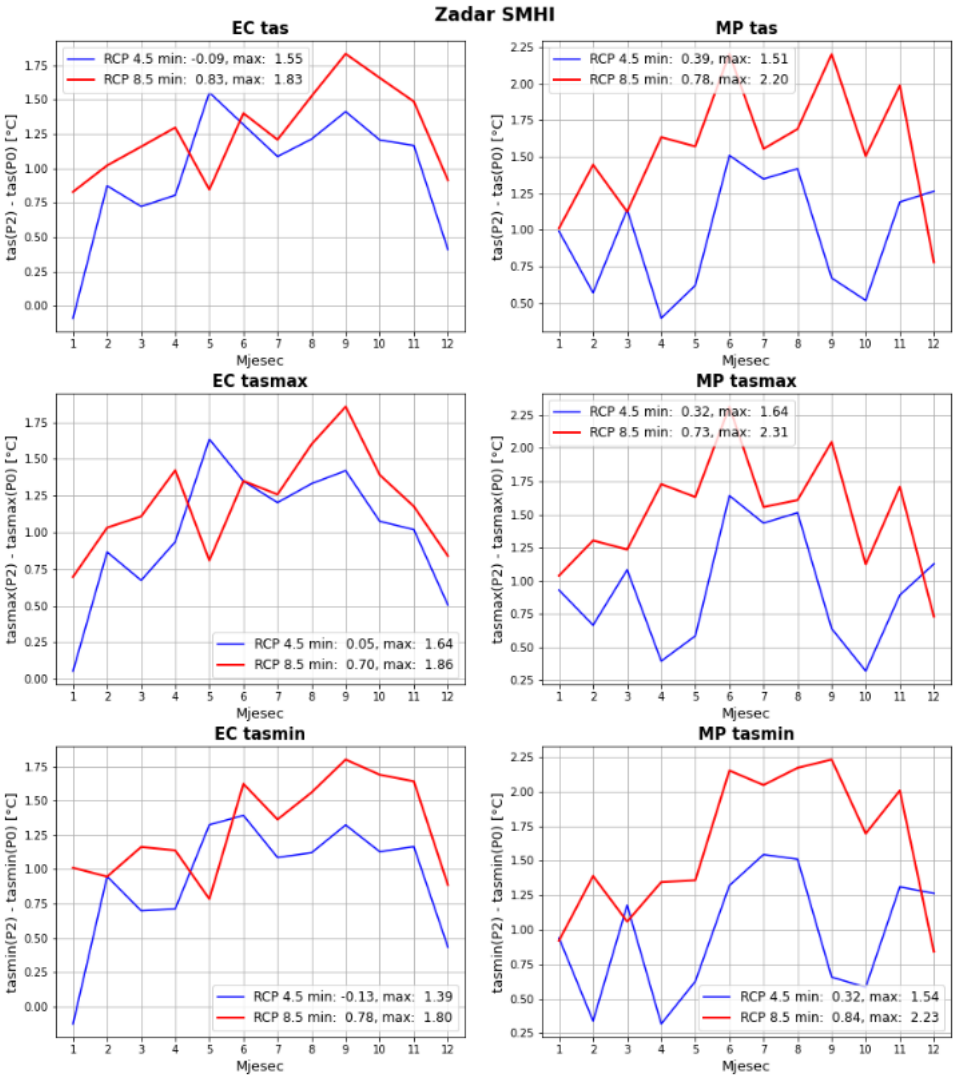

Slika A8: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om SMHI forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Zadar. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

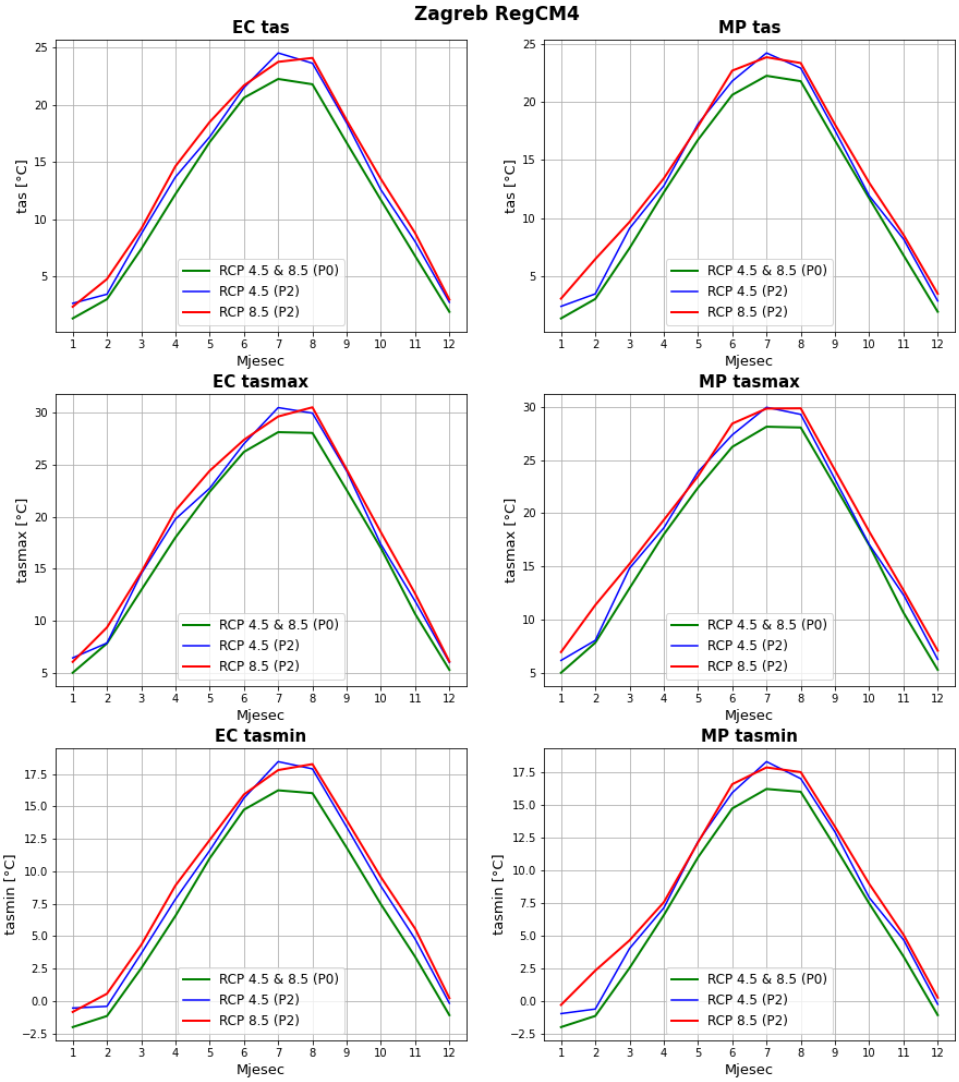
Zagreb RegCM4
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)

b)

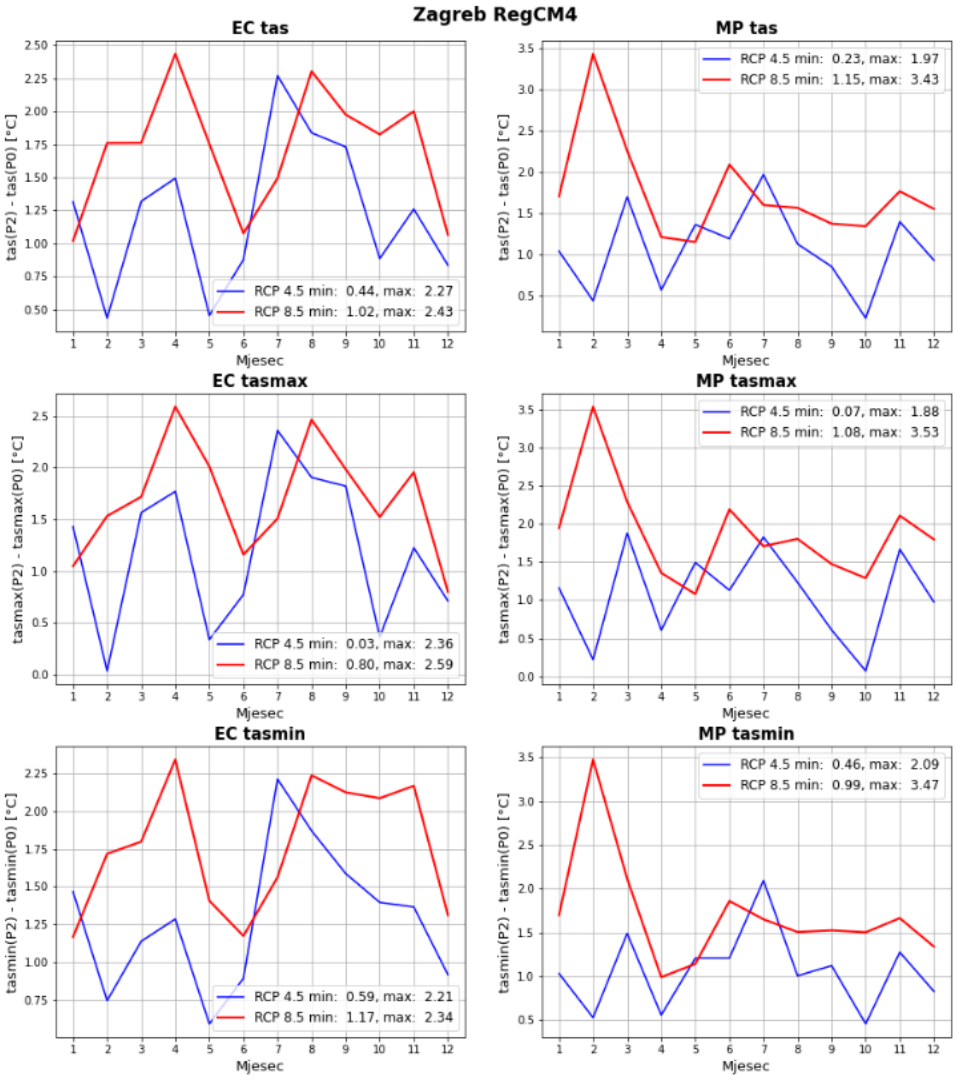

Slika A9: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om RegCM4 forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Zagreb. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

a)

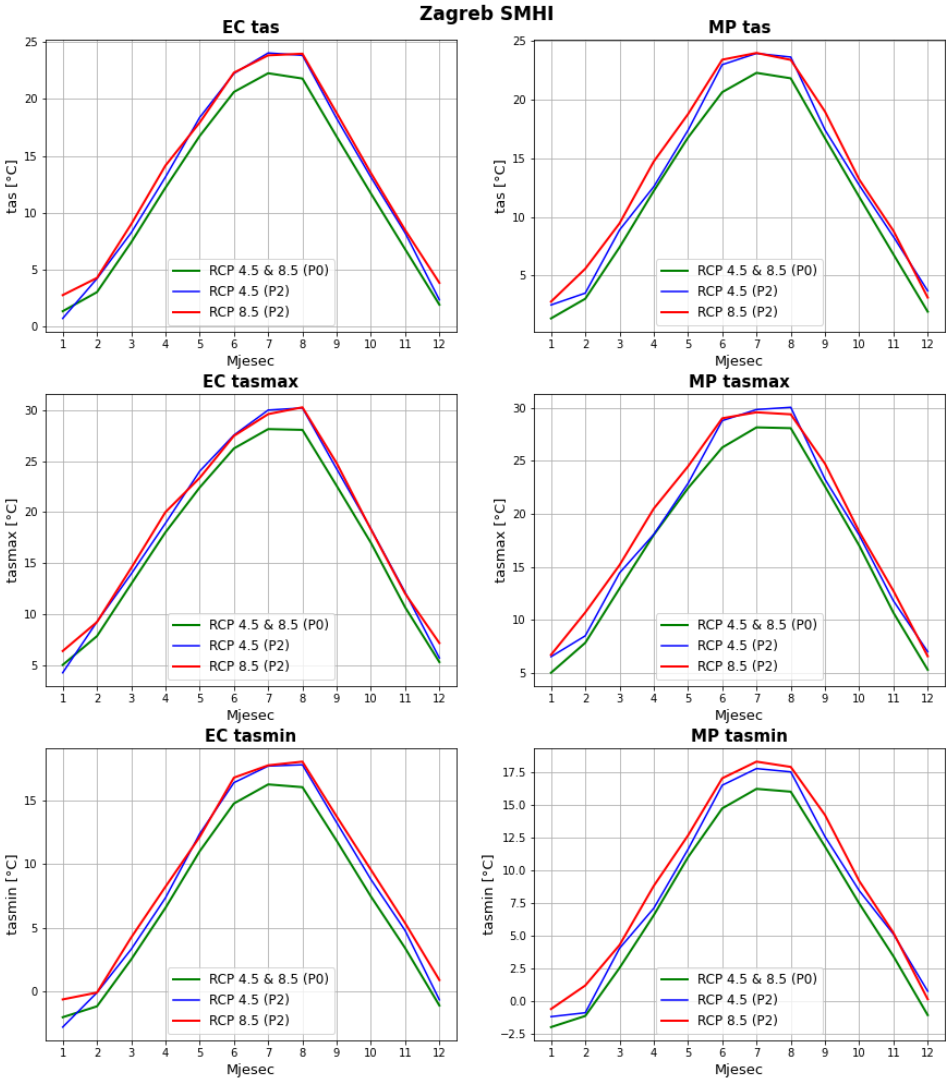
Zagreb SMHI
EC tas
MP tas
EC tasmax
MP tasmax
EC tasmin
MP tasmin
tas [°C]
tasmax [°C]
tasmin [°C]
Mjesec
RCP 4.5 & 8.5 (P0)
RCP 4.5 (P2)
RCP 8.5 (P2)

b)

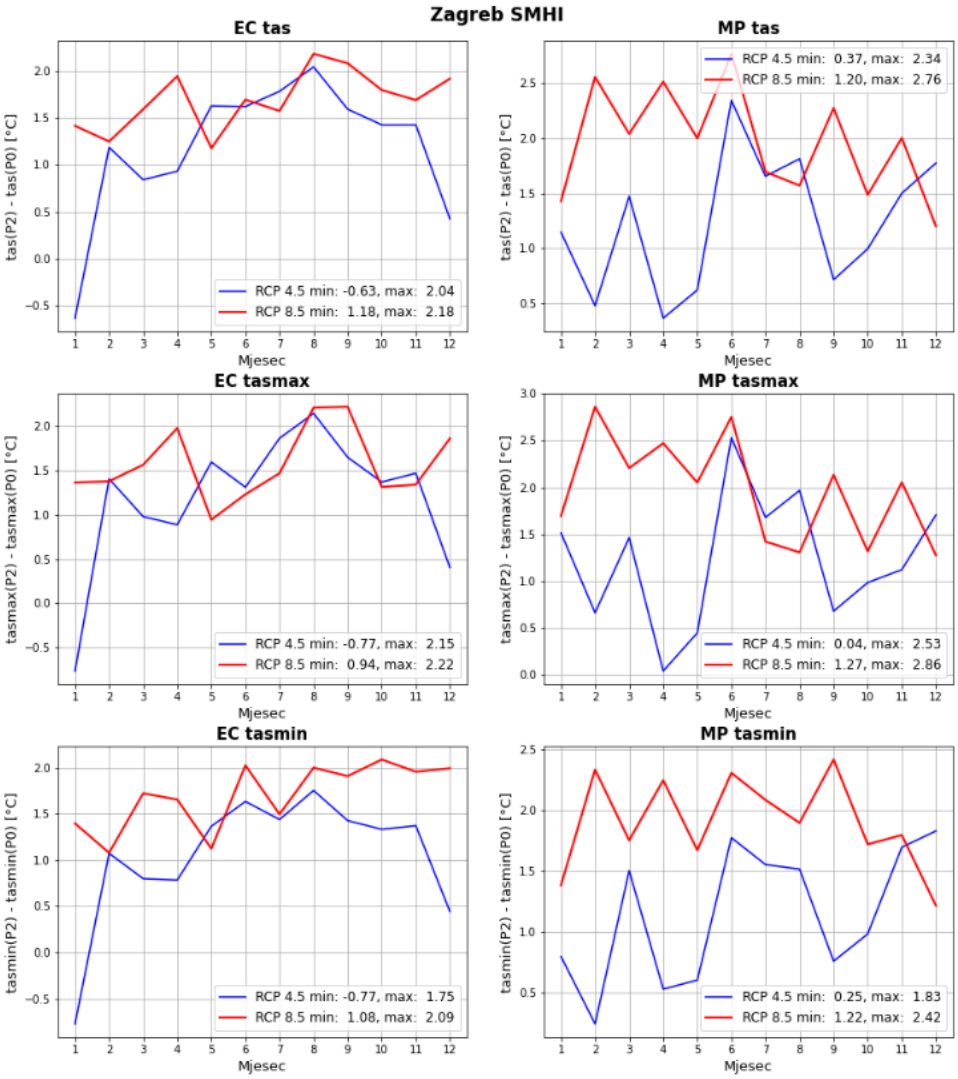

Slika A10: a) Višegodišnji mjesečni srednjaci *tas, tasmax* i *tasmin* modeliranih RCM-om SMHI forsiranog s EC (lijevo) i MP (desno) GCM-ima za grad Zagreb. Vrijednosti koje odgovaraju razdoblju P2 označene su plavom bojom u slučaju scenarija RCP 4.5, odnosno crvenom u slučaju scenarija RCP 8.5, a vrijednosti iz referentnog razdoblja P0 označene su zelenom bojom. Razlike ovih vrijednosti iz razdoblja P2 i P0 dane su na slici b) plavom bojom za RCP 4.5 i crvenom za RCP 8.5.

Dodatak B: Vremenski nizovi *tas*, *tasmax* i *tasmin*

U ovom dodatku dane su slike vremenskih nizova srednjih (*tas*), maksimalnih (*tasmax*) i minimalnih (*tasmin*) temperatura za sve promatrane gradove i sve kombinacije korištenih RCM, GCM i scenarija. Na slikama je ucrtan i pravac linearnog trenda pored kojeg je zapisan trend promatrane varijable izražen u °C/10 god. Pravci trendova koji su prošli Mann-Kendallov test označeni punom linijom, a oni koji nisu označeni su isprekidanom crtom.

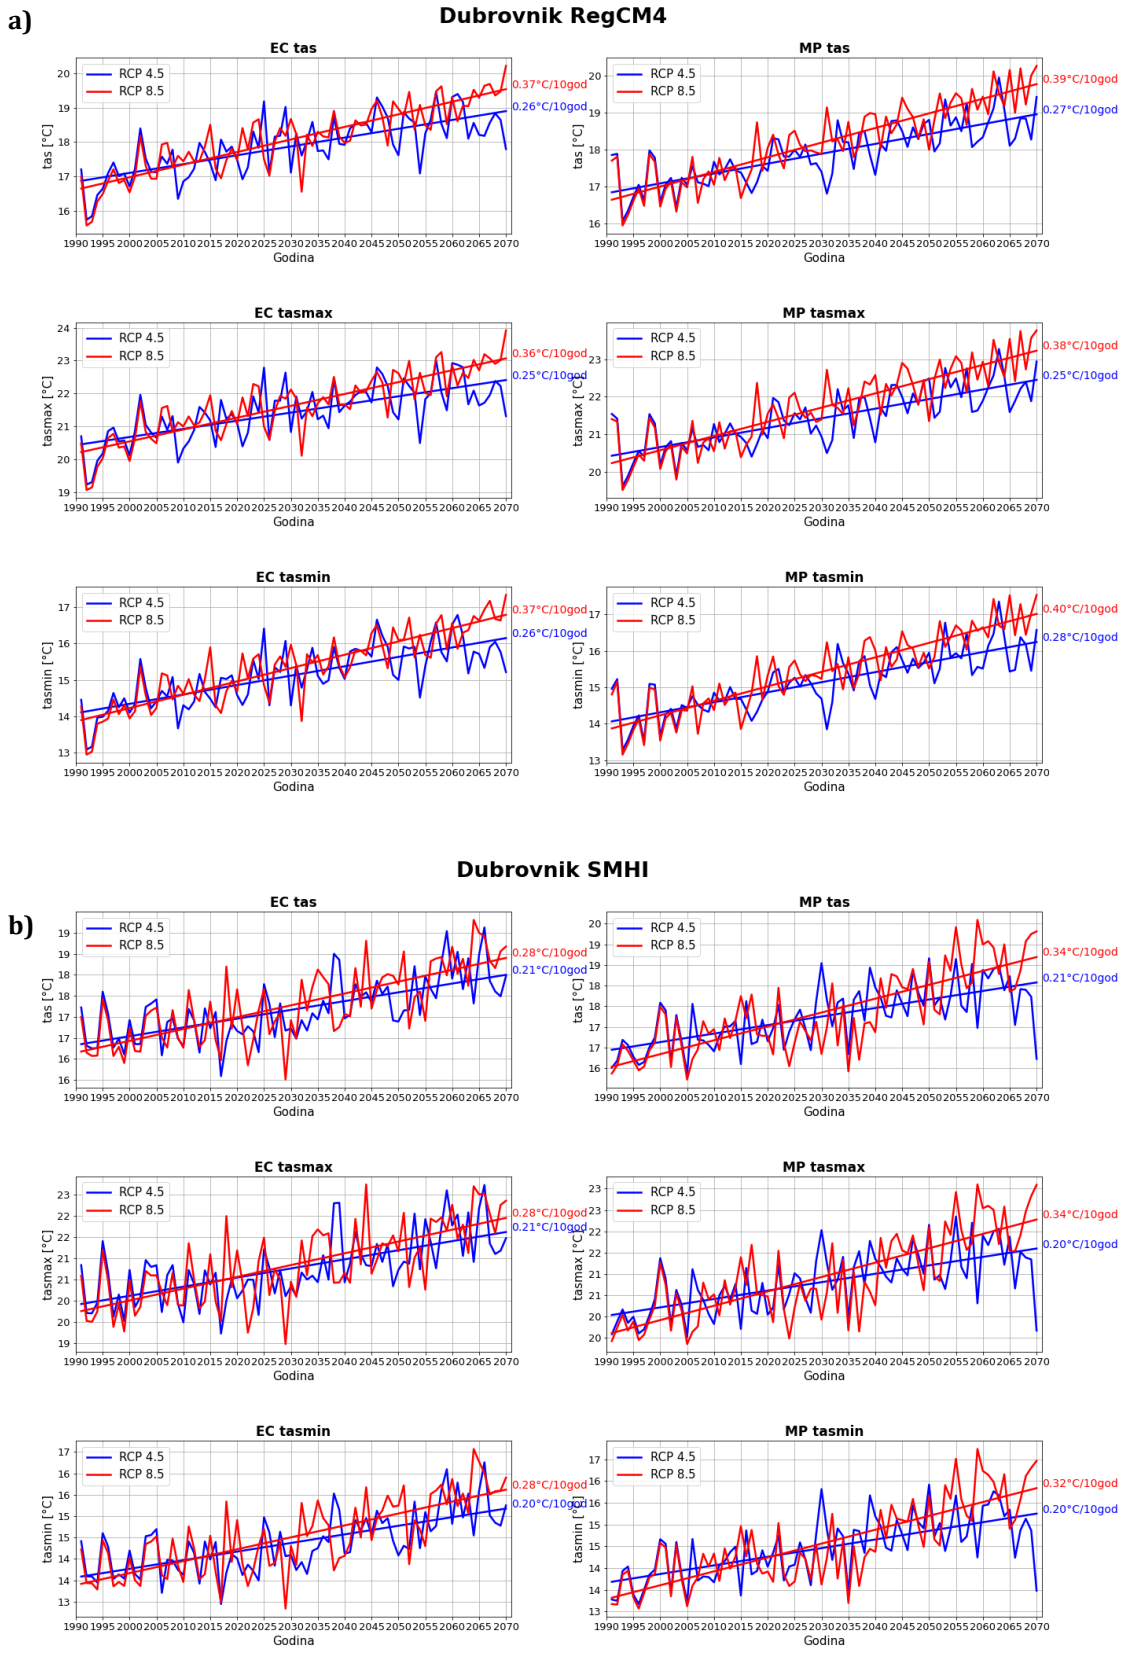

Slika B1: Vremenski nizovi *tas*, *tasmax* i *tasmin* modeliranih RCM-ima: a) RegCM4, b) SMHI-RCA4 forsiranih s EC i MP GCM-ima, te pravci trendova s upisanim trendom izraženim u °C/10 god. za grad Dubrovnik.

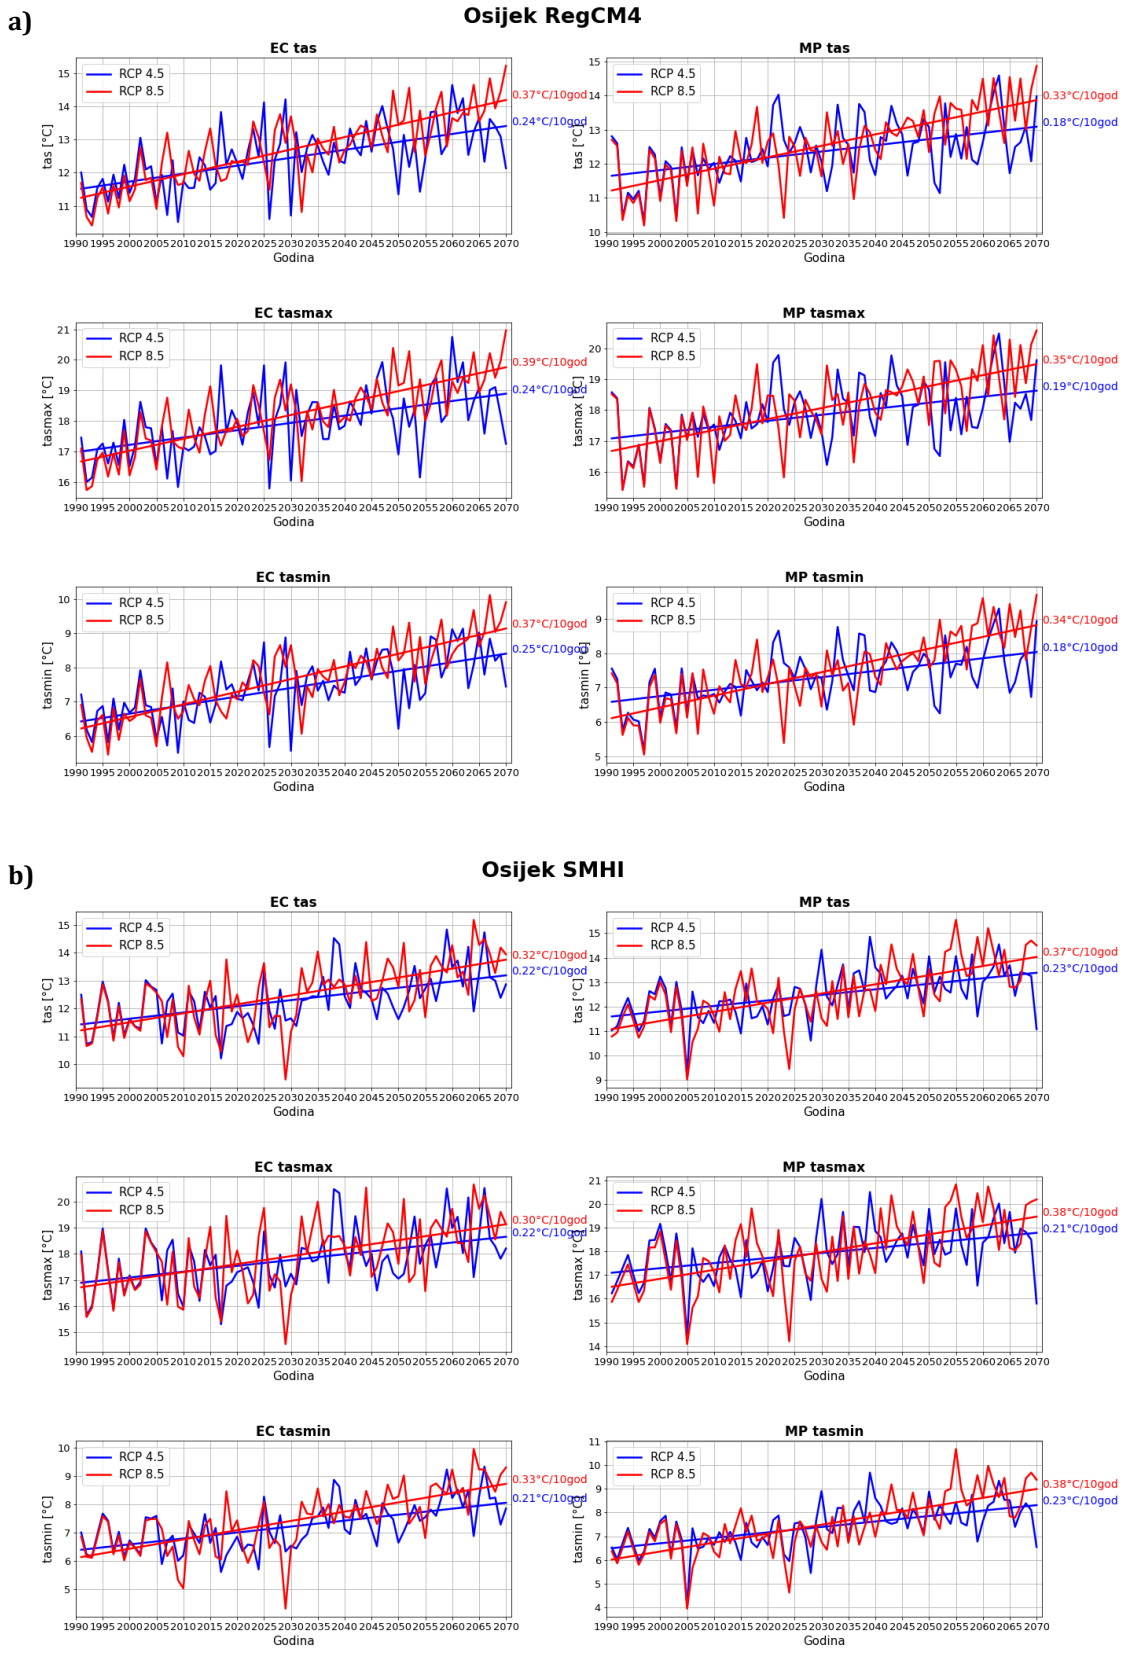

Slika B2: Vremenski nizovi *tas*, *tasmax* i *tasmin* modeliranih RCM-ima: a) RegCM4, b) SMHI-RCA4 forsiranih s EC i MP GCM-ima, te pravci trendova s upisanim trendom izraženim u °C/10 god. za grad Osijek.

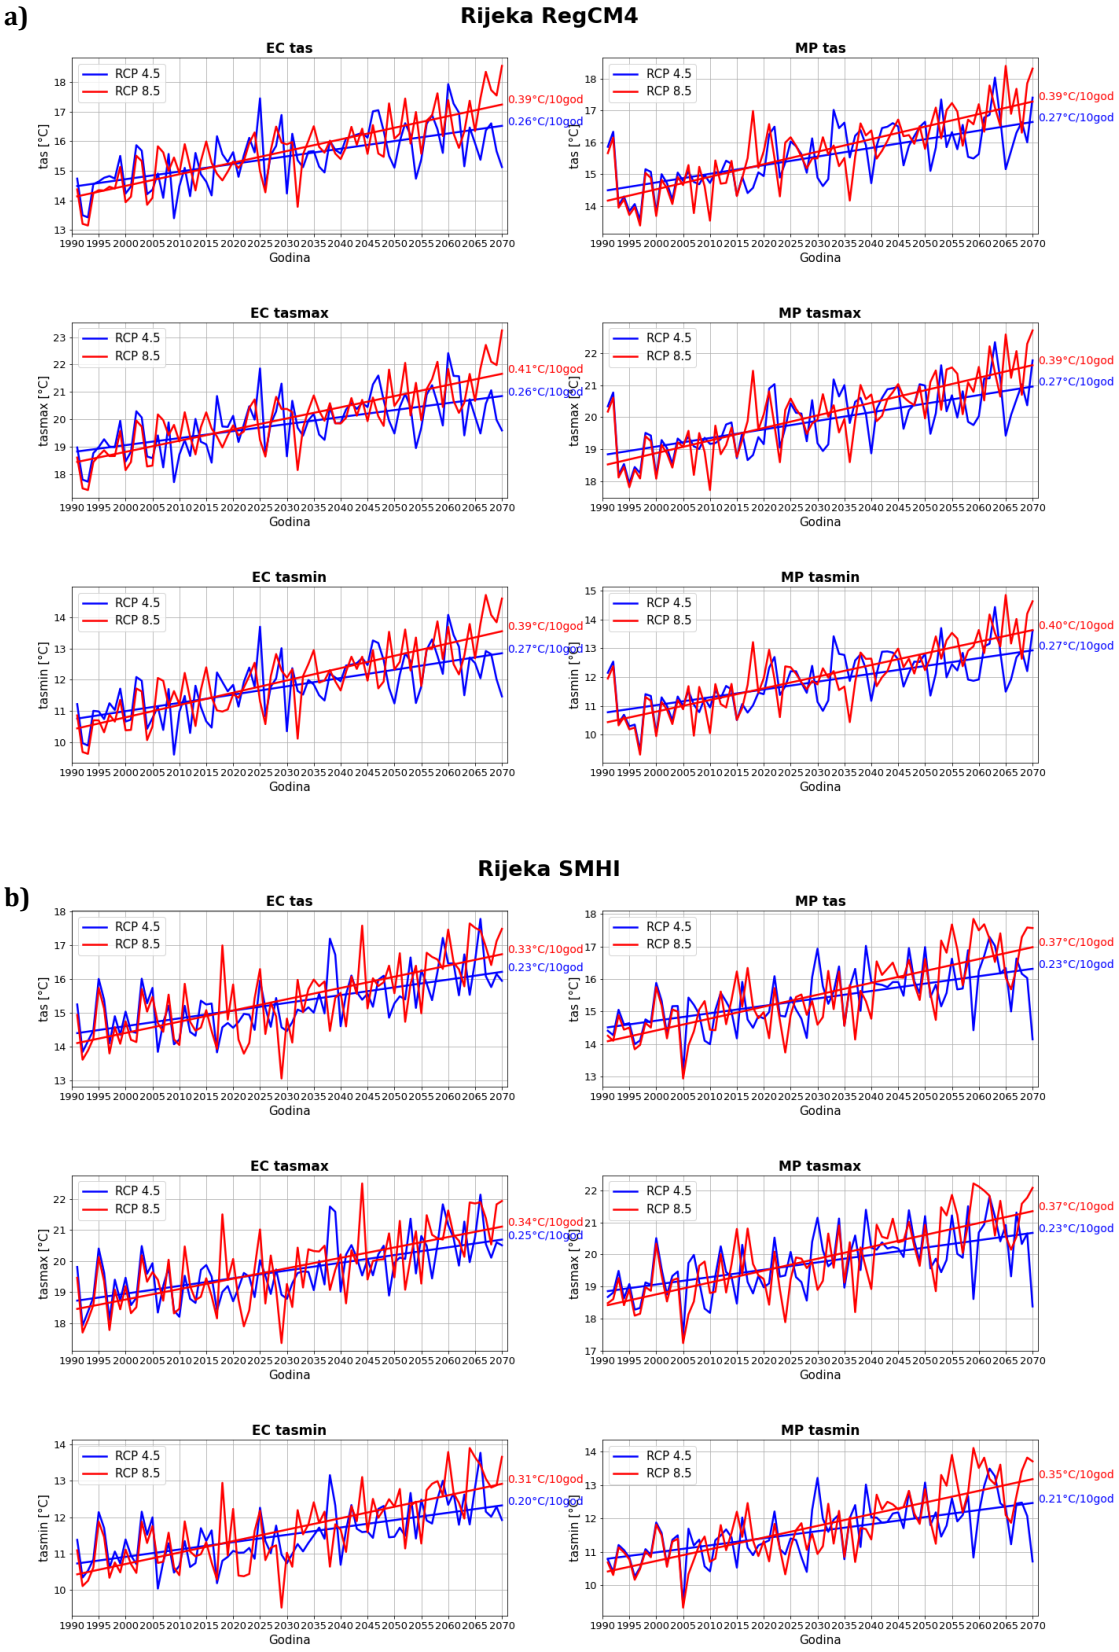

Slika B3: Vremenski nizovi *tas*, *tasmax* i *tasmin* modeliranih RCM-ima: a) RegCM4, b) SMHI-RCA4 forsiranih s EC i MP GCM-ima, te pravci trendova s upisanim trendom izraženim u °C/10 god. za grad Rijeku.

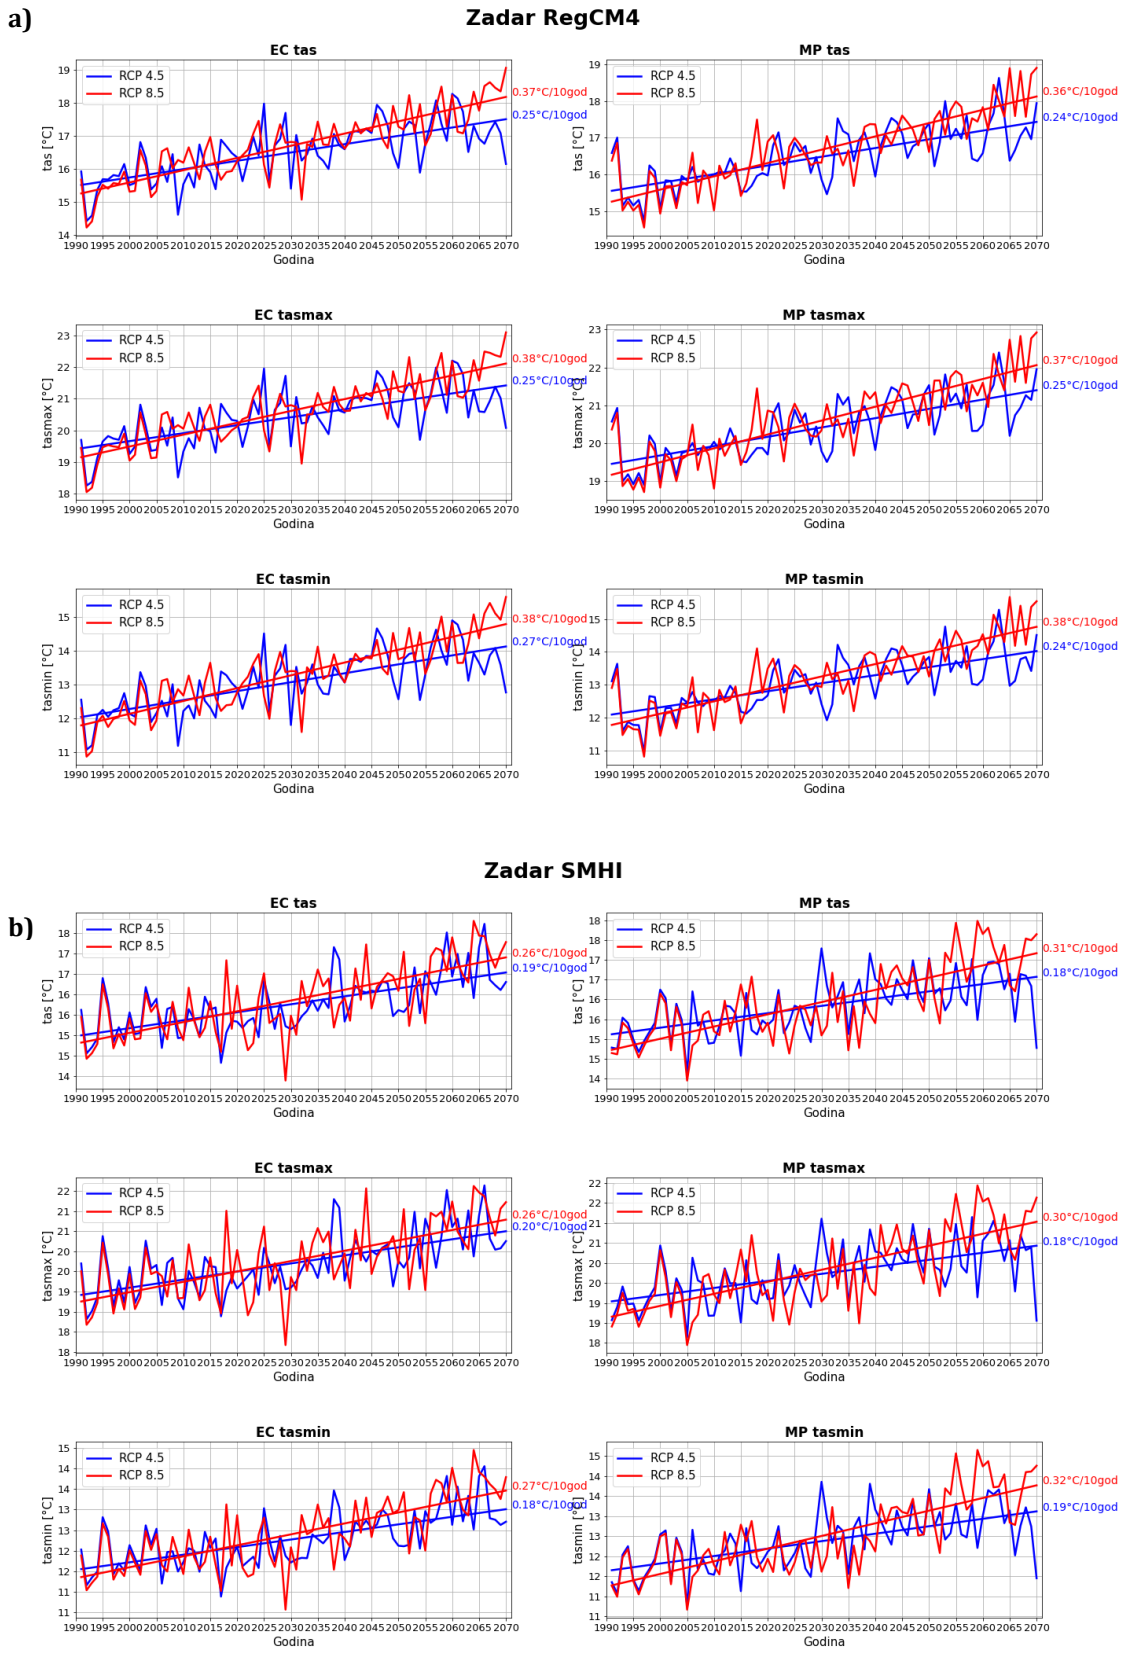

Slika B4: Vremenski nizovi *tas*, *tasmax* i *tasmin* modeliranih RCM-ima: a) RegCM4, b) SMHI-RCA4 forsiranih s EC i MP GCM-ima, te pravci trendova s upisanim trendom izraženim u °C/10 god. za grad Zadar.

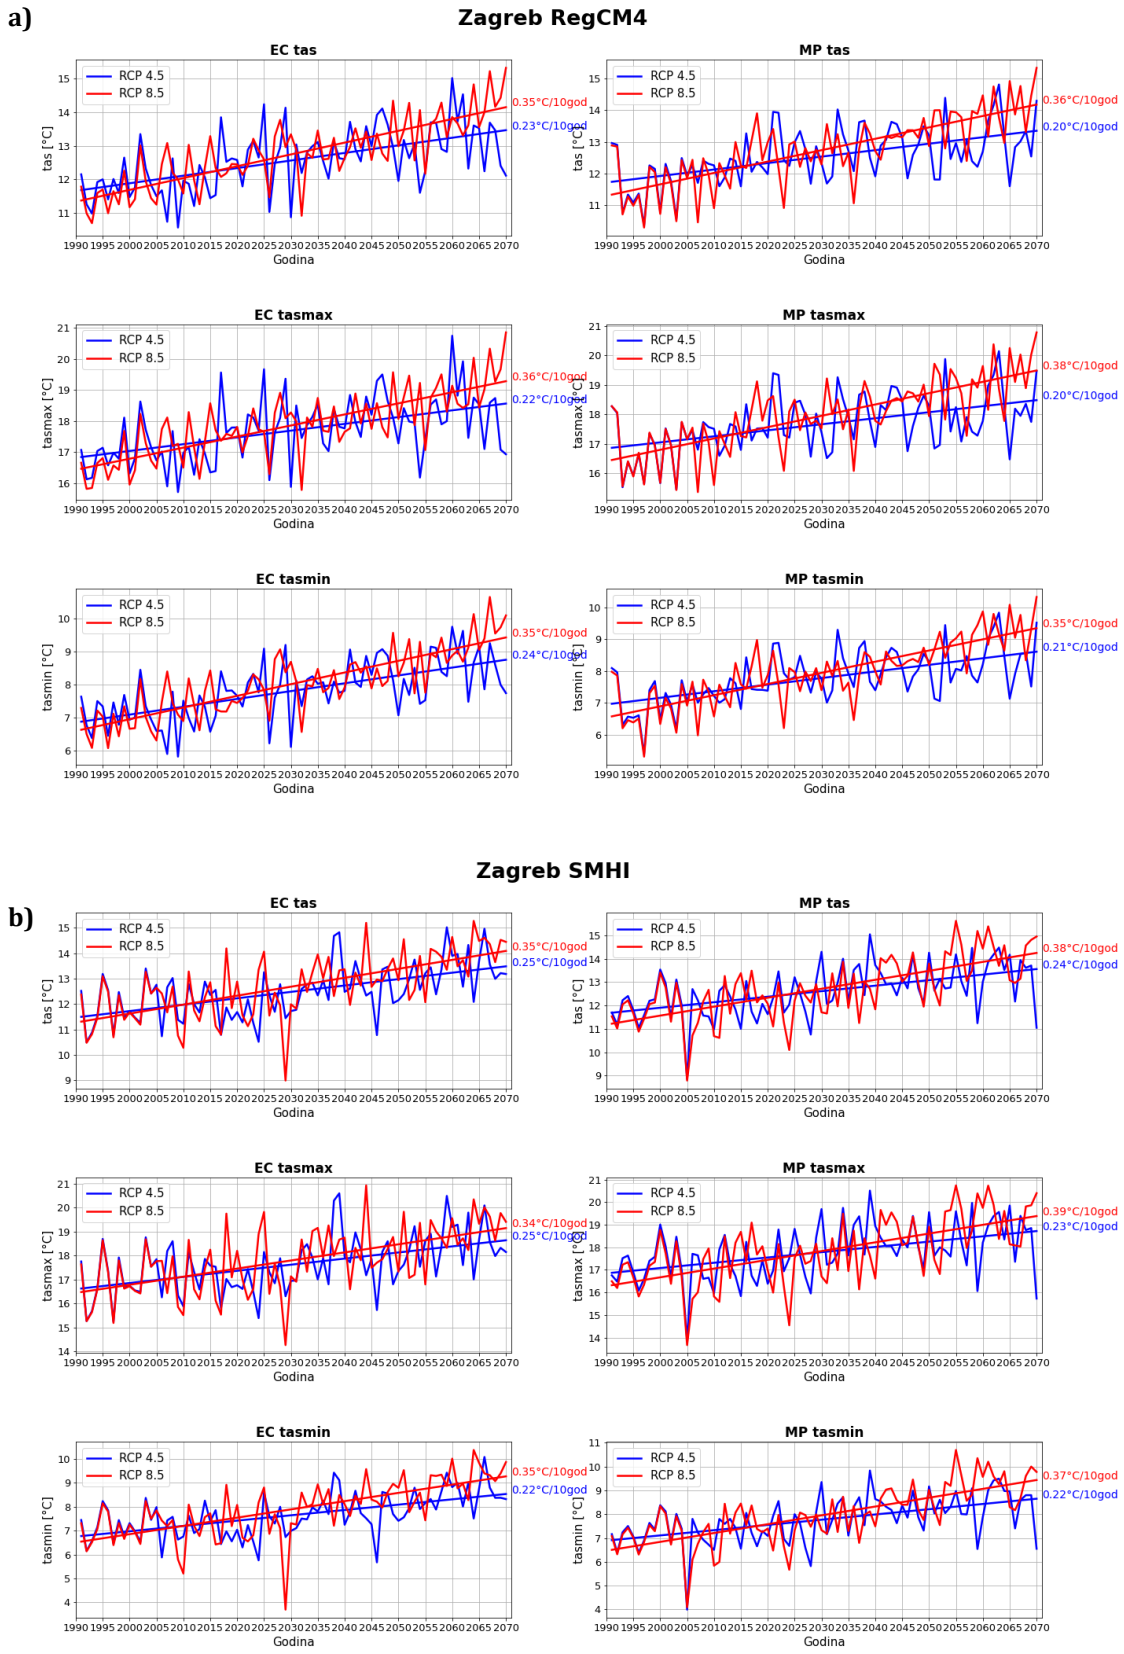

Slika B5: Vremenski nizovi *tas*, *tasmax* i *tasmin* modeliranih RCM-ima: a) RegCM4, b) SMHI-RCA4 forsiranih s EC i MP GCM-ima, te pravci trendova s upisanim trendom izraženim u °C/10 god. za grad Zagreb.

Dodatak C: Vremenski nizovi klimatskih indeksa *FD*, *IF*, *SU*, *TR*, *DTR* i *ETR*

U ovom dodatku dane su slike vremenskih nizova klimatskih indeksa *FD*, *ID, SU*, *TR*, *DTR* i *ETR* za sve promatrane gradove i sve kombinacije korištenih RCM, GCM i scenarija. Na slikama je ucrtan i pravac linearnog trenda, a trend promatrane varijable izražen je u °C/10 god. i zapisan u legendi. Pravci trendova koji su prošli Mann-Kendallov test označeni punom linijom, a oni koji nisu označeni su isprekidanom crtom.

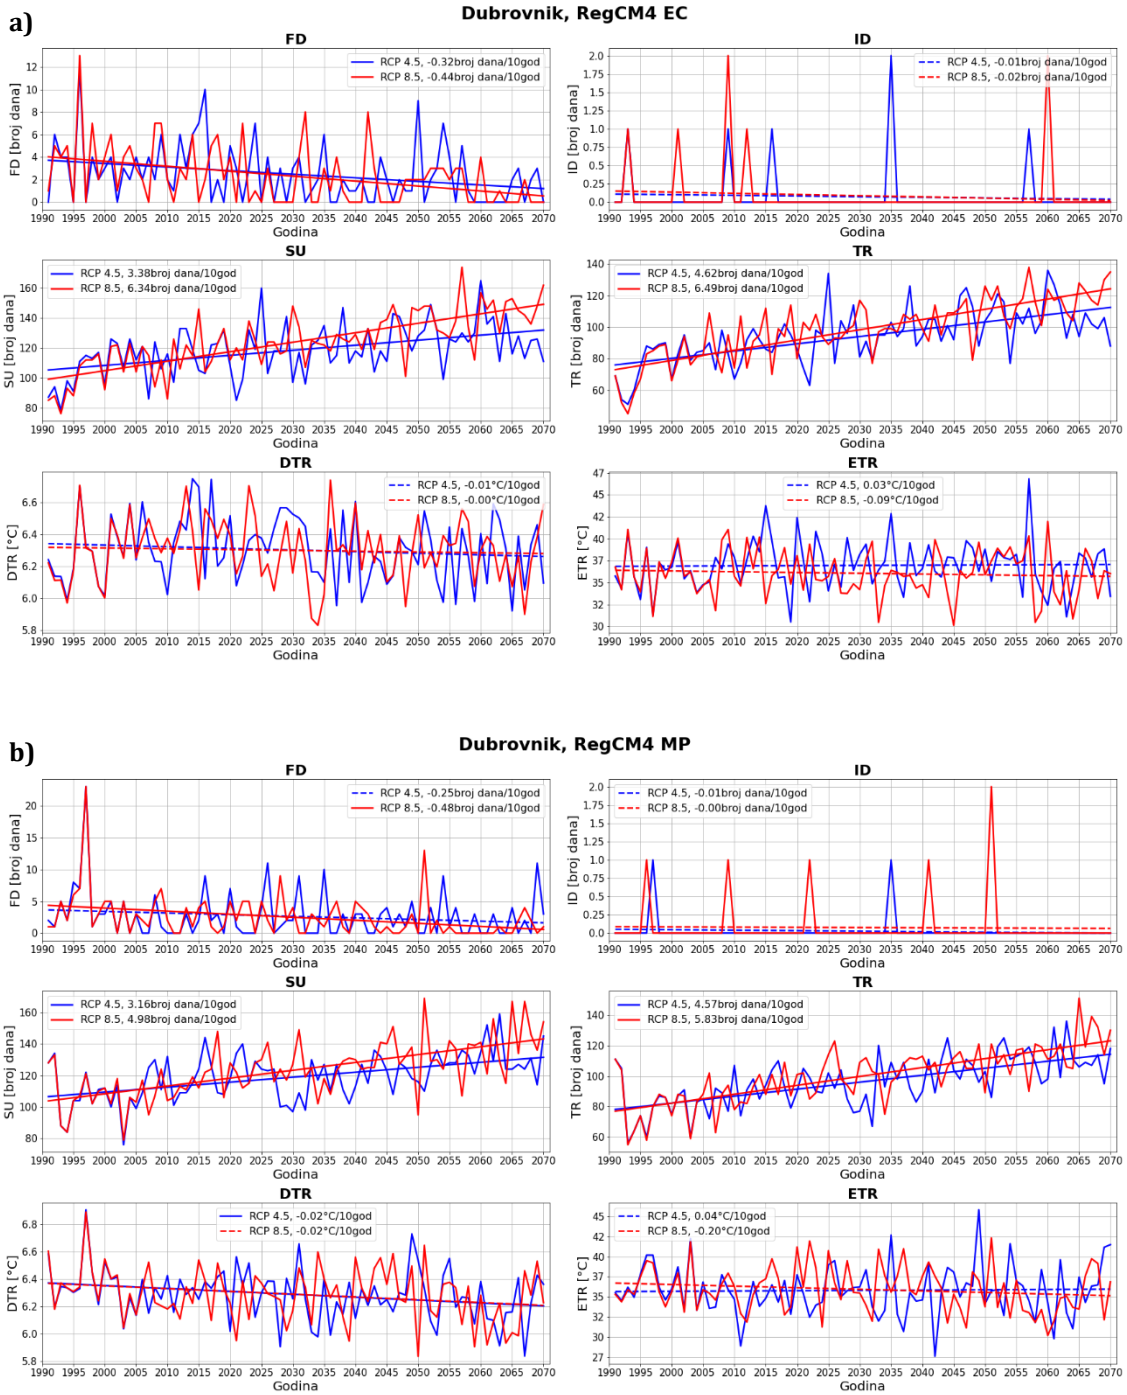

Slika C1: Vremenski nizovi klimatskih indeksa modeliranih RegCM4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Dubrovnik. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

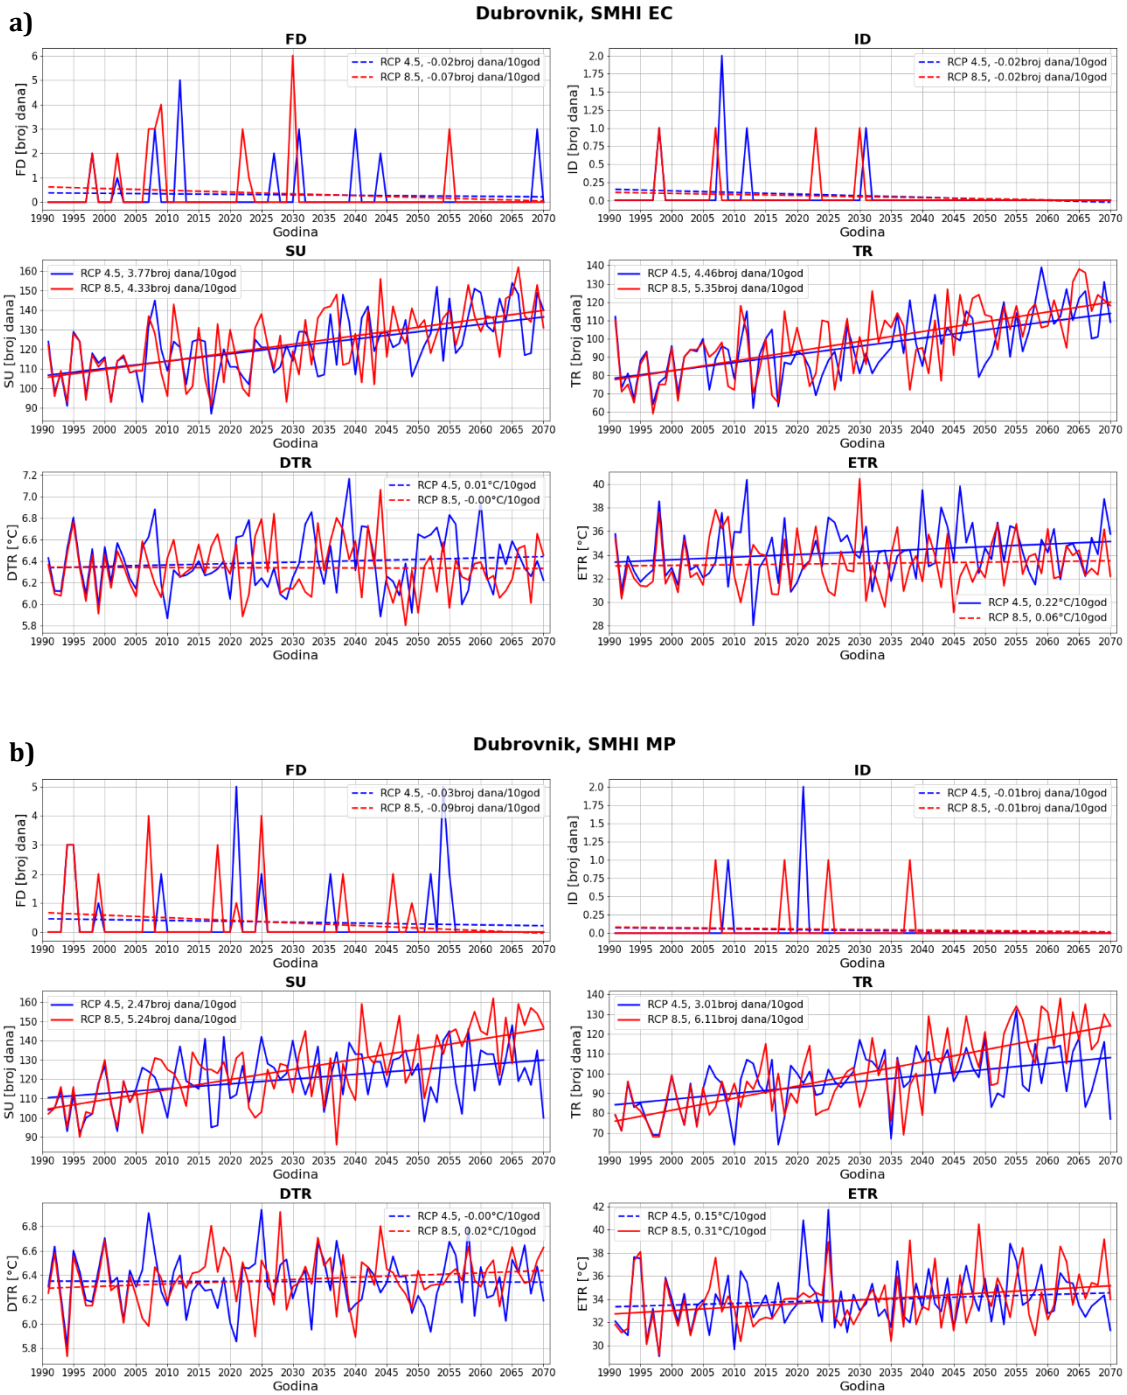

Slika C2: Vremenski nizovi klimatskih indeksa modeliranih SMHI-RCA4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Dubrovnik. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

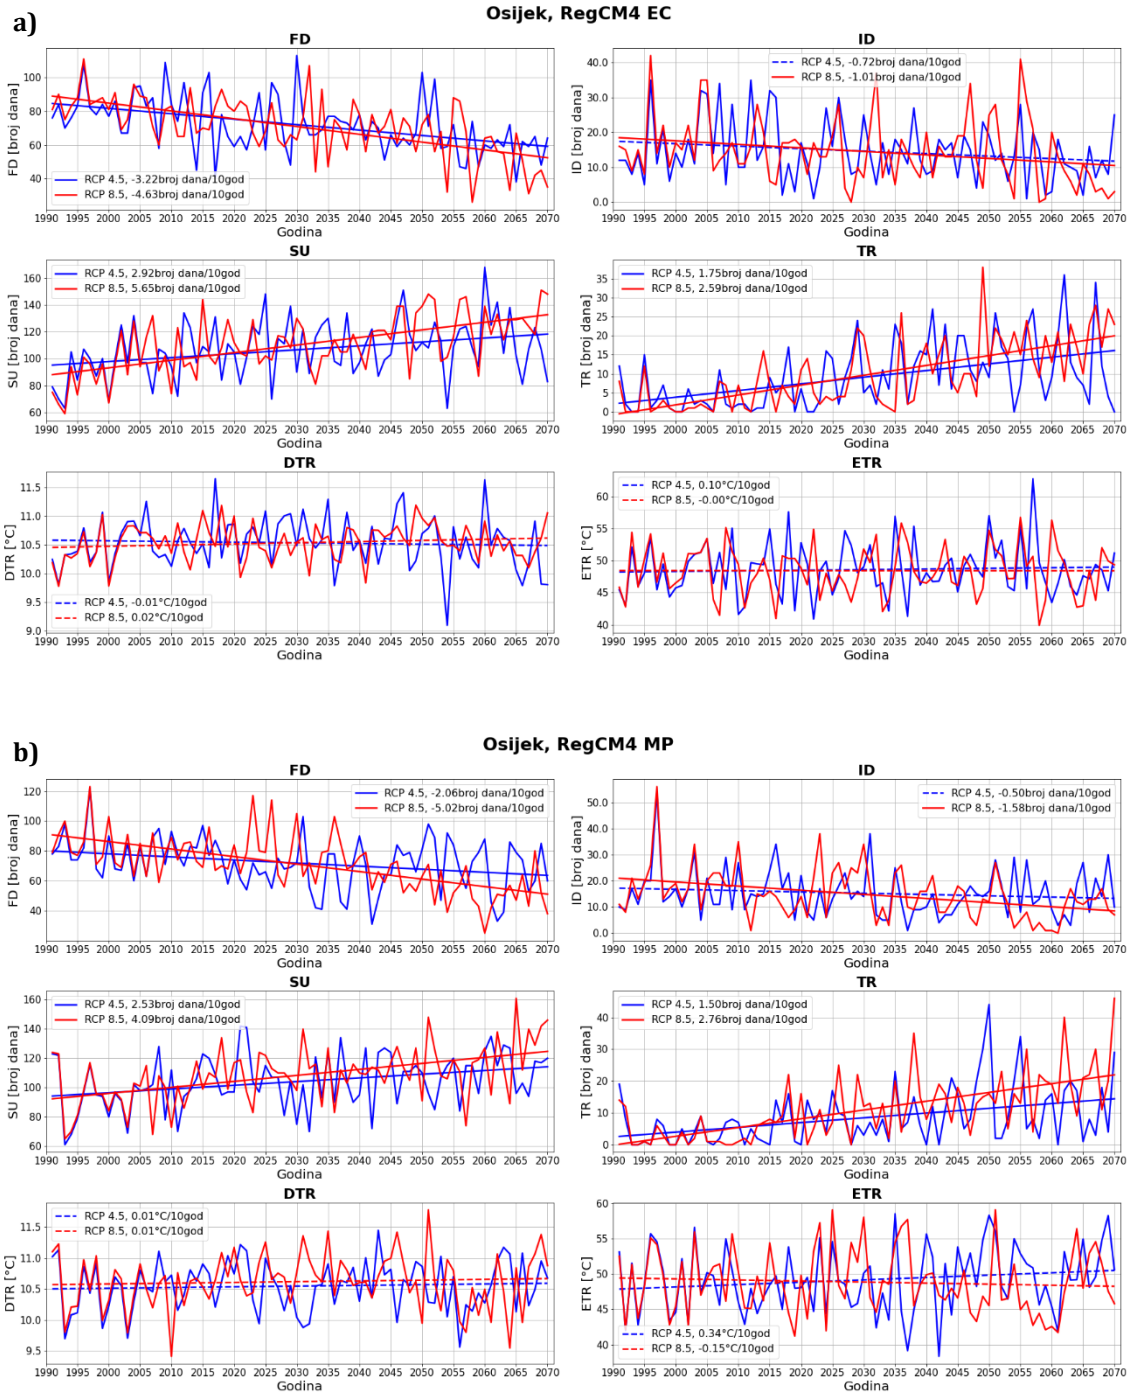

Slika C3: Vremenski nizovi klimatskih indeksa modeliranih RegCM4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Osijek. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

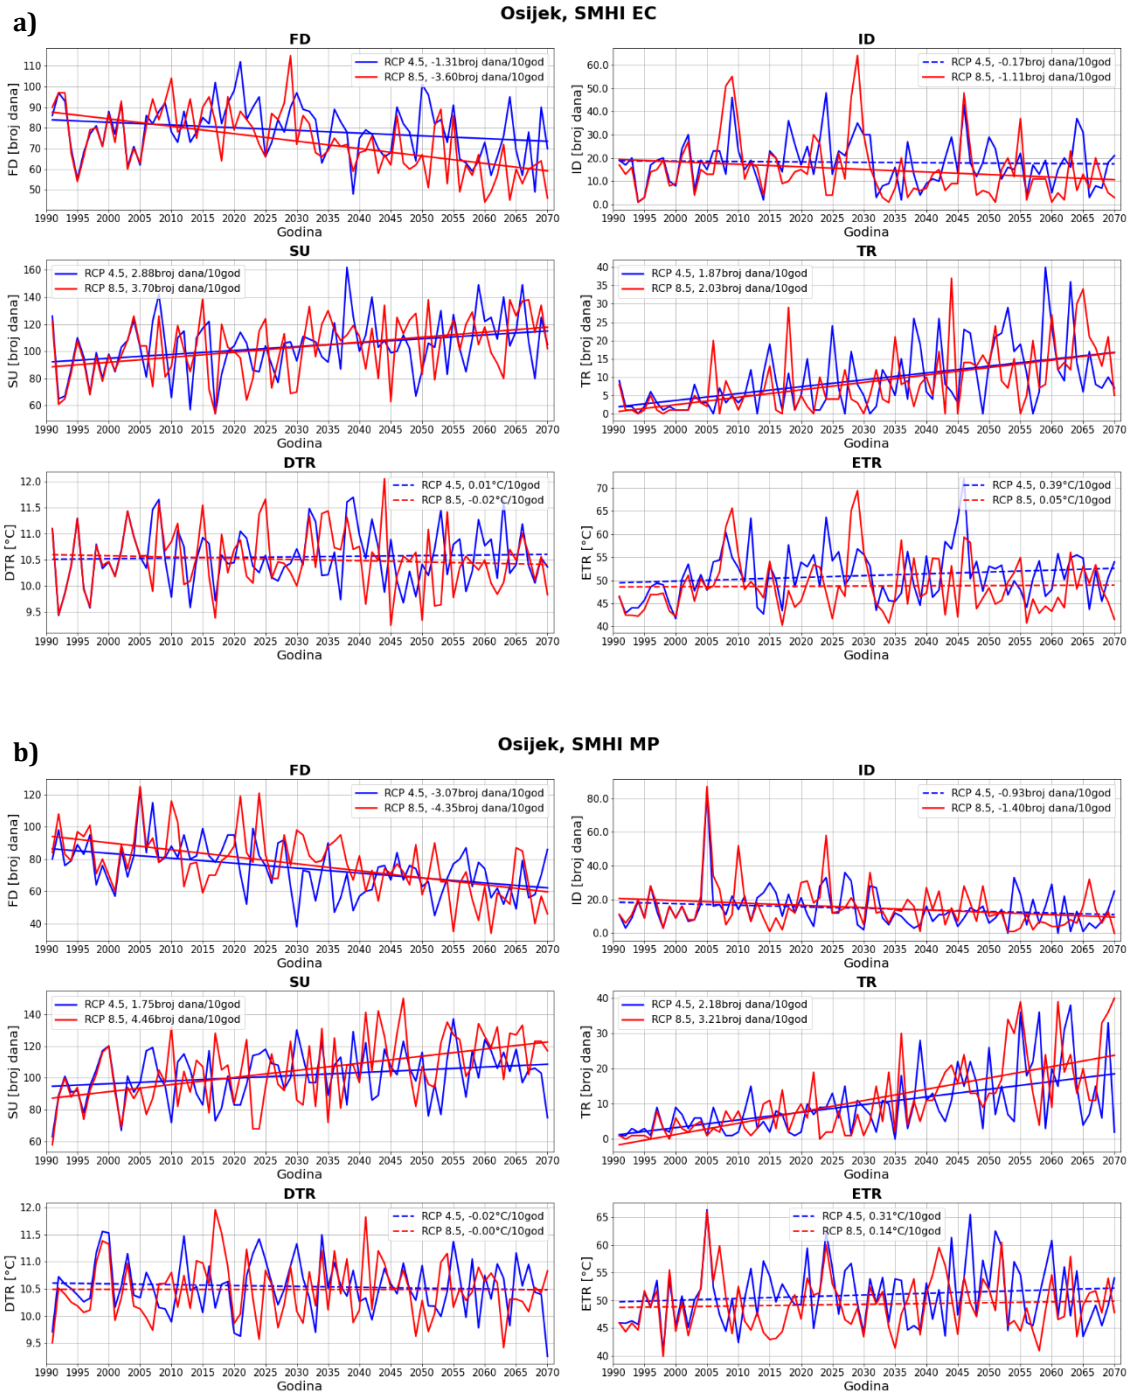

Slika C4: Vremenski nizovi klimatskih indeksa modeliranih SMHI-RCA4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Osijek. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

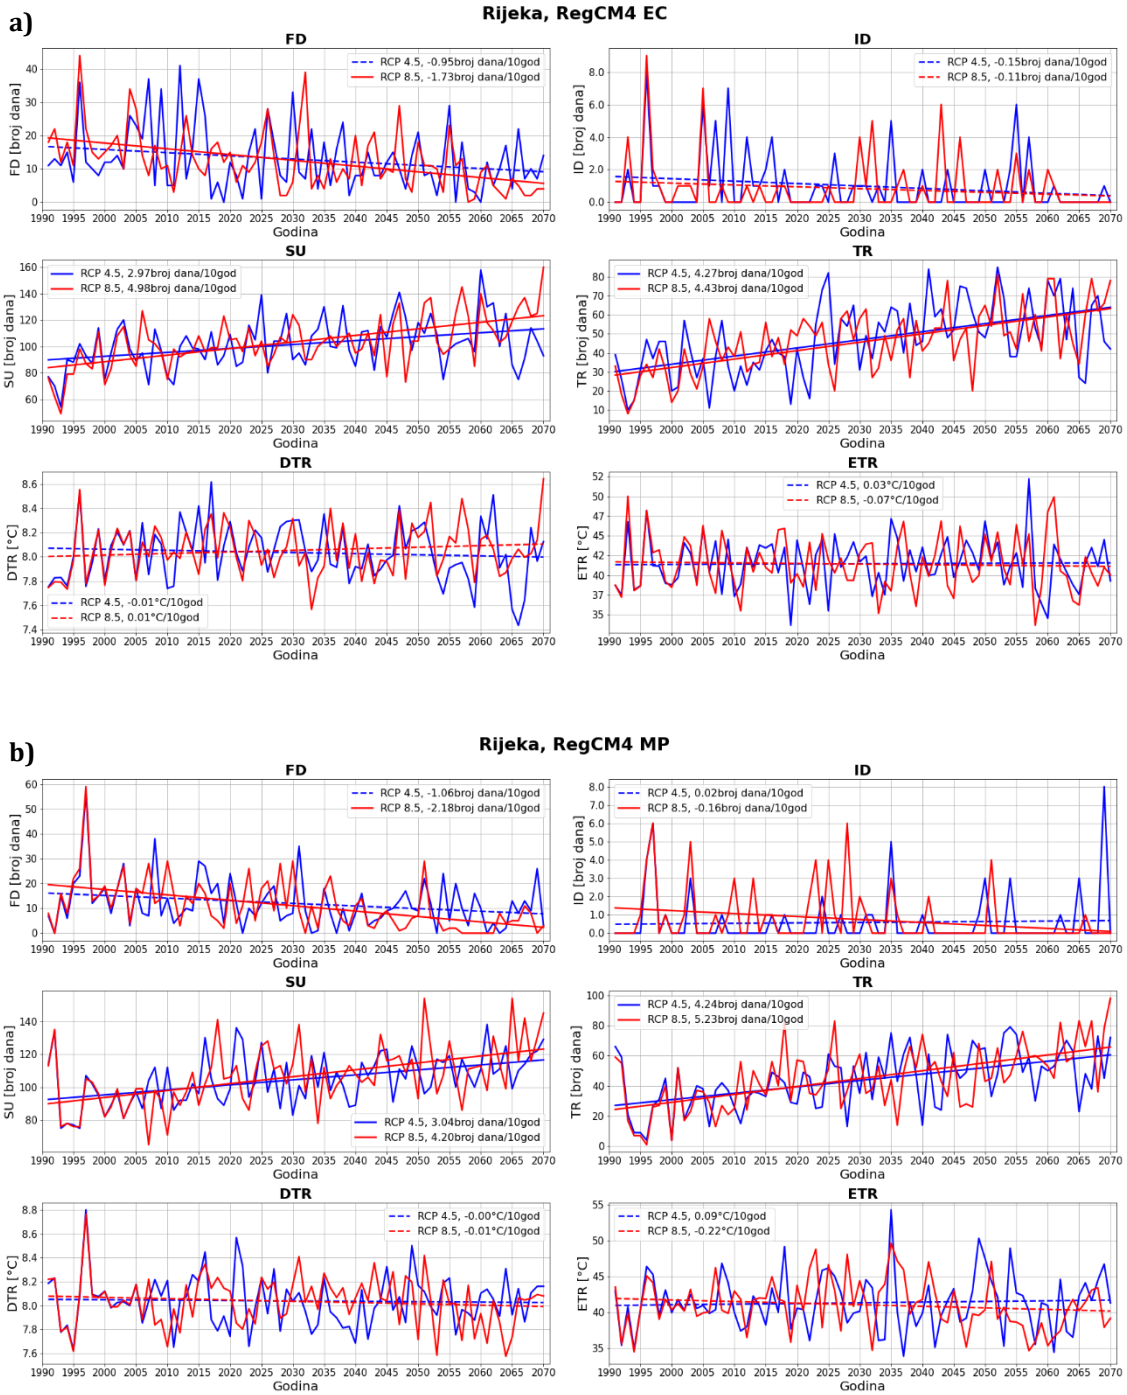

Slika C5: Vremenski nizovi klimatskih indeksa modeliranih RegCM4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Rijeku. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

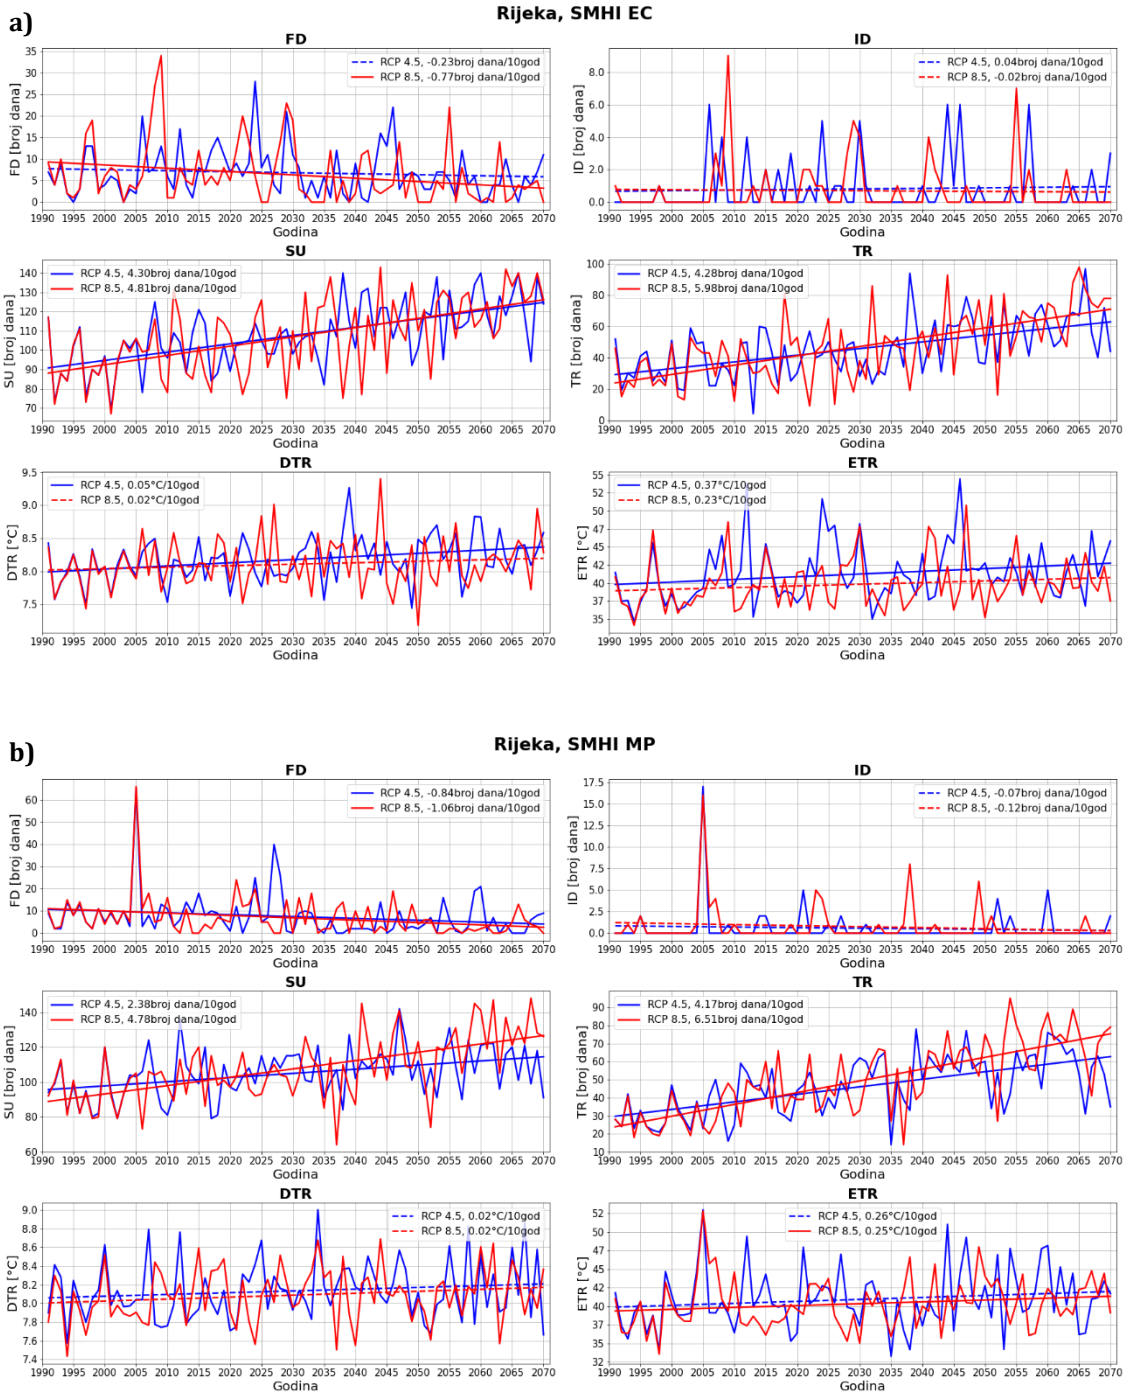

Slika C6: Vremenski nizovi klimatskih indeksa modeliranih SMHI-RCA4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Rijeku. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

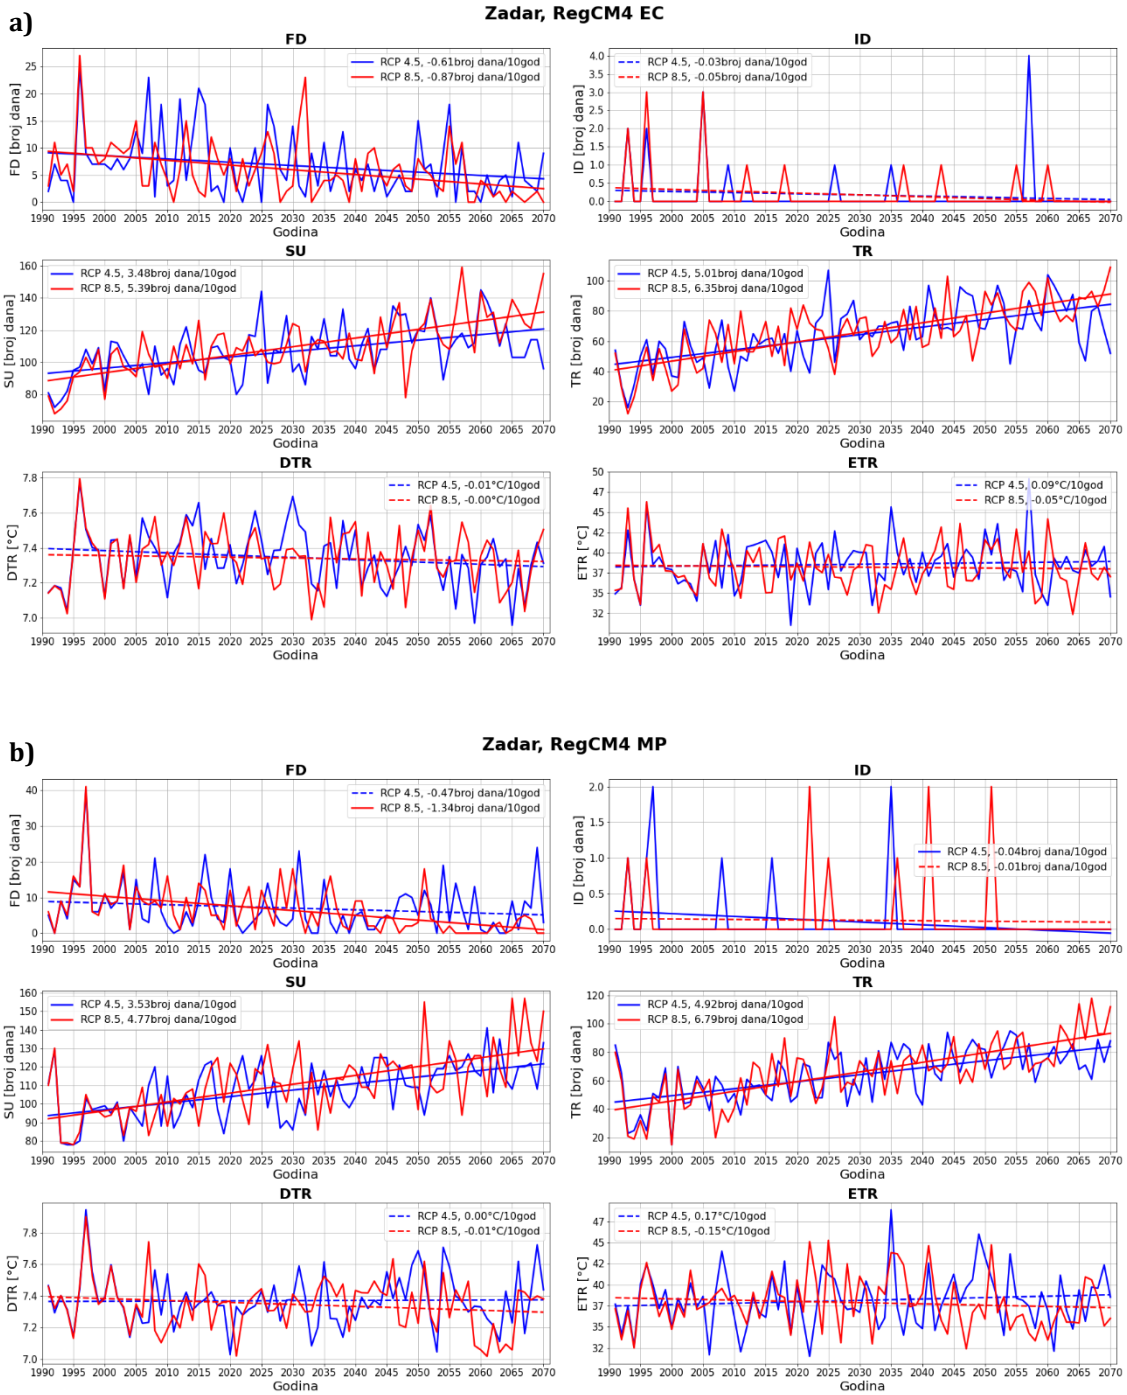

Slika C7: Vremenski nizovi klimatskih indeksa modeliranih RegCM4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Zadar. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

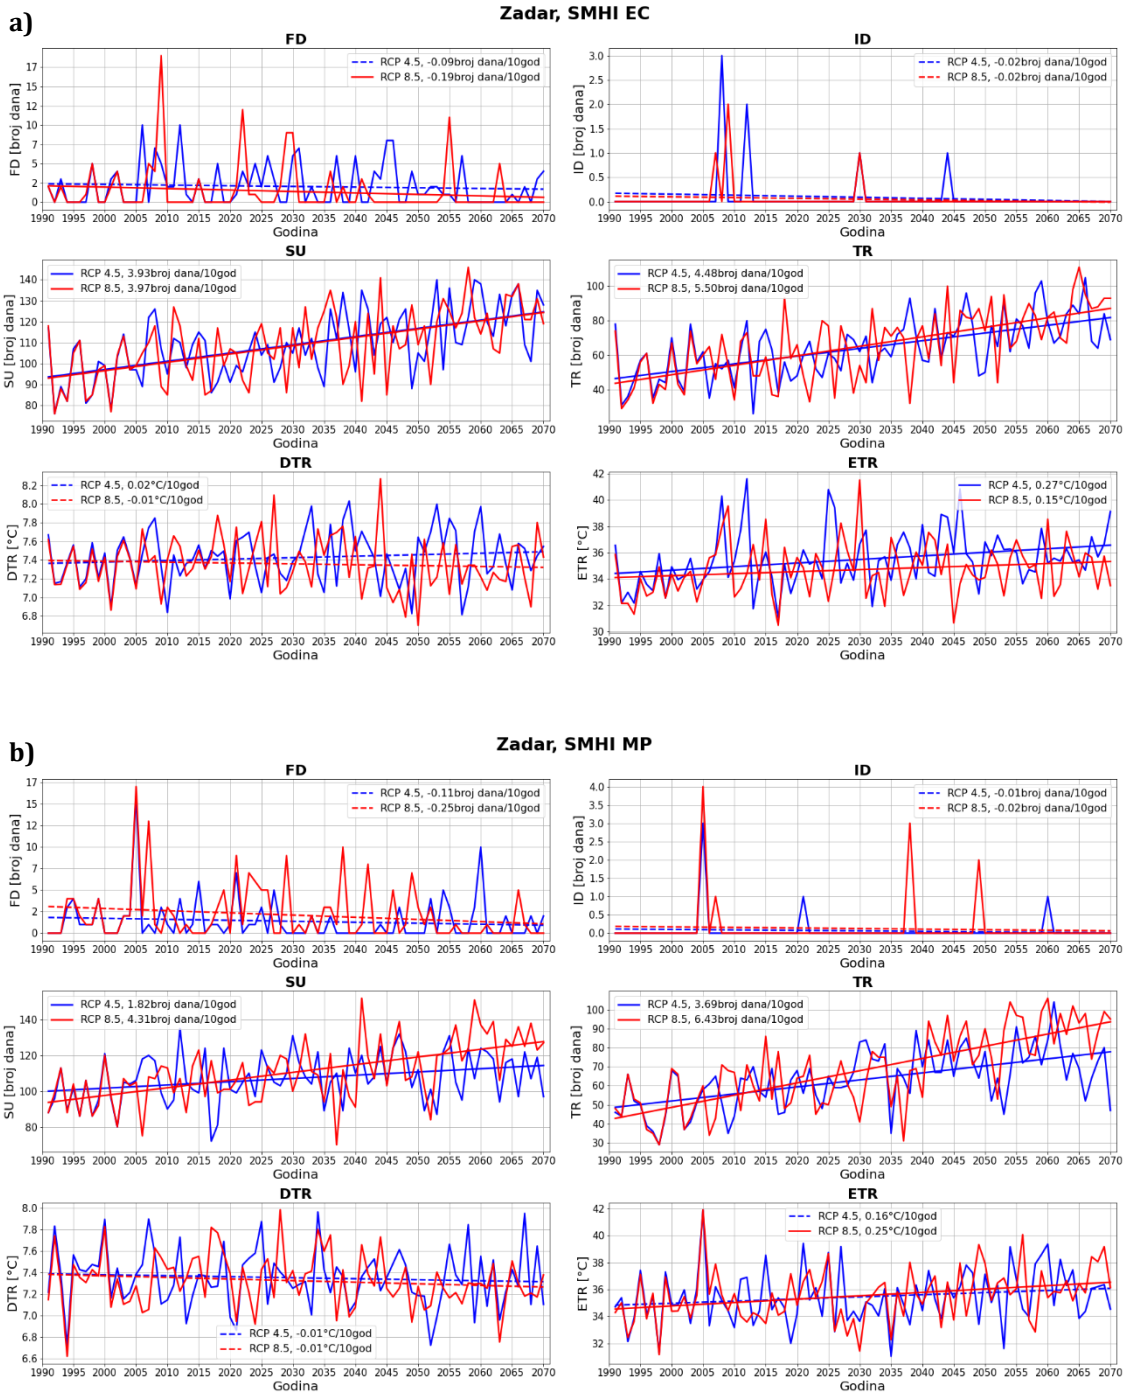

Slika C8: Vremenski nizovi klimatskih indeksa modeliranih SMHI-RCA4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Zadar. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

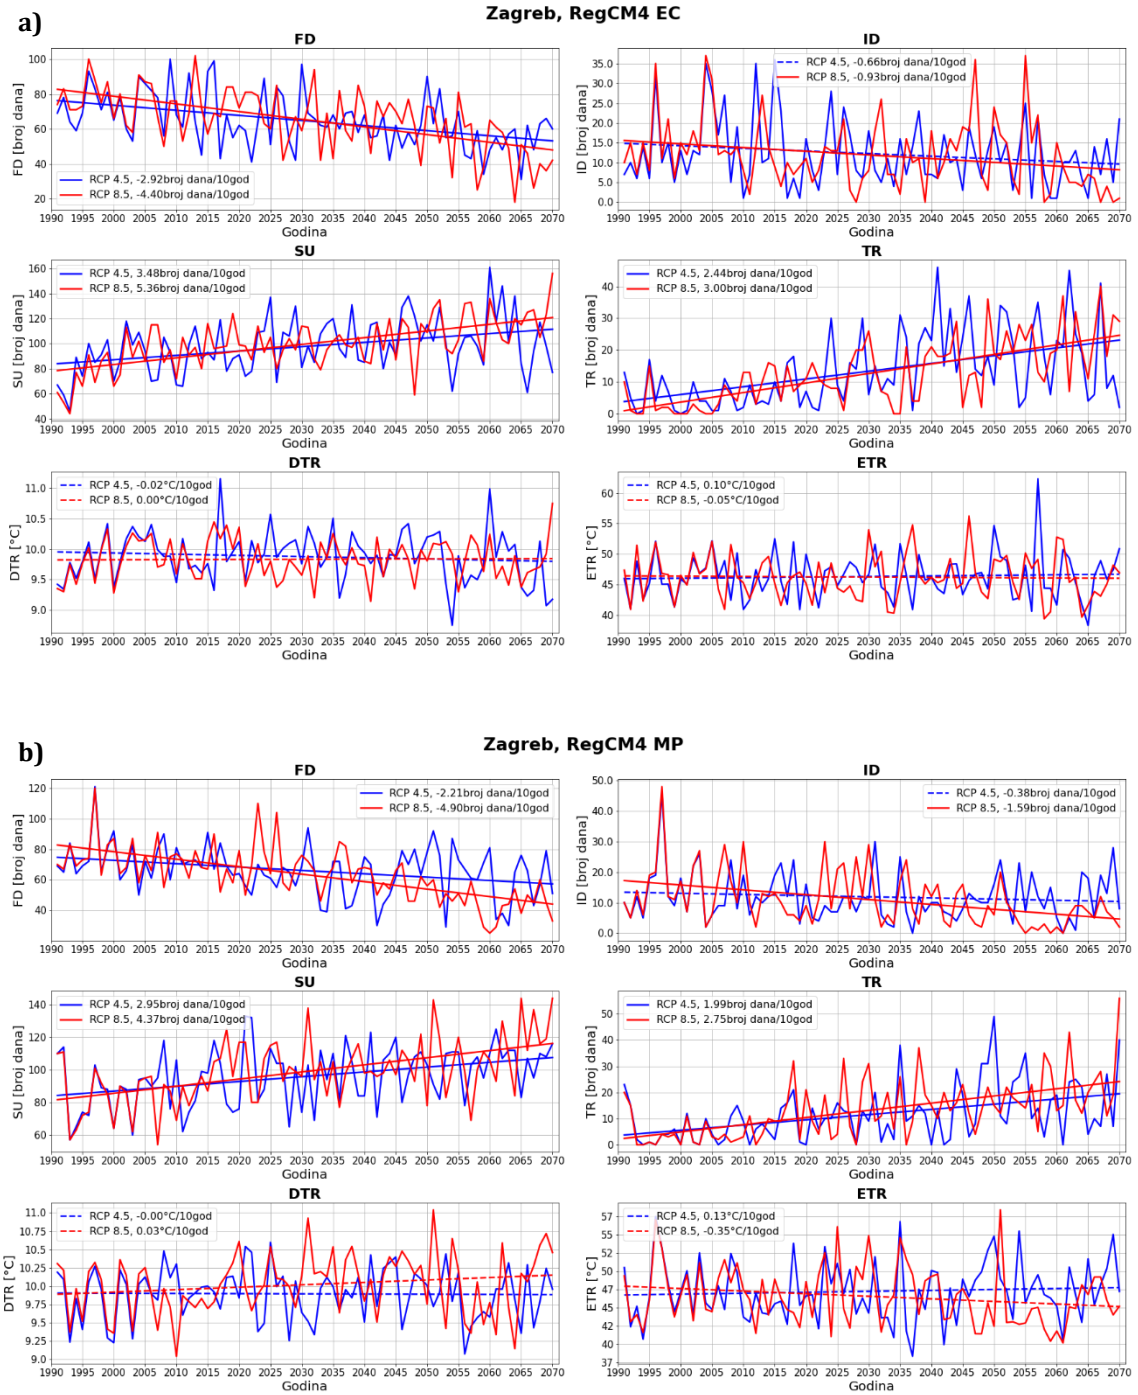

Slika C9: Vremenski nizovi klimatskih indeksa modeliranih RegCM4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Zagreb. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.

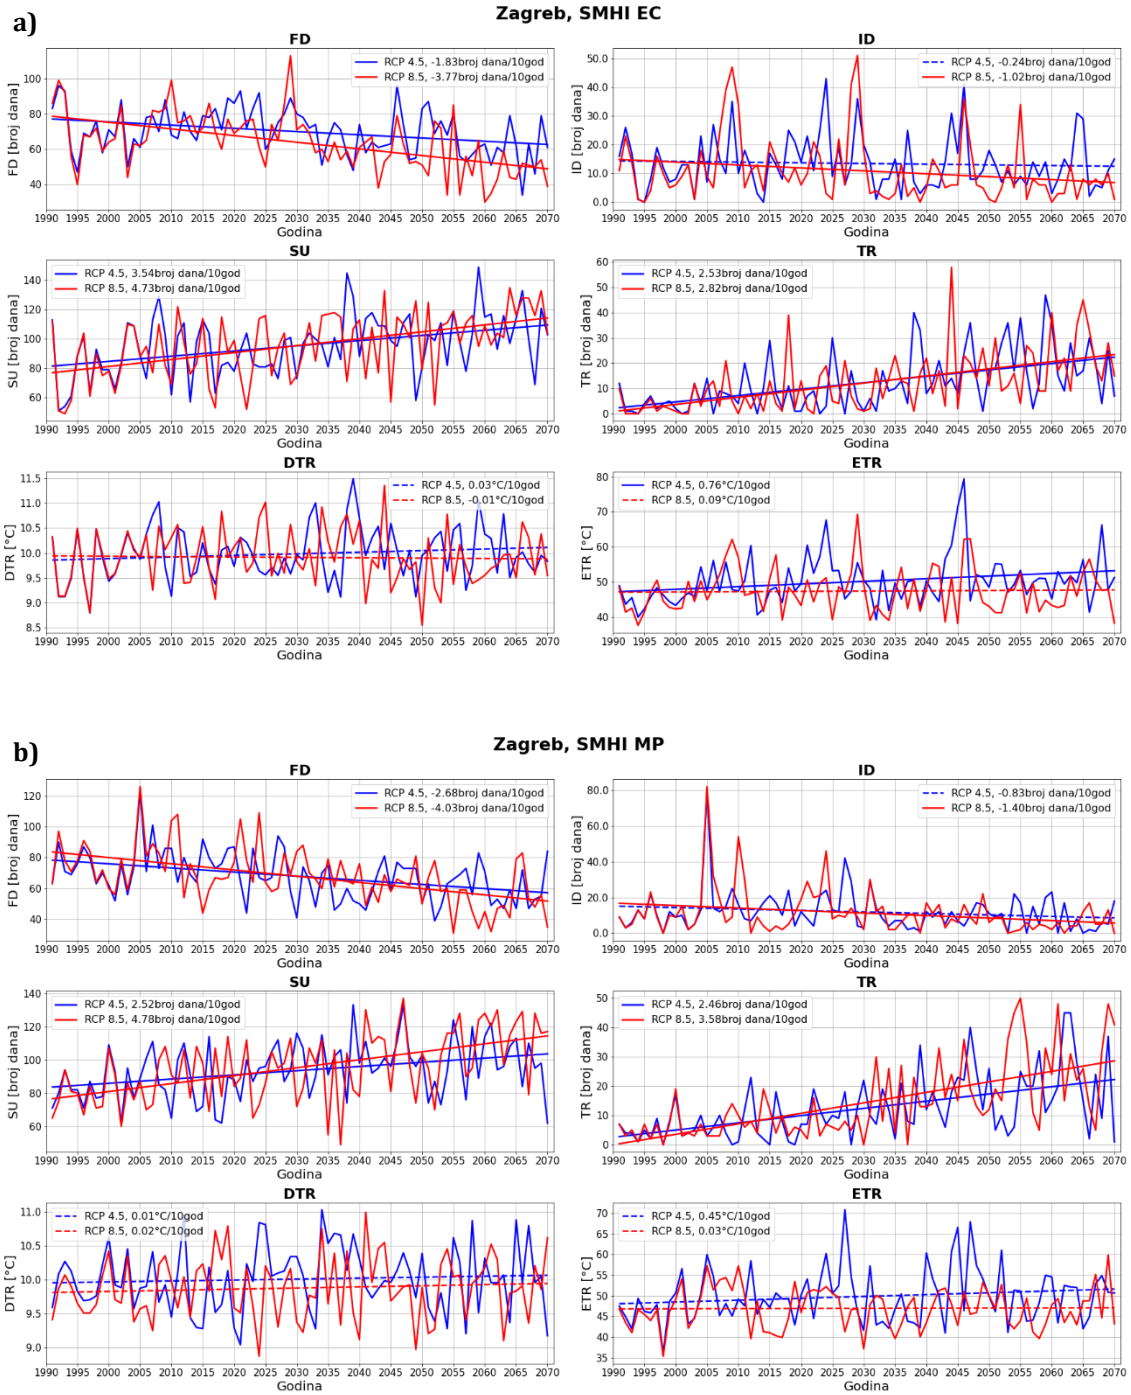

Slika C10: Vremenski nizovi klimatskih indeksa modeliranih SMHI-RCA4 RCM-om forsiranim s: a) EC i b) MP GCM-om, te pravci trendova i upisani trendovi izraženi u °C/10 god. za grad Zagreb. Pravci trendova koji nisu prošli test značajnosti na nivou značajnosti od 95 % označeni su isprekidanim linijama.