Opažanja i modeliranje klimatskih trendova temperature zraka i mora za jadransko područje

Radilović, Slavko

Doctoral thesis / Disertacija

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:217:170503

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb



Sveučilište u Zagrebu

PRIRODOSLOVNO-MATEMATIČKI FAKULTET

GEOFIZIČKI ODSJEK

Slavko Radilović

OPAŽANJA I MODELIRANJE KLIMATSKIH TRENDOVA TEMPERATURE ZRAKA I MORA ZA JADRANSKO PODRUČJE

DOKTORSKI RAD

Zagreb, 2021.



Sveučilište u Zagrebu

PRIRODOSLOVNO-MATEMATIČKI FAKULTET

GEOFIZIČKI ODSJEK

Slavko Radilović

OPAŽANJA I MODELIRANJE KLIMATSKIH TRENDOVA TEMPERATURE ZRAKA I MORA ZA JADRANSKO PODRUČJE

DOKTORSKI RAD

Mentor: prof. dr. sc. Darko Koračin

Zagreb, 2021.



University of Zagreb

FACULTY OF SCIENCE
DEPARTMENT OF GEOPHYSICS

Slavko Radilović

OBSERVATIONS AND MODELING OF AIR AND SEA TEMPERATURE CLIMATE TRENDS IN THE ADRIATIC REGION

DOCTORAL DISSERTATION

Supervisor: prof. dr. sc. Darko Koračin

Zagreb, 2021

Ova je doktorska disertacija izrađena na Fizičkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Splitu pod vodstvom prof. dr. sc. Darka Koračina, u sklopu Sveučilišnog poslijediplomskog doktorskog studija fizike, smjer geofizika, Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu.

ZAHVALA

Ovom doktorskom disertacijom se završava jedno intenzivno ali nadasve ugodno razdoblje u mom životu. Zahvala za pomoć u izradi ove disertacije, znanstvenim radovima i cijelom razdoblju koje im je prethodilo ide mnogim osobama.

Iskrene zahvale prof. dr. sc. Darku Koračinu, mom mentoru, na strpljenju, savjetima i to ne samo znanstvenim već i životnim te ukazanom povjerenju kroz sve godine mojeg doktorskog studija. Zahvaljujem se i dr. sc. Željki Fuchs-Stone koja mi je dala priliku za zapošljavanje i omogućila upisati doktorat u sklopu projekta Hrvatske zaklade za znanost.

Također, zahvaljujem se i svim suradnicima na projektu centra izvrsnosti STIM-REI - VODA I OKOLIŠ na čelu s prof. dr. sc. Darkom Koračinom na velikoj potpori tijekom moga rada kao znanstvenog suradnika na projektu. Zahvaljujem i suradnicima na projektu ADIOS Instituta za oceanografiju i ribarstvo u Splitu na čelu s dr. sc. Ivicom Vilibićem u okviru kojeg mi je omogućeno dodatno usavršavanje na Meteorološkom i hidrološkom institutu u Norrköpingu u Švedskoj. Zahvalu upućujem i svim suradnicima koji su sudjelovali u usmjeravanju i pisanju mojih znanstvenih radova koji su doveli do ove doktorske disertacije. Hvala i svim djelatnicima Fizičkog odsjeka Prirodoslovno-matematičkog fakulteta Sveučilišta u Splitu na stvaranju poticajne radne sredine.

Veliko hvala i dr. sc. Ivanu Güttleru s Državnog hidrometeorološkog zavoda čiji su brojni razgovori i sugestije učinili moj znanstveni rad boljim te ga podigli na veću razinu.

Posebno se želim zahvaliti i članovima povjerenstva za ocjenu doktorskog rada dr. sc. Ivani Herceg Bulić, dr.sc. Ivanu Güttleru i dr. sc. Vladimiru Đurđeviću na uloženom vremenu i trudu, komentarima i sugestijama koji su ovaj rad upotpunili.

Na kraju, veliko hvala mojoj supruzi Viktoriji, sinu Nikoli, mojim roditeljima Veselki i Petru, sestri Željki, obitelji na bezuvjetnoj podršci, razumijevanju, strpljenju i ljubavi.

Split, travanj 2021.

Slavko Radilović

SAŽETAK

Klimatska predviđanja temperatura zraka i mora u obalnim područjima predstavljaju veliki izazov zbog kompleksnih međudjelovanja između atmosfere, mora i kopna. Pošto je Sredozemlje proglašeno jednim od mjesta na Zemlji gdje su klimatske promjene najizraženije, regionalni klimatski modeli (*Regional Climate Models, RCMs*) i reanalize su zbog toga najpoželjniji alati za istraživanje sastava lokalne klime i promjenjivosti iste. Prednost je u tome što RCM-i bolje prikazuju kompleksnu orografiju razvijene obale na području kakvo je Jadran. Sve je to bitno za istraživanje temperaturnih trendova. Također, korištenje rezultata RCM-a, reanaliza visokih prostornih rezolucija te satelitskih mjerenja značajno pridonosi razumijevanju promjenjivosti klime te regionalnih klimatskih procesa. Jedni od takvih procesa su i morski toplinski valovi (*Marine heatwaves, MHWs*) koji u većini slučajeva nastaju kao posljedica klimatskih promjena (prijelaz velike količine topline iz atmosfere u more), odnosno rasta površinskih temperatura zraka i mora. Takvi ekstremni događaji imaju uvelike utjecaj na ekosustave i ljudske djelatnosti diljem svijeta, a posebice na ribarstvo.

Korišteni RCM-ovi uključuju modele iz CORDEX projekta s prostornim korakom od 0,11º s rezultatima povijesnih i evaluacijskih simulacija (Kotlarski i sur. 2014). Povijesne simulacije za rubne uvjete koriste rezultate simulacija globalnih klimatskih modela (*Global Climate Models, GCMs*) za razdoblje 1961. - 2005. godine, dok evaluacijske simulacije koriste ERA-Interim reanalizu za razdoblje 1989. - 2008. Simulirane temperature zraka su uspoređene s temperaturama standardne mreže kopnenih meteoroloških postaja, podatcima reanaliza UERRA te mrežom interpoliranih E-OBS mjerenja za šire područje Jadrana. Također, pri evaluaciji trendova površinskih temperatura mora korišteni su satelitski podaci i podaci ERA5 reanalize. U analizi su se koristile statističke metode kao što su pristranost, korijen srednje kvadratne pogreške, razlike koeficijenata trendova i to uspoređujući: (a) rezultate evaluacijskih simulacija naspram rezultata povijesnih simulacija; (b) RCM-ovi naspram reanaliza; i (c) točkasti podaci mjerenja na položajima postaja naspram mrežastih podataka (E-OBS). Ova analiza je rezultirala procjenom ograničenja u simuliranju temperaturnih trendova današnjom generacijom RCM-ova. Pokazano je da, bez obzira na ograničenja koja pojedini modeli imaju, ukoliko se više modela promatra kroz aritmetički srednjak ili težinske mjere njihovog ansambla, rezultati mogu biti bolji za 15 - 20% u odnosu na pojedini RCM (poglavlja 4.1.1 i 4.1.3).

Pri analizi MHW-ova na Jadranu su se još koristile i klimatološke mape 99. percentila, temeljene na tridesetogodišnjem klimatološkom srednjaku u razdoblju od 1982. do 2012., koje su korištene kao pragovi za otkrivanje pojedinih epizoda MHW-ova tako što bi se računalo kada srednja dnevna površinska temperatura mora prelazi vrijednost 99. percentila. Uvidom u trenutni i prošli broj ponavljanja epizoda, pokazano je da se broj MHW-ova povećava, a ujedno i njihova jačina raste iz godine u godinu. Prosječno vremensko trajanje ljetnih epizoda MHW-ova na Jadranu za razdoblje 1982. - 2018. iznosi između 6 i 7 dana dok su se epizode u ljetnim sezonama 2003. i 2015. godine pokazale kao najjače u zadnjih nekoliko desetljeća.

Ključne riječi: CORDEX, reanalize, satelitski podaci, Jadransko more, regionalni klimatski modeli, morski toplinski valovi, trendovi temperatura zraka i mora, međudjelovanje zrak-more

OBSERVATIONS AND MODELING OF AIR AND SEA TEMPERATURE CLIMATE TRENDS IN THE ADRIATIC REGION

EXTENDED ABSTRACT

Introduction

Investigating influence of climate change in last few decades led to conclusion that eliminating negative consequences of global warming needs scientific information on local and regional scales. Kotlarski et al. (2014) estimates that increased public interest has influenced the accelerated development of different climate scenarios. Part of this process is the development and improvement of techniques for adapting different techniques ("downscaling") with the aim of translating information from low-resolution domains used by global climate models (GCMs) to high-resolution domains used by regional climate models (RCMs; i.e., Hewitson & Crane 1996; Wilby & Fowler 2011). An important part in the development of climate models is the analysis and validation of model results in comparison with measurements. The procedure is to conduct an evaluation experiment with as best as possible boundary conditions, that is, the results of the reanalysis should be set as a boundary condition for the RCM.

Model evaluation is an essential procedure for the development of RCMs. Within the European domain, evaluation of a large number of regional climate models was carried out within large projects (PRUDENCE, ENSEMBLES). Different parameters are studied, including mean climatological distributions of temperature and precipitation as the two main parameters for studying climate change (Bergant et al. 2007; Böhm et al. 2008; Holtanova et al. 2012; Branković et al. 2013; Jacob et al. 2014; Jaeger et al. 2008; Kotlarski et al. 2005, 2014), temperature trends (Lorenz & Jacob 2010) and variability (Fischer et al. 2012; Vidale et al. 2007). The next generation of regional climate projections has been realized within the CORDEX initiative (Giorgi et al. 2009). The European part of the CORDEX initiative (EURO-CORDEX; Jacob et al. 2014) prepared regional climate projections for Europe with resolutions

of 0.11º and 0.44º including ensembles of regional models forced by various projections of GCMs as well as historical and evaluation simulations.

The Mediterranean area is extremely sensitive to global warming, and due to the complex morphology and socio-economic conditions it is one of the so-called "hot spot" areas for climate change (Giorgi, 2008). Similarly, the Adriatic Sea is sensitive to climate change, and with its complex coastal topography channels regional winds such as the Bora and Sirocco. With approximately 1,200 islands, the Adriatic is a region with a strong land-sea contrast, land-atmosphere feedback, and intense air-sea interaction. The inflow of 38 major rivers into the Adriatic is a significant component for dynamic and thermodynamic processes and represents one of the main dilution areas for the Mediterranean (Raicich, 1996). Significant differences in bathymetry of shallow northern and deep southern Adriatic, and the inflow of rivers, causes significant differences in seasonal characteristics of air and sea temperatures and has a strong impact on the Adriatic ecosystem (Zavatarelli et al. 2000; Spillman et al. 2007). Orlić et al. (1992) show that the main circulation has a seasonal dependence and consists of a large-scale cyclonic flow with smaller cells inside. Additionally, the connection between the southern Adriatic and the Ionian Sea is extremely complex (Manca et al. 2006; Civitarese et al. 2010) and shows significant seasonal differences (Zavatarelli & Pinardi 2002). Shaltout and Omstedt (2014) show that sea surface temperature (SST) trends in the Mediterranean are mostly positive and have seasonal properties.

SST and air temperature trends are increasing in the Mediterranean and the Adriatic (Branković et al. 2013; Radilović et al. 2019). This increase results in occurrence increase of the warm temperature anomalies in the ocean which characterize the marine heat waves (MHW). MHW can occur on the sea surface as well as propagate deeper to the water column (Schaeffer & Roughan 2017; Darmaraki et al. 2019a, 2019b, 2019c). Since, a stable stratification with a shallow mixing layer is present during the summer months, MHWs can be detected by the sea surface temperature. One of the strongest detected MHW occurred in the Mediterranean in the summer of 2003. This MHW episode registered SST anomalies of 2-3 °C above climatological mean and lasted for more than 20 days. SST increase was influenced by sea properties, air-sea flux exchanges and wind stress reduction (Grazzini & Viterbo 2003; Sparnocchia et al. 2006; Olita et al. 2007; Grbec et al. 2007).

Investigating MHWs has recently gained attention, where some studies analyzed past trends of extreme SST (e.g., MacKenzie & Schiedek 2007; Scannell et al. 2016). Past MHWs have been investigated in coastal regions (Lima & Wethey 2012; Schaeffer & Roughan 2017) and global ocean (Oliver et al. 2018a, 2018b). Mediterranean MHWs are being studied for last two decades where Darmaraki et al. (2019b) found an increase in surface MHW intensity and frequency in the basin for current century relative to the past and, described future evolution of MHWs in the Mediterranean Sea (Darmaraki et al. 2019a).

The main goal of this research includes observations, modeling, and evaluation of climate trends of air and sea temperatures for the Adriatic area. Signals of temperature change are used to examine the impact of climate change as well as to assess performance of RCMs in temperature reproduction. Also, it is important to investigate changes in frequency, duration, intensity, and possible causes of past MHWs in the Adriatic as one of the extreme consequences of the global warming and SST increase. This is significant for the 2003 and 2015 MHWs which were investigated from the aspects of air-sea interactions, cloudiness, and wind stress. These MHWs are highlighted as most severe MHW events in the Adriatic Sea and Mediterranean in the last decades.

Data and methods

For the purpose of this study, evaluation of eight EURO-CORDEX RCMs were performed using results from the evaluation mode (with ERA-Interim reanalysis forcing) for the 1989-2008 time period and results from the historical mode (with various GCM forcing) for the 1961-2005 period. Also, multi-model ensemble composed of eight EURO-CORDEX RCMs (seven for the historical mode) simulations at a 0.11° evaluation were evaluated. In addition, three high-resolution reanalyses, from the UERRA project, were used in this study: HARMONIE reanalysis from the Swedish Meteorological and Hydrological Institute (SMHI) with the spatial resolution of 11 km; MESCAN-SURFEX model reanalysis from Météo-France with 5.5 km resolution; and the unified model reanalysis (UM) from the UK Met Office with a 12 km resolution. All skill metrics were thus derived from monthly air temperature anomalies for the evaluation and the historical periods, respectively. The UERRA reanalyses were upscaled from the

original resolutions to match the resolution of the EURO-CORDEX regional models, which is 12.5 km (0.11°). Since, the UM results do not cover the entire 1961–2005 period it was excluded from the historical period analysis.

Skill assessment of eight RCMs and three different reanalyses in the Adriatic are estimated using the E-OBS surface air temperature data in addition to *in-situ* station observations measured by Croatian Meteorological and Hydrological Service (DHMZ). Observations consists of daily mean air temperature at 2 meters (T2m) to cover three regions of the Adriatic: islands (Lastovo, Hvar, and Rab), coastline (Dubrovnik, Split, and Rijeka), and inland areas (Sinj, Knin and Pazin). The E-OBS dataset (version v18.0e) interpolates 11 *in-situ* observations from stations along the eastern Adriatic coast, including six presented in this study (Rijeka, Knin, Split, Hvar, Lastovo, and Dubrovnik). The analyses assessed EURO-CORDEX RCMs performances based on three major comparisons. First, evaluation mode versus historical mode, then, reanalyses versus individual RCM (multi-model ensemble included), and, finally, point observation data vs. gridded data (E-OBS). Statistical measures such as bias, root mean square error (RMSE) and differences in trend coefficients were used in the analysis.

To investigate trends in regional SST and detect extreme events such as MHWs, satellite SST data provided by Earth-orbiting satellites are complementary to the in-situ network, providing finer and more complete spatio-temporal sampling. Since, during the summer, the mixed layer is thin and MHW are usually confined close to the surface, SST data of the first layer depth represent surface temperatures relevant for analysis and detection of the MHWs. Analysis and evaluation include satellite data provided by the Copernicus Climate Change Service (C3S) for the period 1982-2018, and ERA5 reanalysis data provided by European Centre for Medium-Range Weather Forecasts (ECMWF). C3S include L4 data of daily reprocessed SSTs on a 0.05°grid. This data is derived from satellite measurements collected by two series of sensors from the Earth-orbiting satellites: 11 Advanced Very High-Resolution Radiometers (AVHRRs) and three Along-Track Scanning Radiometers (ATSRs). ERA5 provides hourly worldwide estimates by using the 4D-Var assimilation method. Spatial resolution of ERA5 is 0.28°. Data used for analysis are hourly 2-meter air temperature, surface latent heat flux, surface sensible heat flux, total cloud cover, and U and V wind components at 10 m. All these parameters are averaged to construct daily means. For a uniform temperature diagnostic and for every grid point, the 99^{th} quantile of daily SST was computed. Then a 2D threshold map was constructed

from 30-year climatological means of these extreme values. An MHW episode at every grid point is assumed at any given day when the local SST 99th quantile threshold is exceeded with minimum duration of 5 days, following Hobday et al. (2016). The analysis includes the frequency, duration and intensity of each MHW event, especially, most prominent episodes of 2003 and 2015. Intensity is characterized by a mean difference of the temperature anomaly relative to the 99th quantile climatological threshold over the event duration. Also, episodes of 2003 and 2015 are additionally analyzed to examine air-sea interactions to potentially see causes of MHWs in the Adriatic Sea. This investigation includes correlation of the SST with parameters like surface latent heat flux, surface sensible heat flux, cloud cover, and wind stress.

Results and concluding remarks

The model-to-observation RMSE of the annual T2m averages and trend difference analysis show different behavior of the evaluation and historical results. In the evaluation period, RCMs, better represent variability with RMSE between 0.5 and 1.5 °C than in the historical period where variability is much higher (1.75-2.25 °C). This is due forcing and boundary condition issues where simulations in the evaluation mode are forced by ERA-Interim reanalysis and historical ones with GCMs. This, also, includes lack of data assimilation in historical simulations. One model, REMO2009, shows high RMSE (>1.3 °C) for all stations in the evaluation period. Higher REMO2009 model bias values, compared to the other RCMs, over Adriatic region, suggest possible reason why REMO2009 shows higher RMSE values.

Similar variability of the RCM results prevails among stations. Middle and southern Adriatic stations of Dubrovnik, Lastovo and Hvar exhibits RMSE between 0.6 and 0.8 °C. The northern Adriatic stations have higher RMSEs (>1 °C) because of complex terrain in the northern part of the Adriatic coast. This agrees with smaller RMSE values (0.6-0.8 °C) of the EURO-CORDEX ensemble in the evaluation period. All UERRA reanalyses showed similar RMSE values in both periods (0.25–0.8 °C), where slightly smaller RMSEs were present at the southern Adriatic stations (Dubrovnik, Lastovo and Hvar).

Trend differences among RCMs and observations at station locations of the stations are very similar when we compare both time periods. Also, there is a consistency in the sign present in

the trend difference at all stations for each RCM. In the historical period, significant underestimation (>0.1 °C decade^{-1}) was especially pronounced for the NCCNorESM1-M HIRHAM5 and CNRM-CM5 CCLM4-8-17 RCMs. A general overestimation of T2m trends in all RCMs and reanalyses, is present at station Sinj, which could have been caused by specific microclimates of the valley in which it is located. Although there were no significant differences in the RMSEs among UERRA reanalyses, distinct trend differences exist because different horizontal resolutions and surface models. It is significant to say that historical and evaluation EURO-CORDEX ensembles show improved results by 15-20 % compared to individual RCMs for trend difference results.

Spatial comparison of the T2m trend differences between RCMs and E-OBS gridded data show small differences (−0.5-0.5 °C decade^{-1}) for all models over the eastern Adriatic coast, while there are larger differences over the western coast and Italy. It can be emphasized that there is no connection between the land sea fractions and orography in RCMs with patterns of T2m differences in both periods. It is important that uncertainty, of simulated T2m, is determined by the density of stations, and the large amount of station data for the whole eastern Adriatic coast hinders easy model comparisons. All RCMs forced with the same global model, in the historical period, are strongly influenced by the same boundary conditions and show similar patterns.

Investigating summer SST of the Adriatic, during 1982-2018 period, western part is warmer than the eastern part by 2 ºC on average. In the Adriatic Sea, a NE-SW pattern of cold-warm temperatures is present during summer season (range from 22-25 ºC). This western-eastern difference in summer SST is around 3 ºC, where highest SST is observed in the shallow northern Adriatic. There is a warming tendency of mean annual SST and extremes (99th quantile). Both reanalysis (ERA5) and satellite data (C3S-L4) show that the extreme trends of SST_{99Q} are higher than trends of mean annual values by about 0.02 °C year^{-1} and are most pronounced in the south Adriatic. Comparing the Ionian and Adriatic Seas, it is shown that Ionian Sea is warmer than Adriatic by 0.5 °C although they have similar trends. There is a significant effect of T2m on the SST in the Adriatic by analyzing air-sea interaction. This is highly correlated with the Ionian Sea SST (correlation coefficient R = 0.92). High correlation suggests that local variability of SST is controlled by air-sea fluxes and local ocean processes.

Analysis of the MHW events in the Adriatic shows that average duration of the episodes is about 6-7 days in the 1982-2018 period. Result is obtained from both the reanalysis and satellite data. Also, 2003 and 2015 are detected as years with most pronounced MHWs in the last few decades. The 2015 episode is concentrated in the middle and southern Adriatic and connected with the Ionian Sea where average duration is higher than 20 days. In contrast, the 2003 episode was localized in the northern and middle Adriatic and appears to be decoupled from the Ionian Sea. The mean intensity of the MHW episodes for this 36-year period is 0.04 °C above SST_{99Q} threshold. This is lower in comparison with the 2003 and 2015 events where mean intensities are 0.3 °C and 0.4 °C, on average.

Closely investigating causes and the effects of 2003 and 2015 episodes it appears that 2003 episode is more related by the surface sensible heat flux (correlation coefficient 0.2-0.5) which can signify that colder air advection increases surface sensible heat flux while the 2015 episode is more related to surface latent heat flux which is positively correlated with SST (0.2-0.5) and can indicate possible existence of drier air advection over the Adriatic that summer. In 2003, negative correlation (between -0.4 and -0.1) in the Adriatic implicates that weaker winds over the warm water regions can reduce the latent heat flux and increase the SST preventing formation of deep convective clouds (correlation -0.3 and -0.5). Generally, analyzing occurrence frequency of MHW episodes of different duration (5-days, 10-days, 15-days, and 20-days), only 5 and 10-day episodes have noticeable increase of 0.1 event per decade. Statistical significance (95%) of all frequency occurrences is confirmed by Mann-Kendal test.

Increasing climate change requires investigation of capabilities of regional climate models to predict MHW events in terminal seas such as the Adriatic. Additionally, assessing of how regional climate model parametrizations, including land surface processes, soil hydrology, and land-sea fraction specifics, impact variability in coastal regions. This is, also, important for the identification of regions with high physical predisposition for these extreme events because of MHW influence on the various ecosystems.

Keywords: CORDEX, reanalyses, satellite data, Adriatic Sea, regional climate models, marine heatwaves, air and sea temperature trends, air-sea interaction

POPIS KRATICA I POJMOVA

ATSR	*Along-Track Scanning Radiometer*
AVHRR	*Advanced Very High-Resolution Radiometer*
C3S	*Copernicus Climate Change Service*
CORDEX	*The Coordinated Regional Downscaling Experiment*
DHMZ	*Državni hidrometeorološki zavod*
ECMWF	*Europski centar za srednjoročnu prognozu*
ENSEMBLES	*ENSEMBLE-based Predictions of Climate Changes and their Impacts*
EURO-CORDEX	*europska domena CORDEX inicijative*
ERA	*ECMWF Re-Analysis*
E-OBS	*europska mreža podataka visoke rezolucije*
GCM	*globalni klimatski model*
HARMONIE	*HIRLAM–ALADIN Research on Mesoscale Operational NWP in Euro-med system*
IPCC	*Međuvladin panel o klimatskim promjenama*
L4	*četvrta razina podataka*
MESCAN-SURFEX	*sustav (model) površinske analize*
MHW	*morski toplinski valovi*
PRUDENCE	*Prediction of Regional scenarios and Uncertainties for Defining European Climate change risks and Effects*
RCM	*regionalni klimatski model*
RMSE/RMSD	*korijen srednje kvadratne pogreške/razlike*
SLHF	*površinski tok latentne topline*

SMHI	*Švedski hidrometeorološki institut*
SSHF	*površinski tok osjetne topline*
SST	*površinska temperatura mora*
T2m	*temperatura zraka na 2 metra visine*
TCC	*ukupna naoblaka*
UERRA	*Uncertainties in Ensembles of Regional ReAnalysis*
UM	*Unified Model*
WS	*napetost vjetra*

SADRŽAJ

SAŽETAK i

EXTENDED ABSTRACT iii

POPIS KRATICA I POJMOVA x

1. UVOD 3

1.1 Obilježja temperature zraka na Jadranu 4

1.2 Obilježja temperature mora na Jadranu 5

1.3 Modeliranje klime regionalnim klimatskim modelima 7

1.3.2 Razvoj regionalnih klimatskih modela (RCM) 8

1.4 Klimatsko modeliranje na jadranskom području 11

1.5 Ciljevi i motivacija doktorskog istraživanja 11

2. PODACI 12

2.1 Prizemna mjerenja temperature zraka 12

2.2 Satelitska mjerenja površinske temperature mora (C3S-L4) 14

2.3 Produkt E-OBS 15

2.4 Reanalize UERRA 15

2.5 Reanaliza ERA5 17

2.6 Regionalni klimatski modeli 17

3. METODOLOGIJA 20

3.1 Metrika regionalnih klimatskih modela i statistički parametri 20

3.2 Identifikacija toplinskih valova u Jadranu 26

4. REZULTATI I DISKUSIJA 29

4.1 Temperatura zraka na 2m (T2m) 29

4.1.1 Lokalna sezonska obilježja i trendovi 29

4.1.2 Rangiranje regionalnih modela kroz ljetne (JJA) i zimske (DJF) sezone te prednosti korištenja ansambla 38

4.1.3 Prostorna, regionalna obilježja i trendovi 44

4.2 Površinska temperatura mora 50

4.2.1 Trendovi površinske temperature mora i evaluacija metode za detekciju toplinskih valova u moru 50

4.2.2 Analiza toplinskih valova u moru u ljetnim sezonama (JJA) u razdoblju od 1982. do 2018. 56

4.2.3 2003. i 2015. godina - ekstremne ljetne epizode toplinskih valova u Jadranu 59
5. ZAKLJUČAK 67
6. LITERATURA 72
Životopis 84
Popis radova 86

1. UVOD

Područje istočne jadranske obale je orografski vrlo razvijena zona, gdje su vremenski i klimatski obrasci uglavnom pod utjecajem složene topografije i međudjelovanja kopna i mora. Također, s otprilike 1200 otoka, otočića i hridi, Jadran je i područje jakog utjecaja atmosfere i kopna na more te povratnog mehanizma između kopna i atmosfere.

Kada govorimo o jadranskoj regiji, moramo naglasiti da more obuhvaća većinu područja, a ostatak čini kopno. Zbog toga je i temperatura zraka pod utjecajem mora koje posjeduje sposobnost da zadrži sunčevu toplinu. Upravo je sporije grijanje i sporije hlađenje mora razlog zbog čega temperatura nikad ne doseže ekstremne vrijednosti kao što je to slučaj kod kopnene površine. Planinski obalni lanac Dinarida uvelike smanjuje utjecaj sredozemne klime na unutrašnjost Balkanskog poluotoka, međutim djeluje i obratno tako da smanjuje utjecaj hladnije klime iz unutrašnjosti. Temperatura se može promijeniti i dolaskom toplih ili hladnih zračnih strujanja koje dolaze na područje Jadrana iz udaljenih krajeva, a također i sama strujanja (kao okidač promjene temperature) mogu nastati pod utjecajem lokalnog vjetra (Penzar i sur. 2001). Pod utjecajem vjetra su i morske struje koje ulaze u Jadran kroz Otrant te putuju istočnom jadranskom obalom dok duž zapadne jadranske obale izlaze ponovno u Jonsko more. Strujanja ujedno imaju i sezonski režim gdje su u ljetnim sezonama pod utjecajem sjeverozapadnog vjetra (maestral) dok su zimi više pod utjecajem jugoistočnog i južnog vjetra (jugo). Površinska cirkulacija na Jadranu uključuje i nekoliko lokalno-cirkulacijskih režima (eng. *„gyre“*). Najveći i najpoznatiji cirkulacijski režim se nalazi na južnom (dubljem) dijelu Jadrana koji je kružni režim ciklonalnog strujanja. Druga dva veća režima su kružni režimi u kotlini otoka Jabuke na srednjem Jadranu i sjevernojadranski režim. Sjevernojadranski režim je ciklonalnog smjera koji, pod utjecajem Bure, uzrokuje stvaranje voda visoke gustoće (eng. „*high density waters*“) u plićem dijelu sjevernog Jadrana.

Jadran je, ujedno, i područje u kojem se uvelike očituju globalne klimatske promjene te će i u budućnosti te promjene biti sve izraženije (Giorgi 2006). Promjene će se najviše očitovati u porastu temperature zraka i mora do kraja 21. stoljeća. Negativne posljedice porasta temperature mora su uzroci stvaranja temperaturnih anomalija na morskoj površini koje nazivamo morski toplinski valovi. U ovoj će se doktorskoj disertaciji govoriti o klimatskim obilježjima temperature zraka i mora te njihovim trendovima. Ujedno će se i analizirati ekstremne

posljedice porasta temperatura kroz toplinske valove na moru s posebnim naglaskom na jedne od najizraženijih epizoda toplinskih valova u moru s početka 21. stoljeća (2003. i 2015. godine).

1.1 Obilježja temperature zraka na Jadranu

Temperatura zraka na Jadranu je određena zemljopisnom širinom. Generalno, postoji povećanje temperature zraka, odnosno gradijent, od sjeverozapada prema jugoistoku. Posljedica takve raspodijele temperature zraka je često strujanje hladnog zraka (koje je uvjetovano raspodjelom tlaka) s kopna na sjeverni Jadran. To se posebice očituje u zimskim mjesecima (Stravisi 1984). Također, Artegiani i sur. (1997) su pokazali da prevladava zapadna komponenta strujanja tijekom cijele godine i u svim sezonama. Dodatno obilježje temperature jest da je istočni dio Jadrana topliji od zapadnog ako gledamo istu zemljopisnu širinu (Stravisi 1984). Razlog tome možemo pronaći zimi kada se topli zrak sa Sredozemlja giba duž istočne obale Jadrana prema njegovom sjevernom dijelu, a hladan alpski zrak putuje od doline rijeke Po duž zapadnog Jadrana prema Otrantu (Penzar i sur. 2001). Morske struje također imaju utjecaj jer se morska voda na sjeveru Jadrana ohladi pod utjecajem alpskih rijeka te zatim putuje duž zapadne obale Jadrana prema Sredozemnom moru (Penzar i sur. 2001).

Najhladniji mjesec u godini je siječanj, a najtopliji srpanj. Zimi je zrak nad sjevernim dijelom Jadrana hladniji nego na južnom dijelu dok ljeti nema tako izrazite razlike. Topliji zrak se nalazi nad zapadnom obalom dok je nad otvorenim morem temperatura niža i ne razlikuje se duž Jadrana (Furlan 1977; Cantu 1977).

Temperatura zraka na Jadranu se mjenja i s visinom. To je posebice važno za istočnu jadransku obalu koju krase obronci Dinarida. Prisutno je sniženje temperature zraka s porastom visine dok se zrak noću najviše hladi u blizini tla. Stoga su kotline i udoline zimi hladna područja. Razlike u temperaturi zraka na meteorološkim postajama velike visinske razlike, premda ponekad i male udaljenosti, mogu biti znatne. Te razlike su manje zimi nego ljeti zbog temperaturnih inverzija koje se događaju na nižim postajama (Biel 1927; Penzar i sur. 2001). Izuzetno hladnih dana (u kojima je srednja dnevna temperatura neprekidno niža od 0 °C) na Jadranu ima vrlo malo. Izuzetak je Pazin koji takve dane zbog svoje mikro-klime ima u prosjeku tri puta godišnje. Hladnih dana (srednja dnevna temperatura od 0 °C i malo iznad 0 °C) najviše ima na obroncima Dinarida u južnoj Dalmaciji. Vrućih dana (srednje dnevne temperature iznad 30 °C)

najviše ima u Istri i na otocima i to od 20 do 30 dana s time da se ponegdje na obali taj broj penje i do 50 (Penzar i Penzar 1995). Važno je naglasiti da veliki porast temperature zraka na Jadranu najčešće uzrokuju zračne mase iz sjeverne Afrike, unutrašnjosti Balkanskog poluotoka ili susjednih zemalja (Penzar i sur. 2001).

Dosadašnja istraživanja su pokazala da su u 7 odnosno 8 od 12 mjeseci u godini temperature mora veće od temperatura zraka na cijelom jadranskom području (Stipaničić 1975). S obzirom da je takvo stanje na cijelom Sredozemlju, potrebno je dodatno istraživanje odnosa mora i atmosfere i njihovog međudjelovanja, uključujući bolje poznavanje i opis klimatoloških obilježja temperatura mora i zraka.

1.2 Obilježja temperature mora na Jadranu

Temperatura mora na Jadranu se mjeri na obalnim i otočnim postajama. To su najčešće površinska mjerenja koja se izvode jedan do tri puta na dan. Takva mjerenja su pokazala da su zimske temperature mora na sjevernom Jadranu niže nego na srednjem ili južnom Jadranu. Na otocima su temperature više nego u priobalnom području (Supić i Orlić 1992). Minimalne temperature mora su izmjerene na prelazu iz zime u proljeće (veljača i ožujak) dok su maksimalne temperature mora izmjerene u kolovozu. Temperatura mora u okolici Senja je pod jakim utjecajem zračnih strujanja (najviše bure) i utjecaja hladnih kopnenih voda pa je zbog toga ona niža u odnosu na okolni sjeverni Jadran (Prtenjak i Grisogono 2007; Grisogono i Belušić 2009). Također, pokazano je da je prisutan gradijent temperature mora koji raste od sjevera prama jugu gdje na sjevernom Jadranu prosječna temperatura mora iznosi 15 - 16 °C a na južnom Jadranu 17 - 18 °C (Supić i Orlić 1992). S obzirom da temperatura mora raste od priobalja prema otvorenom moru, javlja se povratni mehanizam gdje se toplina vraća prema obali. To se događa posebice zimi gdje se more zbog toga hladi, a priobalne vode zagrijavaju (Penzar i sur. 2001).

Zore-Armanda i Grbec (1993), u svojoj analizi ljetnih morskih temperatura iz 1992. godine, navode da se u određenim situacijama stanja atmosfere nad Jadranom mogu stvoriti uvjeti koju podržavaju slab vjetar i zračna strujanja u dužem vremenskom razdoblju uslijed čega se javljaju

anomalno visoke temperature mora. Razlog tome jest slabo miješanje u moru zbog čega toplina ostaje zarobljena na površini. Površinska temperatura mora najniža je u zimskoj sezoni i to na najplićem dijelu sjevernog Jadrana. Također, dva dijela Jadrana bilježe povišenja temperature. To su Jabučka i Južnojadranska kotlina (Penzar i sur. 2001).

Mjerenja temperature mora na Jadranu nisu vršena kontinuirano, izuzev zadnjih par desetljeća. Iako su neki vremenski nizovi mjerenja manji od 30 godina, za neke detaljnije klimatološke analize takvih nizova ipak možemo kazati da utjecaj temperature mora na temperaturu zraka postoji. Očituje se u sporom jesenskom ohlađivanju i proljetnom grijanju tako da je u priobalju proljeće hladnije od jeseni. Idući dalje u unutrašnjost Balkanskog poluotoka, taj se utjecaj gubi (Sijerković i Milković 1995; Sijerković i Zaninović 1996, 1998, 1999).

Brodska mjerenja temperature mora vrše se na Jadranu od sredine 19. stoljeća. Ona su se vršila povremeno, s prekidima u razdobljima kako dvaju svjetskih ratova tako i Domovinskog rata. Tek se krajem 20. stoljeća počelo prikupljati dovoljno podataka da bi se mogla analizirati temperatura mora. Buljan (1965), prema brodskim mjerenjima za područje otoka Visa, navodi da krajem veljače temperatura mora postaje konstantna po dubini što znači da se uspostavlja homotermija. Tijekom proljeća se more u većim dubinama počinje zagrijavati uslijed prijenos topline s površine u dublje slojeve mora. Na oko 20 m dubine formira se termoklina. Valja naglasiti da se temperatura mora na velikim dubinama (ispod 100 m) ispod termokline ne mijenja značajno. U jesen počinju puhati vjetrovi uslijed čega more počinje gubiti toplinu. Ponovnim nastupom zime, daljnje hlađenje uzrokuje smanjenje temperature u cijelom vodenom stupcu.

Krajem 1980-ih godina temperatura mora se počela mjeriti satelitskim senzorima pa je do kraja 1990-ih i početka 2000-ih godina prikupljeno dovoljno podataka za podrobniju analizu obilježja površinske temperature mora (Orlić i sur. 1992; Gačić i sur. 1997; Borzelli i sur. 1999; Tomažić 2000). Pokazuje se da postoje zimske i ljetne temperaturne anomalije koje se mogu manifestirati na cijelom jadranskom području, premda, zimi se češće javljaju na sjevernom Jadranu (npr. 1992. i 1993. godine su postojale hladne anomalije na cijelom Jadranu), a ljeti na južnom. Za ljetne sezone 1992., 1994., 1998., 2003. i 2015. godine su zabilježene ekstremno visoke ljetne temperature mora (Gačić i sur. 1997; Tomažić 2000; Grbec i sur. 2007; Darmaraki i sur. 2019b).

1.3 Modeliranje klime regionalnim klimatskim modelima

Procesima u klimatskim sustavu upravlja ukupna količina energije u sustavu, a preraspodjela te energije određuje daljnji razvoj procesa. Na dužim vremenskim skalama energijska bilanca planeta je presudna za razumijevanje mogućih promjena klimatskog sustava tijekom vremena. Upravo će promjene u energijskoj bilanci, bilo da su pod utjecajem čovjeka ili prirode, uzrokovati klimatske promjene. Globalne klimatske promjene podrazumijevaju postojanje određene metrike (kao što je na primjer globalna prosječna temperatura) i određeni smjer (npr. zagrijavanje ili pozitivan trend). Shodno tome, globalno zatopljenje je dio (podskup) klimatskih promjena kao takvih (Gettelman i Rood 2016).

1.3.1 Povijest klimatskog modeliranja

Klimatsko predviđanje nadišlo je samu spoznaju dnevnog vremena i njegovih utjecaja na ljude i socio-ekonomske prilike (Edwards 2010). Takvo razmišljanje se počelo javljati u 1960-im godinama s prvim znacima razvoja klimatskog predviđanja. Znanstvenici, poput Simone Laplacea, su još u 19. stoljeću imali ideju da, ako znamo gdje se sve čestice u svemiru nalaze i poznajemo zakone koji njima upravljaju, tada možemo predvidjeti njihovu budućnost. Takvo razmišljanje se kroz povijest mijenjalo, a pogotovo u trenutku kad je kvantna mehanika pokazala da se ipak ne mogu opisati svojstva pojedine čestice bez da se ujedno i utječe na tu česticu.

Prvi eksperimenti i analize predviđanja stanja vremena s početka 20. stoljeća pokazuju da je dovoljnim poznavanjem osnovnog stanja vremena i fizičkih zakona koji njime upravljaju, moguće predvidjeti njegovo stanje u određenom (ne svakom) trenutku u vremenu. U početku su jednadžbe koje su opisivale takva stanja sustava bile analitički nerješive do pojave Carl Gustav Rossbya i njegovog uvođenja prvih pretpostavki u jednadžbe koje su pojednostavile takve sustave i omogućile opis evolucije stanja vremena i njihovo predviđanje. Nakon Drugog svjetskog rata i izrade prvih računala počele su se izračunavati jednadžbe stanja (Dyson, 2012). Takve prve simulacije su mogle predstaviti važne aspekte opće cirkulacije, a odatle su razvijeni klimatski modeli (izvorno opći cirkulacijski modeli). Daljnjim razvojem računala simulacije su postajale sve bolje i preciznije. To je dovelo do razvoja različitih vrsta klimatskih modela.

1.3.2 Razvoj regionalnih klimatskih modela (RCM)

Regionalni klimatski modeli (RCM) su razvijeni s ciljem povećanja razlučivosti klimatskih polja dobivenih globalnim klimatskim modelima (GCM), pružajući na taj način informacije u finim mrežama prikladnijim za proučavanje regionalnih fenomena i za procjenu njihovih utjecaja i prilagodbe. Način na kojem se temelji ovaj princip povećanja razlučivosti (Hewitson i Crane 1996; Giorgi i Mearns 1999; Giorgi 2008; Wilby i Fowler 2011; Branković i sur. 2012) jest da GCM može opisati odziv globalne cirkulacije na utjecaje na velikim prostornim skalama, poput stakleničkih plinova ili varijacija sunčevog zračenja, dok RCM može prostorno i vremenski profiniti ovu informacije na preciznijoj skali uzimajući u obzir fizičke procese koji se odvijaju na mrežama velike razlučivosti unutar samog GCM-a, poput utjecaja složene topografije, obalnih linija, kopna ili dinamičkih procesa koji se javljaju na mezoskali (Christensen i sur. 2007; Branković i sur. 2013; Kotlarski i sur. 2014; Giorgi 2019).

Regionalni klimatski modeli su se počeli razvijati 1980-ih godina (Giorgi i Bates 1989, Dickinson i sur. 1989). Usprkos razvoju RCM-ova ipak se razvila debata među znanstvenicima o kvaliteti samih rezultata klimatskih modela. Iako su regionalni modeli, kao i svi modeli, ipak samo približan prikaz stvarnosti te su kao takvi nesavršeni, oni ipak daju puno bolju informaciju o procesima na regionalnim prostornim skalama nego globalni modeli.

Europska znanstvena zajednica se počela intenzivnije baviti analizama rezultata simulacija RCM-ova negdje sredinom 1990-ih godina kroz europske projekte kao što su: MERCURE (Machenhauer i sur. 1998), PRUDENCE (Christensen i sur. 2007), ENSEMBLES (van der Linden i sur. 2009), PRINCIPLES (SMHI), EUCP (https://www.eucp-project.eu/) i EURO-CORDEX (Jacob i sur. 2014). Projekt MERCURE je bio određen za testiranje različitih RCM-ova, dok su se u projektu PRUDENCE prvi puta vršile klimatološke simulacije (30 godina rezultata) europskog kontinenta s prostornim korakom od približno 50 km. Unutar projekta ENSEMBLE su povećani prostorni koraci na 25 km te je omogućena bolja razlučivost. Projekt EUCP uključuje izradu i unaprjeđenje modela koji uključuju konvektivne procese (eng. *Convection-Permitting*). Za razliku od hidrostatskih modela, modeli koji dopuštaju konvekciju (CP-RCMs) poboljšavaju prikaz regionalne klime boljim razlučivanjem regionalnih i lokalnih fizičkih procesa koji su povezani s topografijom, a nastaju kao odgovor na promjenjivost u

atmosferskoj cirkulaciji na velikim prostornim skalama. Najnoviji projekt EURO-CORDEX je je prvi puta proizveo rezultate povijesnih GCM-RCM simulacija s jako finim prostornim korakom od oko 12,5 km te su one postale standardni dio europskih klimatskih servisa. Također, europska inicijativa MED-CORDEX (Ruti i sur. 2016) pokrenula je razvoj združenih regionalnih klimatskih modela koji povezuju sustav atmosfera-more.

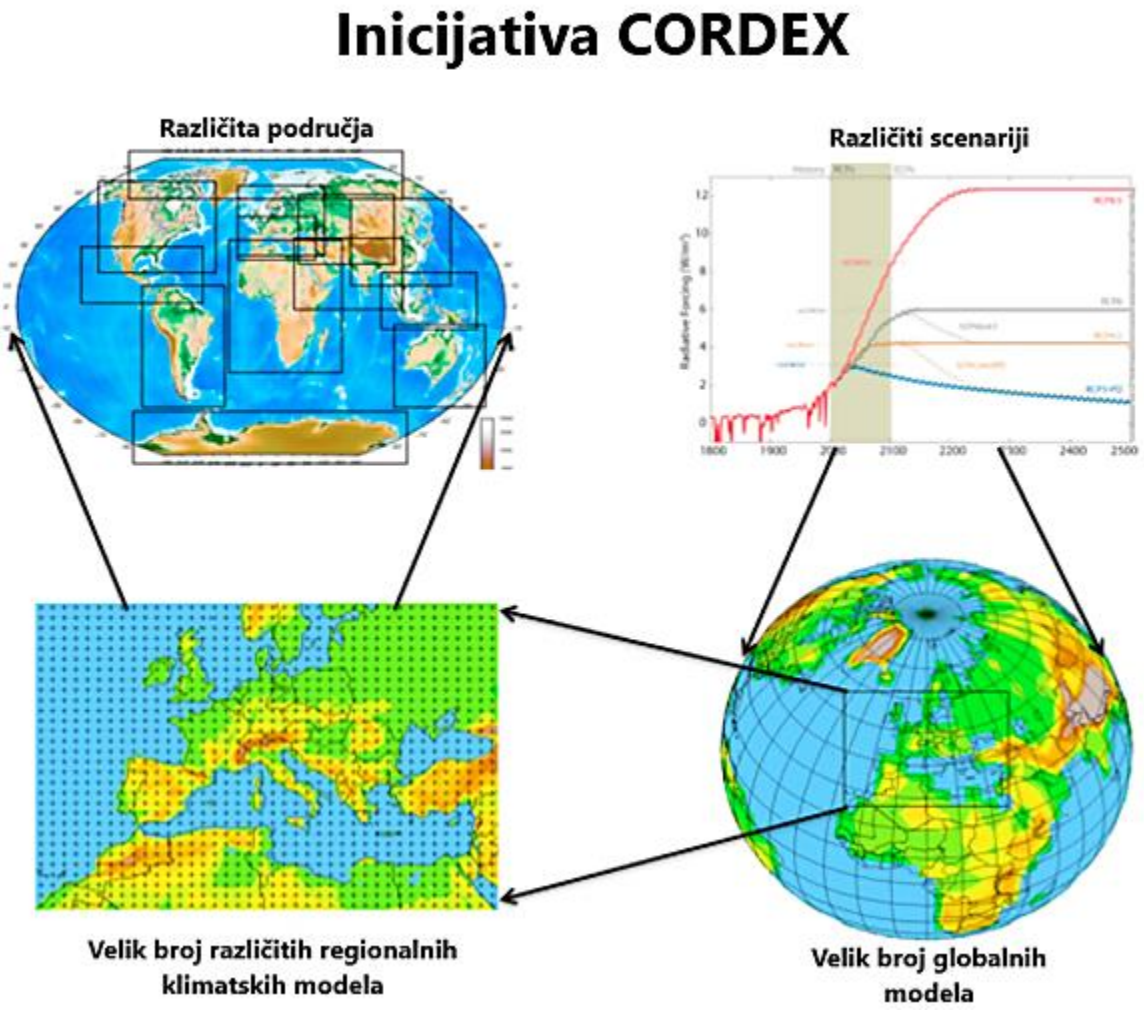
Tijekom rada navedenih projekata ustanovilo se da postoje određeni problemi u regionalnom klimatskom modeliranju gdje su se primjenjivali različiti modeli i simulacije u različitim područjima i pri tome su rezultati takvih modela korišteni za razne namjene. Zbog toga je bilo jako teško povezivati znanja koja su se stekla kroz sve te projekte i nije se mogao dati jedan zajednički sustavni opis ponašanja svih RCM-ova (Takle i sur. 2007; Giorgi 2019). Rješavanju tog problema pristupilo se osnivanjem inicijative CORDEX (Giorgi i sur. 2009; Jones i sur. 2011). Inicijativa CORDEX (sl. 1) je postala okvir za razna znanstvena partnerstva koja danas unaprijeđuju regionalno klimatsko modeliranje.

Inicijativa CORDEX ima za cilj: *(i)* bolje razumijevanje promjenjivosti i promjenjivosti klimatskih fenomena kroz velike rezolucija RCM-ova, *(ii)* unaprjeđenje samih RCM-ova, *(iii)* proizvodnju ansambala različitih regionalnih modela za razna područja te *(iv)* razmjenu znanja znanstvenih institucija unutar područja regionalnog klimatskog modeliranja. Proizvodnja samih ansambala je stvorila repozitorije u kojima se nalaze rezultati različitih scenarija, zatim različitih GCM-ova (preko kojih su analizirani različiti lateralni rubni i početni uvjeti) uključenih u RCM-ove (Gutowski i sur. 2016).

Rummukainen (2016) upućuje na stvarnu vrijednost rezultata RCM-ova ističući da poboljšanje razlučivosti ne mora uvijek dovesti do kvalitetnijih rezultata u odnosu na globalne modele s lošijom razlučivosti. Ukoliko nas zanimaju varijable usrednjene na širem području, onda povećanje prostornog koraka (dinamička prilagodba) nije potrebno. Međutim, ukoliko nas zanimaju klimatološka obilježja na području s kompleksnom orografijom ili nas zanimaju lokalni ekstremi, manji prostorni koraci su itekako bitni i stvaraju „*dodatnu vrijednost*“ (eng. *added value*) na domeni obuhvaćenoj regionalnim modelom (Önol 2012; Branković i sur. 2013; Mayer i sur. 2015; Torma i sur. 2015). Također, često se navodi da regionalni modeli moraju biti uspješniji od globalnih modela jer u protivnom ne stvaraju dodatnu vrijednost, ali trebamo voditi računa da primjerice jedan regionalni model može u sebi sadržavati sustavnu pristranost (eng. *bias*) na cijelom području domene (područje od interesa za koje su izrađene simulacije

pojedinog RCM-a) te kao takav davati lošije rezultate od globalnog modela. Ovo upućuje na to da metodologija ne smije biti generalizirana već se mora svakom RCM-u pristupati posebno. Dodatno pitanje se stvara u tome hoće li sustavna pogreška koja je ustanovljena kod određenog RCM-a propagirati i u rezultate klimatskih projekcija te na taj način utjecati na njihovu kvalitetu (Giorgi 2019).

Budućnost regionalnog klimatskog modeliranja leži u postupnom prijelazu s klasičnih hidrostatskih atmosferskih RCM-ova na *„Convection-Permitting"* RCM-ove visoke razlučivosti (Denamiel et al. 2020, 2021) koji će biti povezani i s drugim komponentama klimatskog sustava kao što su ocean i biosfera. Posebni naglasak na području Jadrana će predstavljati *„Convection-Permitting"* RCM-ovi povezani s oceanskim sustavom.



Slika 1: Opis dijelova inicijative CORDEX. *Izvor: Giorgi (2019).*

1.4 Klimatsko modeliranje na jadranskom području

Veliki utjecaj na regionalno modeliranje na jadranskom području ima kompleksna orografija koja se očituje u jakoj razvedenosti istočno jadranske obale obilježene Dinaridima. Dosadašnje analize rezultata RCM-ova pokazuju jaku prostornu povezanost kod parametra temperature zraka (Branković i sur. 2013). Branković i sur. (2012) upućuju na to da regionalni modeli s prostornim korakom od 35 km ne mogu dovoljno dobro prikazati sezonske prostorne raznolikosti temperaturnih ekstrema u području s kompleksnom orografijom, dok Önol (2012) pokazuje da RCM-ovi s malim prostornim korakom od 10 km daju dobre rezultate u usporedbi s mjerenjima na kompleksnim područjima u Turskoj.

Branković i sur. (2013) su napravili analizu temperature zraka i oborina na jadranskom području koristeći regionalne modele s prostornim korakom od 25 km. Regionalni modeli su iz projekta PRUDENCE. Radilović i sur. (2019) pokazuju da lateralni rubni i početni uvjeti iz globalnih modela imaju dominantni utjecaj na rezultate bez obzira na fiziku regionalnih modela jer različiti RCM-ovi tjerani istim globalnim model pokazuju sličnu raspodjelu i točnost rezultata kad se usporede s mjerenjima i reanalizama. Stoga, ukoliko se različiti RCM-ovi koriste kao model-ansambl (skup modela čiji su rezultati usrednjeni u jedan model-ansambl) poboljšavaju rezultate za 15 do 20 posto (poglavlja 4.1.1. i 4.1.3.).

1.5 Ciljevi i motivacija doktorskog istraživanja

Istraživanje klimatskih trendova površinskih temperatura zraka i mora na jadranskom području od iznimne je važnosti. S obzirom da globalni modeli ne mogu dati odgovor u područjima velike razvedenosti i kompleksnosti terena kakva je jadranska obala, potrebno je koristiti regionalne modele, reanalize i satelitske podatke (uz mjerenja DHMZ-a) da bi se omogućila procjena regionalne klime za Jadran s dostatnom razlučivosti. Dobiveni podaci predstavljat će prostorne i vremenske karakteristike pristranosti temperature te će omogućiti procjenu kvalitete kojom RCM-ovi predstavljaju današnju klimu na Jadranu. Da bi se odredilo u kojoj mjeri regionalni klimatski modeli iz baze EURO-CORDEX mogu reprezentirati trendove temperatura u jadranskom području, potrebno je provesti evaluaciju samih RCM-ova s obzirom na mjerenja.

Također, važno je i istražiti prikazuju li rezultati modela fenomene, kao što su toplinski valovi u Jadranu, unutar globalnih klimatskih promjena.

Glavna hipoteza ovog rada je da su regionalni efekti dominantni u odnosu na utjecaj globalnog zatopljenja. Cilj istraživanja je objasniti uzroke ponašanja klimatskih trendova temperature zraka i mora u jadranskom području s posebnom pažnjom usmjerenom na:

i. Globalne klimatske promjene gdje je važno analizirati i evaluirati trendove temperature zraka i mora korištenjem podataka mjernih postaja na obali, u zaleđu, i na otocima, satelitskih podataka te rezultata regionalnih klimatskih modela.
ii. Utjecaj međudjelovanja Jadranskog i Sredozemnog mora kroz Otrantska vrata. Uočena sezonska promjenjivost ukazuje na potrebu proučavanja sezonskih utjecaja.
iii. Analizu fenomena morskih toplinskih valova u Jadranu uz istraživanje utjecaja globalnih klimatskih promjena na klimu Jadrana.

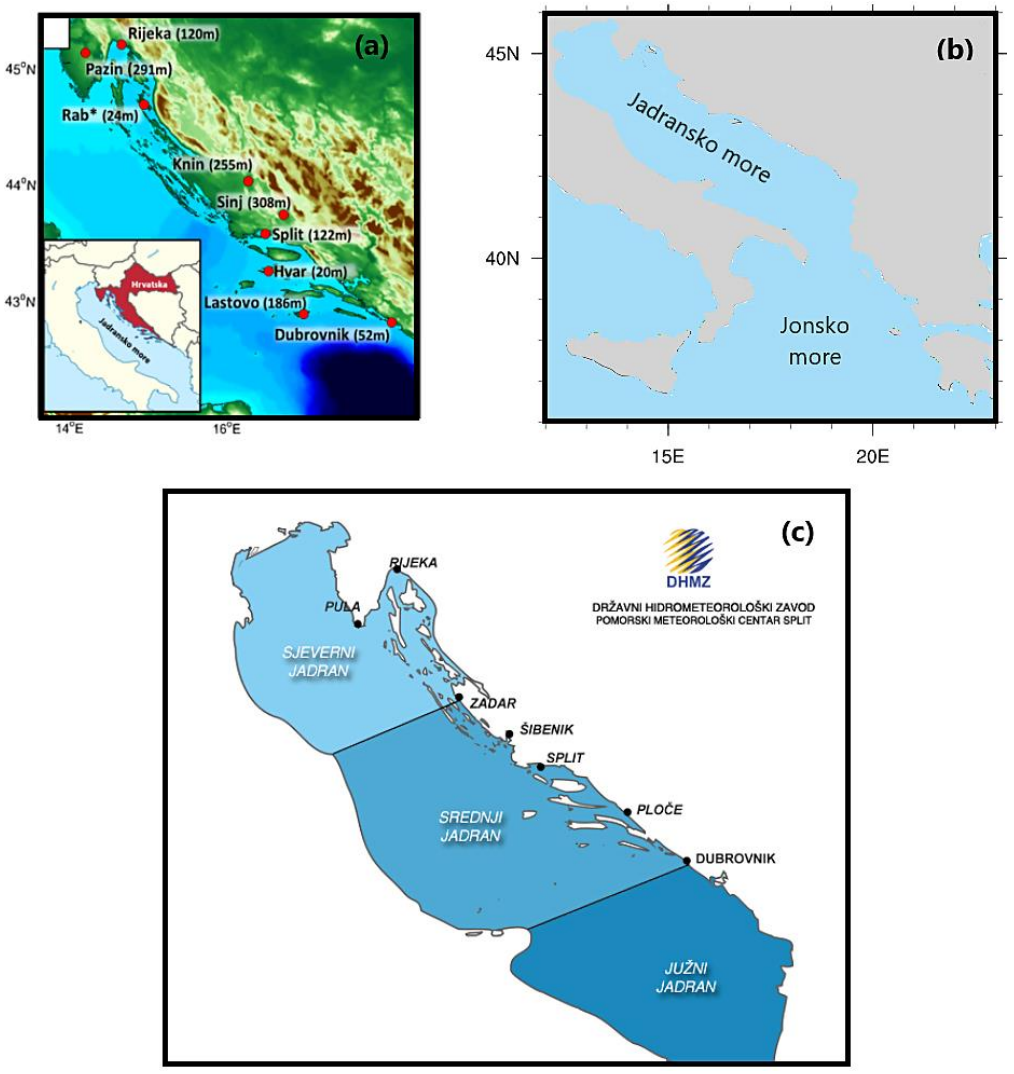
Ovo istraživanje doprinijet će znanju trendova temperatura zraka i mora na jadranskom području.

2. PODACI

2.1 Prizemna mjerenja temperature zraka

U ovom su radu korištena prizemna mjerenja temperature zraka na području Republike Hrvatske, a sastoje se od dnevnih srednjaka temperatura zraka na visini od 2 m (T2m) iz arhive Državnog hidrometeorološkog zavoda (DHMZ). Meteorološki podaci s mreže postaja DHMZ-a dobivaju se svakodnevnim mjerenjima i opažanjima (motrenjima) diljem Hrvatske. Podaci opisuju stanje vremena na položaju meteorološke postaje. Postoje različite prizemne meteorološke postaje na području Republike Hrvatske, a koje pripadaju sustavu postaja DHMZ-a. Takav sustav obuhvaća glavne, automatske, klimatološke i kišomjerne postaje koje mjere temperaturu zraka, mora i oborine te fenološke postaje na kojima se motre vegetativne faze razvoja bilja (cvjetanje, dozrijevanja plodova, jesenje opadanje lišća, zimsko mirovanje).

Na klimatološkim meteorološkim postajama se motrenja obavljaju u 7 h, 14 h i 21 h po lokalnom vremenu. Iz tih podataka su računati dnevni srednjaci za svaki dan u razdoblju od 1961. do 2008. godine. Za klimatološke postaje od interesa u ovoj studiji provjereno je i potvrđeno da svaka postaja sadrži više od 70% podataka iz kojih se mogu izračunati dnevni srednjaci. Pokazano je da male promjene u navedenom kriteriju nisu utjecale na strukturu krajnje izdvojenih postaja. Na kraju je odabrano 9 postaja na istočno-jadranskoj obali koje ispunjavaju navedeni kriterij, a ujedno i zbog toga jer su Kotroni i sur. (2008) argumentirali da se lokalna (točkasta) mjerenja mogu koristiti za prikaz lokalne klime.



Slika 2. (a) Prostorna raspodjela odabranih klimatoloških mjernih postaja duž istočno-jadranske obale. U zagradama se nalazi nadmorska visina pojedine postaje. (b) Prikaz podjele na Jadransko i Jonsko more. (c) DHMZ raspodjela Jadrana na sjeverni, srednji i južni (izvor: www.meteo.hr).

Postaje s Köppenovom klimatskom klasifikacijom odabrane su duž istočno-jadranske obale (sl. 2) tako da uključuju (a) otoke (Lastovo, Hvar i Rab), (b) obalna područja (Rijeka, Split i Dubrovnik) sa sredozemnom klimom s blagim zimama i vrućim ljetima te (c) kopnena područja (Knin i Sinj) sa sredozemnom klimom pod kontinentalnim utjecajem (hladnija zime i vruća ljeta). Uz ove, korišteni su i podaci s postaje smještene u zaleđu Istre (Pazin) koja ima specifična lokalna klimatološka obilježja na sjevernom Jadranu uzrokovana složenom topografijom i blizinom mora.

2.2 Satelitska mjerenja površinske temperature mora (C3S-L4)

Mjerenja površinske temperature mora su uključena u analizu. Površinska temperatura mora je važan pokretač vremenskih i klimatskih obrazaca te igra važnu ulogu u razmjeni energije između oceana i atmosfere. Shodno tome poznavanje SST-a je neophodno za razumijevanje i procjenu promjenjivosti i dugoročnih promjena u Zemljinoj klimi. Podaci su prikupljeni preko servisa *Copernicus Climate Change* (C3S) (https://cds.climate.copernicus.eu/).

Podaci su dnevne procjene globalne temperature površine mora (SST) na temelju mjerenja različitim satelitskim senzorima od 1981. godine do danas. Ovi podaci su četvrte razine (L4) na horizontalnoj mreži razlučivosti 0,05°. Četvrta razina omogućuje spajanje podataka sa svih prijašnjih razina i svih dostupnih senzora, čime se dobiva potpuno polje dnevnih SST srednjaka na dubini od 20 cm. Metoda kojom se spajaju podaci se naziva varijacijska shema asimilacije podataka (Merchant i sur. 2014). Sami podaci su izvedeni iz satelitskih mjerenja toplinskog zračenja. Mjerenja toplinskog infracrvenog zračenja su prikupljena pomoću dvije serije satelitskih senzora koji orbitiraju oko Zemlje: 11 naprednih radiometara vrlo visoke rezolucije (AVHRR) i 3 radiometra za skeniranje uzduž putanje samog satelita (ATSR). Kontrola kvalitete podataka je provedena unutar samog projekta.

Slijedom hipoteze da su morski toplinski valovi (MHW) obično ograničeni na morsku površinu (Darmaraki i sur. 2019a, 2019b, 2019c), možemo smatrati da podaci SST-a na dubini prvog sloja predstavljaju površinske temperature relevantne za istraživanje MHW-a. Međutim, pod određenim uvjetima MHW-i mogu prodrijeti u veće dubine, ali u ovom se trenutku može pretpostaviti da je SST pouzdan izvor za detekciju i analizu MHW-a. To omogućuje upotrebu

satelitskih podataka o SST-u na nižim prostornim i dovoljnim vremenskim rezolucijama, a osobito ljeti kada je sloj miješanja mora plitak.

2.3 Produkt E-OBS

Za procjenu kvalitete rezultata osam regionalnih modela duž hrvatskog obalnog područja u ovom su se istraživanju koristili podaci T2m preuzeti iz E-OBS verzije v18.0e [*European gridded OBServational* mrežasti skup podataka s razlučivošću 0,1° (Haylock i sur. 2008; Cornes i sur. 2018); izrađene od strane nizozemskog Kraljevskog meteorološkog instituta]. Treba napomenuti da su rezultati E-OBS-a podaci koji tvore objektivno interpoliranu mrežu samo za kopno i koriste mjerenja za dobivanje prostornih polja podataka. U našem slučaju je važno kopno koje pokriva istočnu obalu Jadranskog mora.

Kako su trendovi presudni u studijama o klimatskim promjenama, ovo je istraživanje bitno s aspekta utvrđivanja u kojoj mjeri reanalize i RCM-i realno prikazuju opažene trendove površinske temperature zraka duž hrvatske obale. Na istočnoj obali Jadrana, skup podataka E-OBS uključuje 11 mjernih postaja, uključujući šest koje su korištene u ovom istraživanju (Rijeka, Knin, Split, Hvar, Lastovo i Dubrovnik). Srednja vrijednost i raspon (razlika između 5. i 95. percentila) T2m dobivene su iz E-OBS za razdoblje od 1961. do 2008. godine.

2.4 Reanalize UERRA

Uspješnost RCM-a u prikazu varijabilnosti T2m duž hrvatske obale je procijenjena usporedno s tri različita tipa reanaliza i osam različitih RCM-a. U sklopu projekta UERRA, reanalize visoke razlučivosti dostupne su za Europu i korištene su u ovoj studiji: (a) reanaliza HARMONIE razlučivosti 11 km koju je objavio SMHI; (b) reanaliza MESCAN-SURFEX razlučivosti od 5,5 km iz modela koji je proizveo Météo-France; i (c) reanaliza objedinjenog modela razlučivosti 12 km (UM) Met Officea iz Ujedinjenog Kraljevstva.

HARMONIE je sustav za numeričko predviđanje vremena. Razvijen je u HIRLAM (*Hi-Resolution Limited Area Model*) - konzorciju i nadovezuje se na kod modela ALADIN (*Aire Limitée Adaptation Dynamique Développement International*), AROME (*Applications of Research to Operations at MEsoscale*) i ALARO (kombinirani model ALADIN i AROME) razvijen je u suradnji Météo France i konzorcija ALADIN - HIRLAM. HARMONIE ima rezultate od 1961. do 2015. godine s razlučivošću od 11 km s ALADIN-ovom shemom fizike uključujući i 3D varijacijsku shemu asimilacije. Ta metoda uključuje i asimilaciju podataka iz gornjeg sloja zraka i s površine.

Reanaliza MESCAN-SURFEX se sastoji od dva sustava. Prvi sustav je MESCAN koji je verzija operativne površinske analize (CANARI; Météo-France) za numeričko predviđanje vremena na temelju algoritma optimalne interpolacije. Drugi sustav je SURFEX (Masson i sur. 2013) koji je platforma kopna i oceana koja opisuje površinske procese, izračunava površinske tokove i prijenos topline u tlu. Sustav koristi difuzni pristup za izračun prijenosa topline i vode u snijegu i u tlu preko 14 slojeva. S obzirom da koristi 3D varijacijsku shemu HARMONIE – ALADIN modela, razlučivost mu se poboljšava s 11 km na korak od 5,5 km.

UM je atmosferski numerički model koji se koristi kao prognostički i klimatološki model. Model koristi dinamičku jezgru nehidrostatičke jednadžbe gibanja s polu-lagrangovskom advekcijom i vremenskim korakom. Procesi unutar mreže modela, poput konvekcije, turbulencije graničnog sloja, zračenja, oblaka, mikrofizike i orografskog otpora predstavljeni su parametrizacijama. Model koristi točkastu diskretizaciju mreže koristeći sustav zemljopisne širine i dužine sa zarotiranim polom.

Mjerenja koja su korištena kod asimilacije podataka reanaliza UERRA su geopotencijalna visina kod sinoptičkih postaja (SYNOP postaje koje uključuju i mjerne postaje korištene u ovom radu), brodskih mjerenja i plutača. Vjetar i temperatura se preuzimaju iz zrakoplovnih mjerenja i radiosondaža. Daljinska mjerenja nisu korištena kod ovih podataka.

Pri korištenju rezultata ovih reanaliza njihova razlučivost je smanjena (da bi se postigao korak razlučivosti RCM-a od 12,5 km) zbog objektivne usporedbe reanaliza UERRA i rezultata RCM-ova na području Jadrana.

2.5 Reanaliza ERA5

ERA5 je izvedena pomoću asimilacije podataka metodom 4D-Var unutar modela IFS (*Integrated Forecast System*) na ECMWF-u. Vremensko razdoblje koje pokriva je od 1950. godine do danas. Atmosferski podaci su dostupni za 137 sigma vertikalnih razina s vrhom na 0,01 hPa. Također, postoje podaci interpolirani na 37 razina tlaka zraka, 16 razina potencijalne temperature i jednom nivou potencijalne vrtložnosti. Podaci površinske razine su dostupni za parametre kao što je oborina, T2m i atmosfersko zračenje. Model IFS je povezan s modelom tla i valnim modelom oceana. Reanaliza ERA5 ima veću razlučivost i kvalitetu rezultata u odnosu na stariju verziju ERA-Interim. Osim što ima dvostruko više prostornih koraka, pokazuje i bolje rezultate u usporedbi s mjerenjima (Hersbach i sur. 2020).

Za usporedbu rezultata RCM-a s globalnom reanalizom ERA5 korišteni su satni podaci koji usrednjeni u dnevne srednjake. Prostorni korak iznosi 0,28°.

2.6 Regionalni klimatski modeli

Osam EURO-CORDEX (Giorgi i sur. 2009; Jacob i sur. 2014; Kotlarski i sur. 2014) RCM-a je korišteno za analizu povijesnih i evaluacijskih simulacija (tablica 1). Povijesne simulacije koriste lateralne rubne i početne uvjete iz globalnih klimatskih modela (GCM), razlučivosti između 0,8° i 2°, dok evaluacijske simulacije koriste reanalizu ERA-Interim za početne i rubne uvjete s obzirom da njene podatke možemo smatrati kvalitetnima za analizu područja u umjerenim zemljopisnim širinama (Brands i sur. 2013). ERA-Interim ima razlučivost 0,75°. Svi RCM-ovi izuzev CCLM4 modela su hidrostatski. Za dodatnu analizu napravljen je i korišten ansambl od osam RMC-ova kao srednjak svih osam modela. Ansambl je sastavljen od modela čiji su rezultati bili dostupni u trenutku izrade ove analize.

S obzirom da početak vremenskih nizova rezultata modela u povijesnim simulacijama može varirati od 50-ih do 70-ih godina prošlog stoljeća, odabrani su oni modeli koji imaju dostupne rezultate simulacija za razdoblje od 1961. do 2005. godine kako bi se obuhvatilo što dulje vremensko razdoblje. Evaluacijske simulacije također imaju različito trajanje kod pojedinih modela (između 20 i 30 godina) pa su odabrani modeli s rezultatima za razdoblje od 1989. do 2008.

godine. Povijesne simulacije korištene u ovoj studiji obuhvaćaju rezultate šest od navedenih osam RCM-ova zbog toga što dva modela imaju samo rezultate od 1971. godine. Zbog toga se RCA4 i RegCM4 koriste samo u analizi evaluacijskih simulacija. Prostorni korak obje vrste simulacija iznosi 0,11° što iznosi približno 12,5 km, što je jako dobro s obzirom na duljinu istočne jadranske obale (otprilike 1800 km). Sve simulacije obuhvaćaju mjerne postaje koje pokrivaju cijelo područje Jadranskog mora (sl. 2).

Iz EURO-CORDEX simulacija su preuzeti podaci o T2m. Također, svi preuzeti podatci su dnevni srednjaci. Obje vrste simulacija ne uvažavaju međudjelovanje između atmosfere i mora te imaju samo atmosfersku komponentu (imaju donji rubni uvjet kod SST te postoji jednosmjerni protok informacije more-atmosfera). Nazivi simulacija su određeni imenom GCM-a zajedno s imenom RCM-a i to kod povijesnih simulacija da bi se razlikovao utjecaj pojedinog globalnog modela. Kod evaluacijskih simulacija naziv će se odrediti imenom pojedinog RCM-a s obzirom da svi modeli početne i rubne uvjete dobivaju iz reanalize ERA-Interim.

Tablica 1. Popis analiziranih simulacija i njima pripadajućih parametrizacija. Ukoliko se radi o povijesnim simulacijama, navedeni su i pripadajući globalni modeli iz kojih proizlaze rubni i početni uvjeti. Sve EURO-CORDEX simulacije su dostupne s prostornim korakom mreže od 0,11°. Parametrizacije su navedene s desna na lijevo: Procesi u tlu (PK), radijacija (Rad.), konvekcija (Konv.), mikro-fizika (MF) i granični sloj (GS).

* koriste se samo evaluacijske simulacije

RCM	GCM	PK	Rad.	Konv.	MF	GS
CCLM4[a]	CNRM-CM5, MPI-ESM-LR	Doms i sur. (2011)	Ritter i Geleyn (1992)	Tiedtke (1989)	Doms i sur. (2011), Baldauf i Schulz (2004)	Louis (1979)
ALADIN53[b]	CNRM-CM5	Colin i sur. (2010)	Colin i sur. (2010)	Colin i sur. (2010)	Colin i sur. (2010)	Colin i sur. (2010)
RegCM4[c]*	/	Gao i sur. (2016)	Kiehl i sur. (1996)	Grell (1993)	Pal i sur. (2000)	Holtslag i sur. (1990)
HIRHAM5[d]	NCC-NorESM1-M	Roeckner i sur. (1996)	Morcrette i sur. (1986), Giorgetta i Wild (1995)	Tiedtke (1989)	Lohmann i Roeckner (1996)	Louis (1979)
WRF331F[e]	IPSL-CM5A-MR	Ek i sur. (2003)	Iacono i sur. (2008)	Grell i Dévényi (2002)	Hong i sur. (2004)	Hong i sur. (2006)
RACMO22E[f]	ICHEC-EC-EARTH	Van den Hurk i sur. (2000)	Fouquart i Bonnel (1980), Mlawer i sur. (1997)	Tiedtke (1989), Nordeng (1994), Neggers i sur. (2009)	Tiedtke (1993), Neggers i sur. (2009)	Lenderink i Holtslag (2004), Siebesma (2007)
REMO2009[g]	MPI-ESM-LR	Dickinson i sur. (1993)	Morcrette i sur. (1986), Giorgetta i Wild (1995)	Tiedtke (1989), Nordeng (1994), Pfeifer (2006)	Lohmann i Roeckner (1996)	Louis (1979)
RCA4[h]*	/	Samuelsson i sur. (2006)	Savijärvi (1990), Sass i sur. (1994)	Kain i Fritsch (1993)	Rasch i Kristjánsson (1998)	Cuxart i sur. (2000)

[a]Bucchignani i sur. (2015), [b]Colin i sur. (2010), [c]Giorgi i sur. (2012), [d]Lucas-Picher i sur. (2012), [e]Skamarock i sur. (2008), [f]van Meijgaard i sur. (2008), [g]Jacob i Podzun (1997), [h]Kjellström i sur. (2016)

3. METODOLOGIJA

Zbog točnosti same analize regionalnih klimatskih modela i njihove evaluacije, korištena je metoda najbližeg susjeda (eng. „*nearest neighbor"*) da bi se odredila i izdvojila točka unutar mreže pojedinog modela koja je najbliža stvarnom položaju mjerne postaje. Izdvajanje točaka se vrši zadavanjem stvarnih zemljopisnih koordinata mjerne postaje gdje se težina postiže u odnosu na omjer kopna i mora. Takva metoda je vrsta interpolacije točaka mreže modela na stvarne položaje postaja.

Prostorna razlučivost reanaliza UERRA i mreže mjerenja E-OBS je smanjena u odnosu na početne vrijednosti da bi svi podaci imali istu razlučivost RCM-ova (prostorni korak 12,5 km). Ovaj korak prije same evaluacije rezultata daje mogućnost stvaranja dodatne vrijednosti koja može upućivati na bolji prikaz samih fizikalnih procesa unutar pojedinih RCM-ova (Torma i sur. 2015).

3.1 Metrika regionalnih klimatskih modela i statistički parametri

Kod evaluacije regionalnih klimatskih modela, za svaki pojedini set podataka (RCM, reanalize, E-OBS i mjerenja), izračunate su temperaturne anomalije tako što se uklonio godišnji hod iz vremenskog niza rezultata simulacija u povijesnom i evaluacijskom načinu rada. Ansambl EURO-CORDEX je nastao usrednjavanjem temperaturnih anomalija odabranih RCM-ova (osam u evaluacijskom i sedam u povijesnom načinu rada). Pošto rezultati reanalize UM ne uključuju cijelo razdoblje od 1961. do 2005., ta reanaliza nije uključena u statističku analizu povijesnih simulacija. Sve analize su izvršene s dnevnim vrijednostima podataka. Kod analize modela po mjesecima, dnevne vrijednosti su usrednjene u mjesečne. Procjena rezultata evaluacijskih simulacija RCM-ova, ansambla EURO-CORDEX i reanaliza UERRA uključuje i sve 4 godišnje sezone. Zimska sezona (*DJF*) uključuje mjesece prosinac, siječanj i veljaču, proljetna sezona (*MAM*) mjesece ožujak, travanj i svibanj, ljetna sezona (*JJA*) lipanj, srpanj i kolovoz dok jesenska sezona (*SON*) uključuje mjesece rujan, listopad i studeni. Sezonski podaci se računaju usrednjavanjem dnevnih podataka navedenih tromjesečja (DJF, MAM, JJA i SON).

Analiza pristranosti svih RCM-ova usporedno s produktom E-OBS je pokazala da je kod svih modela korekcija pristranosti slično izvedena izuzev REMO2009 modela koji je pokazao povećanu pristranost na području Jadrana.

Kvaliteta T2m trendova modela i reanaliza je proučena korijenom srednje kvadratne pogreške (*RMSE ili RMSD*):

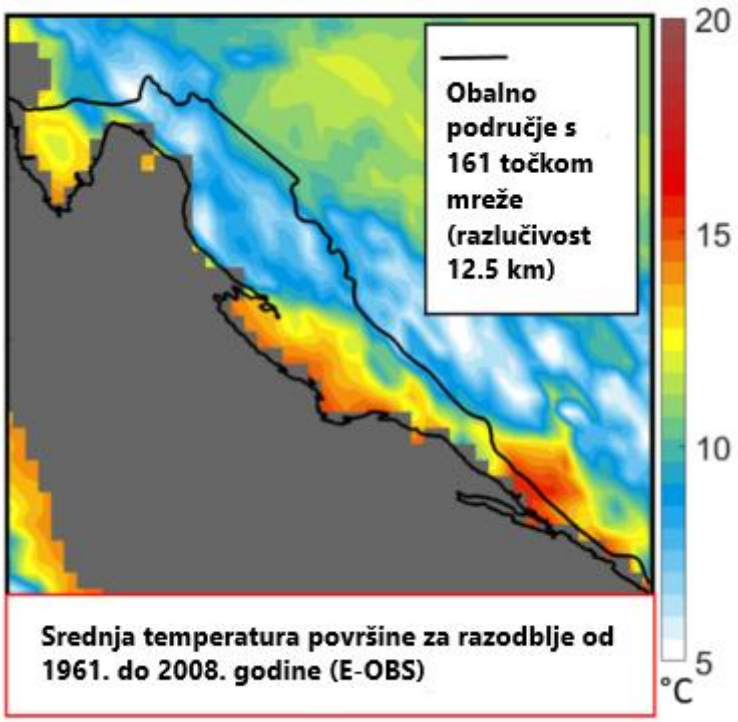
$$RMSE/RMSD = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(M_i - O_i)^2}, \qquad (1)$$

gdje su $\{M_i\}_{i=1}^{N}$ i $\{O_i\}_{i=1}^{N}$ ansambli od *N* vrijednosti dobivenih iz atmosferskih modela i mjerenja. Razlike između trendova izračunate su kroz razliku koeficijenata $\alpha_M - \alpha_O$ unutar kojih su linearni trendovi RCM-ova, reanaliza, E-OBS i mjerenja određeni u svakoj točki kao:

$$T_M(t) = \alpha_M t + \beta_M \; ; T_O(t) = \alpha_O t + \beta_O, \qquad (2)$$

gdje su α_M i α_O koeficijenti trendova modela i mjerenja.

Izračunat je i srednjak korijena srednje kvadratne pogreške usporedno sa srednjom apsolutnom razlikom koeficijenata trendova što je omogućilo rangiranje modela (*i*) na položajima devet postaja (sl. 2a) i (*ii*) kroz sve točke mreže modela (161 točka) koje se nalaze na jadranskoj obali (sl. 3). Dodatno, regionalni modeli, reanalize i EURO-CORDEX ansambl su rangirani preko korijena srednje kvadratne pogreške usporedno s koeficijentom korelacije (sl. 9). Informacija o uspješnosti rezultata evaluacijskih simulacija je prikazana pomoću statističkih parametara korijena srednje kvadratne pogreške/razlike, standardne devijacije i koeficijenta korelacije unutar Taylorovog dijagrama (Taylor 2001). Za usporedbu trendova površinskih temperatura mora korišten je Pearsonov koeficijent korelacije „R“ (sl. 22; Pearson 1895).



Slika 3. Obalno područje omeđeno sa 161 točkom mreže modela čija je razlučivost smanjena na razlučivost EURO-CORDEX RCM-ova. Paleta boja prikazuje srednju površinsku temperaturu u mreži mjerenja E-OBS za razdoblje 1961. - 2008.

Analiza rezultata RCM-ova provedena je za dvije vrste simulacija:

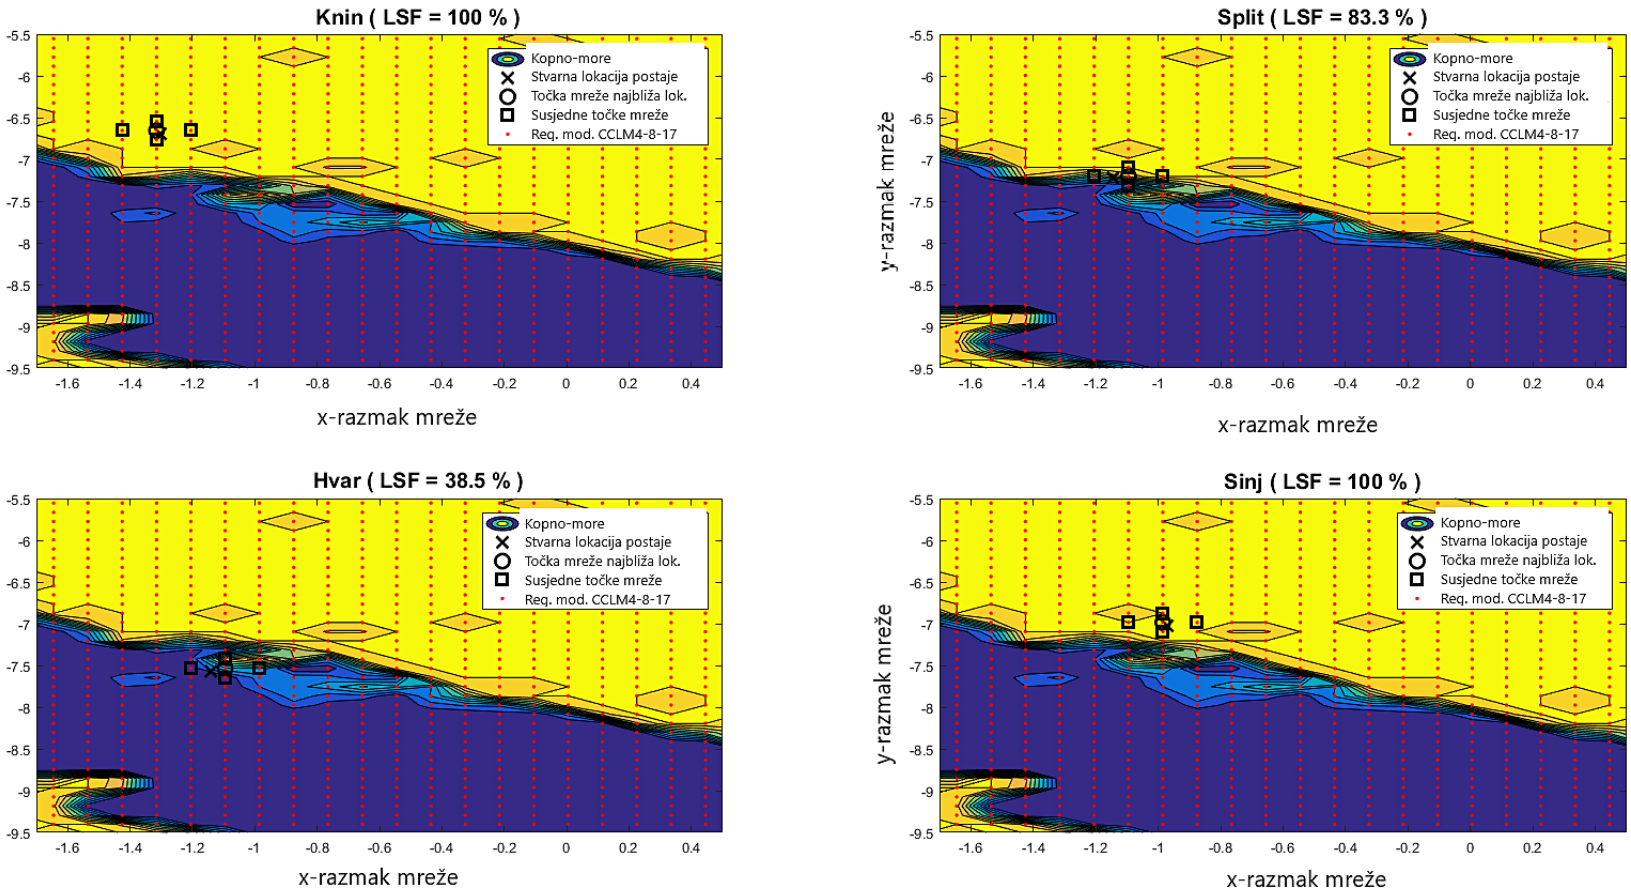
a) Povijesne simulacije – urađene za razdoblje od 1961. do 2005. godine gdje regionalni modeli uzimaju početne i rubne uvjete iz globalnih modela. Postoje rezultati od 1950-ih godina, ali su zbog konzistentnosti vremenske skale odabrani samo modeli s jednakim brojem rezultata i jednakim vremenskim razdobljem.
b) Evaluacijske simulacije – urađene za razdoblje od 1989. do 2008. godine gdje regionalni modeli uzimaju početne i rubne uvjete iz reanaliza (ERA-Interim).

Istraživanje je uključivalo usporedbe rezultata povijesnih i evaluacijskih simulacija te različitih vrsta reanaliza i regionalnih klimatskih modela. Analize su se vršile lokalno (uspoređujući mjerenja s postaja i rezultat iz točke mreže modela najbližoj tom položaju; primjeri slike 4 i 5) i prostorno (sve kopnene točke iz mreže modela koje pripadaju jadranskoj regiji).

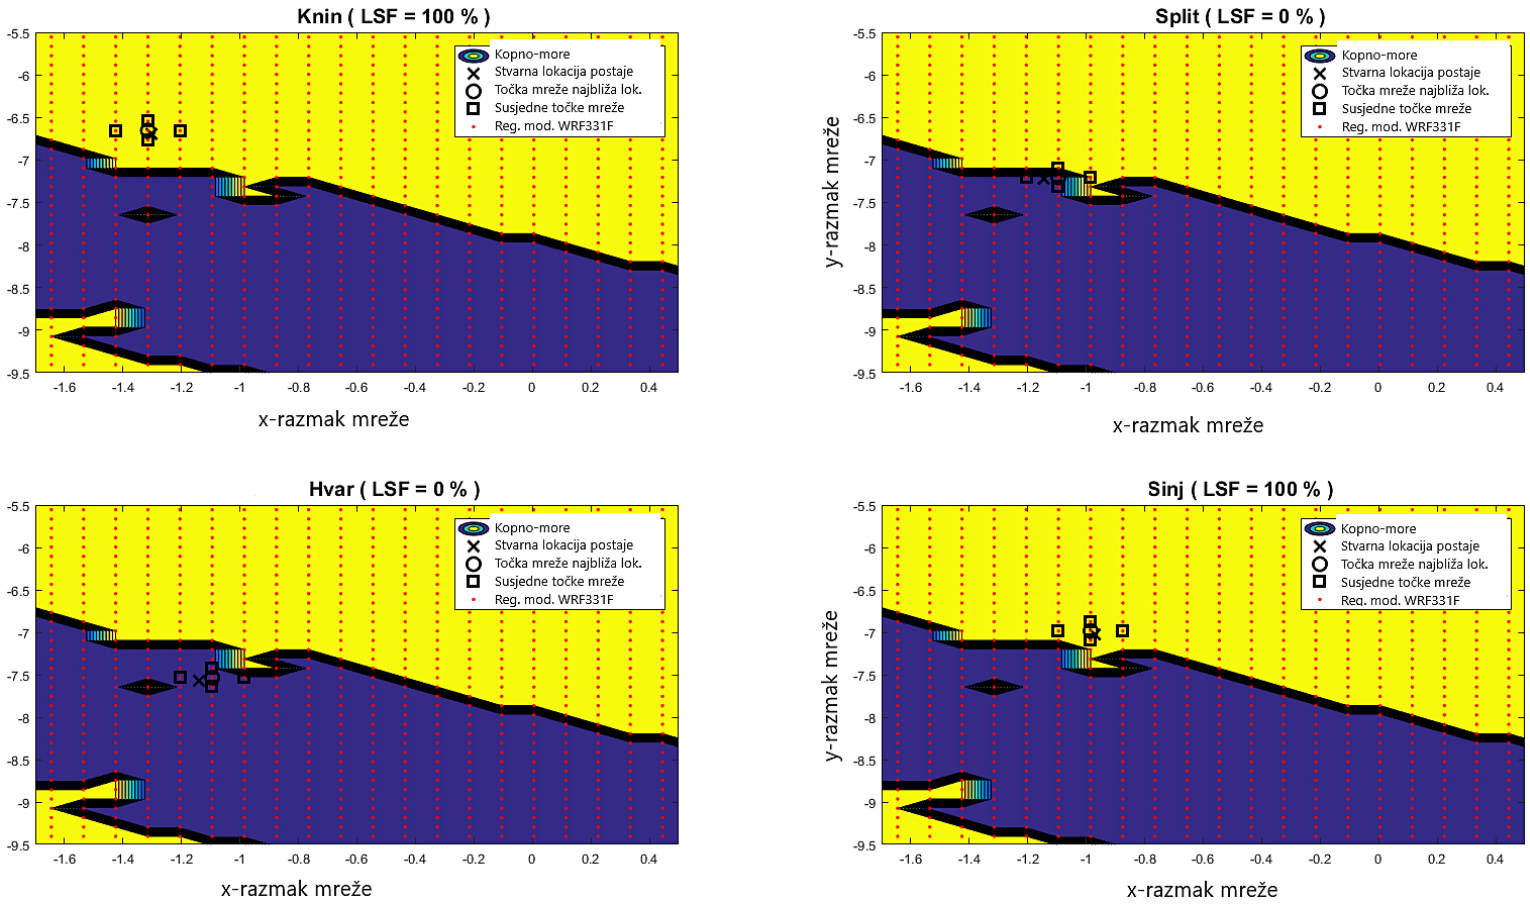
Orografija, koja je različito prikazana u RCM-ima, može uzrokovati pristranost modela u usporedbi s mjerenjima (Heikkilä i sur. 2011). Uzimajući u obzir moguće razlike između

nadmorske visine i odgovarajuće visine mreže modela, jedna od mogućnosti je ispravljanje rezultata temperature unutar modela smanjenjem vrijednosti od 0,65 °C svakih 100 m. Drugi razlog za pojavu pristranosti modela je omjer kopna i mora (eng. *„land-sea fraction; LSF"*) koji određuje koje će se parametrizacije (na moru ili na kopnu) koristiti za računanje vrijednosti temperature u pojedinoj ćeliji mreže modela.

U svim regionalnim modelima omjer kopna i mora je između 0 i 100%, osim u modelu WRF331F gdje može biti samo 0 ili 100% (sl. 5). To je važno jer, osim tri kopnene postaje u modelu WRF331F (sl. 2), sve ostale obalne i otočne postaje imaju omjer kopna i mora nula, što znači da su te postaje predstavljene kao morske ćelije u mreži regionalnog modela. Omjer kopna i mora kod modela i reanaliza se podudara samo za postaje u unutrašnjosti kopna, dok su izraženije razlike za otočne postaje. Najveća razlika u omjeru kopna i mora je na položaju postaje Lastovo gdje svi RCM-ovi imaju omjer kopna i mora manji od 12% dok je stvarni položaj mjerne postaje na kopnu. Regionalni modeli na položajima postaja Dubrovnik, Hvar, Split, Rab imaju omjer kopna i mora manji ili jednak 50%.



Slika 4. Prikaz NN-metode („nearest neighbor“) kod CCLM4-8-17 regionalnog modela za četiri lokacije postaja (Knin, Sinj – kopno, Split – priobalje, Hvar – more). Kružić označava odabranu točku iz modela koja je najbliža stvarnoj lokaciji postaje (križić). Kvadrati označavaju četiri točke mreže modela koje su najbliže odabranoj točki. Crvenom bojom je označena mreža modela.



Slika 5. Prikaz NN-metode („nearest neighbor“) kod WRF331F regionalnog modela za četiri lokacije postaja (Knin, Sinj – kopno, Split – priobalje, Hvar – more). Kružić označava odabranu točku iz modela koja je najbliža stvarnoj lokaciji postaje (križić). Kvadrati označavaju četiri točke mreže modela koje su najbliže odabranoj točki. Crvenom bojom je označena mreža modela.

3.2 Identifikacija toplinskih valova u Jadranu

U ovome istraživanju, toplinski valovi u Jadranu su proučavani kroz površinska svojstva mora kao što je površinska temperatura (SST) i njeni trendovi. Pokazano je da površinska temperatura mora, kao jedna od najbitnijih varijabli, u sebi sadrži informacije koje su bitne u istraživanju toplinskih valova u moru (Hobday i sur. 2016; Darmaraki 2019c). Korištenje ove informacije nam omogućuju satelitski podaci koji imaju visoku prostornu i vremensku razlučivost.

S obzirom da je sloj miješanja u moru jako mali u ljetnim sezonama, površinska temperatura mora je dovoljna za proučavanje i identifikaciju toplinskih valova u moru. Pošto na istočnoj obali Jadrana ne postoji gusta mreža *in-situ* mjerenja, satelitski podaci omogućuju prostorno-vremensko uzorkovanje. Satelitski podaci imaju razlučivost 0,05° i vremenski korak od jednog dana (Merchant i sur. 2019) te su uspoređeni s rezultatima reanalize ERA5. Dodatne varijable iz reanalize ERA5 korištene u analizi površinske temperature mora su: T2m, površinski tok latentne topline (SLHF), površinski tok osjetne topline (SSHF), ukupna naoblaka (TCC), U i V komponente vjetra na 10 metara nadmorske visine. Pošto su podaci ERA5 satne vrijednosti, sve varijable su dnevno usrednjene unutar same analize.

U- i V-komponente vjetra su korištene za izračun napetosti vjetra (eng. „*wind stress*“; τ). Izmjena momenta između kopna i zraka se ne može mjeriti izravno pa se zbog toga koristi empirijska formula koju je dao Taylor (1916):

$$\tau = \rho \cdot C_Z \cdot W_{SZ}^2, \qquad (3)$$

gdje je ρ gustoća zraka (1,22 kg·m^3), C_Z je bezdimenzionalan koeficijent trenja pri visini od Z=10 metara i W_{SZ} je prosječna brzina vjetra izračunata iz U- i V-komponenata vjetra. Vrijednost koeficijenta trenja je izračunata za neutralno stabilnu atmosferu prema Yellandu i Tayloru (1996) zbog toga što su Wróbel-Niedźwiecka i sur. (2019) pokazali da takav način parametrizacije rezultira srednjom vrijednosti toka topline koja je najbliža prosječnoj vrijednosti toka topline iznad tropskog oceana (slične uvjete nalazimo i na Sredozemlju pa shodno tome i na Jadranu) uspoređujući s ostalim vrstama parametrizacije napetosti vjetra.

Parametrizacija koeficijenta trenja C_Z:

$$1000 \cdot C_{10m} = 0{,}29 + \frac{3.1}{U_{10m}} + \frac{7{,}7}{U_{10m}^2}, \quad \left(3\ \frac{m}{s} \leq U_{10m} \leq 6\ \frac{m}{s}\right), \tag{4}$$

$$1000 \cdot C_{10m} = 0{,}6 + 0{,}07 \cdot U_{10m}, \quad \left(6\ \frac{m}{s} \leq U_{10m} \leq 26\ \frac{m}{s}\right), \tag{5}$$

Ova parametrizacija se temelji na pretpostavci da veličina neravnoteže između proizvodnje i gubitka turbulentne kinetičke energije ovisi o stabilnosti atmosfere i brzini vjetra.

Identifikacija samih epizoda toplinskih valova na površini Jadranskog mora je izvedena za ljetne sezone koje obuhvaćaju mjesece lipanj, srpanj, kolovoz i rujan. Iako se toplinski valovi u moru mogu javljati i u zimskim mjesecima, njihov je najveći utjecaj u ljetnim sezonama (Darmaraki 2019c). Proširenje ljetne sezone na 4 mjeseca (u odnosu na standardna 3 mjeseca: lipanj, srpanj i kolovoz) je odabrano jer su dosadašnja istraživanja pokazala da zonalni gradijent temperature mora pokazuje fazni pomak (kašnjenje) od sjevera prema jugu Sredozemlja pa zbog toga utjecaj ljetnih sezona može doći i ranije ili se produljiti i na mjesec rujan (Shaltout i Omstedt 2014).

Toplinski val na morskoj površini je fenomen dugotrajne izrazito visoke temperature mora na određenom području u usporedbi s klimatološkom temperaturom mora za tridesetogodišnje razdoblje (Hobday i sur. 2016; Darmaraki i sur 2019a, 2019b, 2019c). Kod ovog istraživanja je razdoblje od 1982. godine do 2012. godine uzeto kao referentno te predstavlja srednje stanje regionalne klime za Jadran s konca dvadesetog i početka dvadesetprvog stoljeća. Postupak identifikacije i analize epizoda toplinskih valova u Jadranu je sljedeći: *(i)* za svaku godinu referentnog razdoblje je izračunat 99. percentil dnevnih vrijednosti površinske temperature mora *(ii)* prostorno je izračunato za svaku točku mreže modela *(iii)* tako izračunate ekstremne vrijednosti su se usrednjile za razdoblje od 30 godina te su se dobile 2D mape koje predstavljaju temperaturni prag za toplinski val. Uspoređujući dnevne vrijednosti površinske temperature mora s 2D mapama temperaturnog praga 99. percentila možemo identificirati samu epizodu toplinskog vala na morskoj površini s vrijednostima iznad temperaturnog praga u trajanju duljem od 5 dana.

Opis pojedine epizode je izvršen preko svojstava toplinskih valova kao što je frekvencija (broj pojavljivanja), trajanje i intezitet (srednje odstupanje od temperaturnog praga 99. percentila površinske temperature mora). Korelacije između temperature zraka na 2 metra (T2m),

površinskih tokova topline, ukupne naoblake, vjetra i 99. percentila površinske temperature mora (SST) su izračunate da bi se istražile moguće poveznice između lokalnih i regionalnih fizičkih procesa i ekstremnih epizoda toplinskih valova u Jadranu.

Kod analize trendova površinske temperature mora koristili smo raspodjelu Jadrana po regijama (sjeverni, srednji i južni) kako koristi Državni hidrometeorološki zavod u Zagrebu za operativne potrebe pomorskih prognoza (sl. 2c). Također za usporedbu s povšinskom temperaturom Jadrana korišteni su i podaci površinske temperature Jonskog mora (sl. 2b).

4. REZULTATI I DISKUSIJA

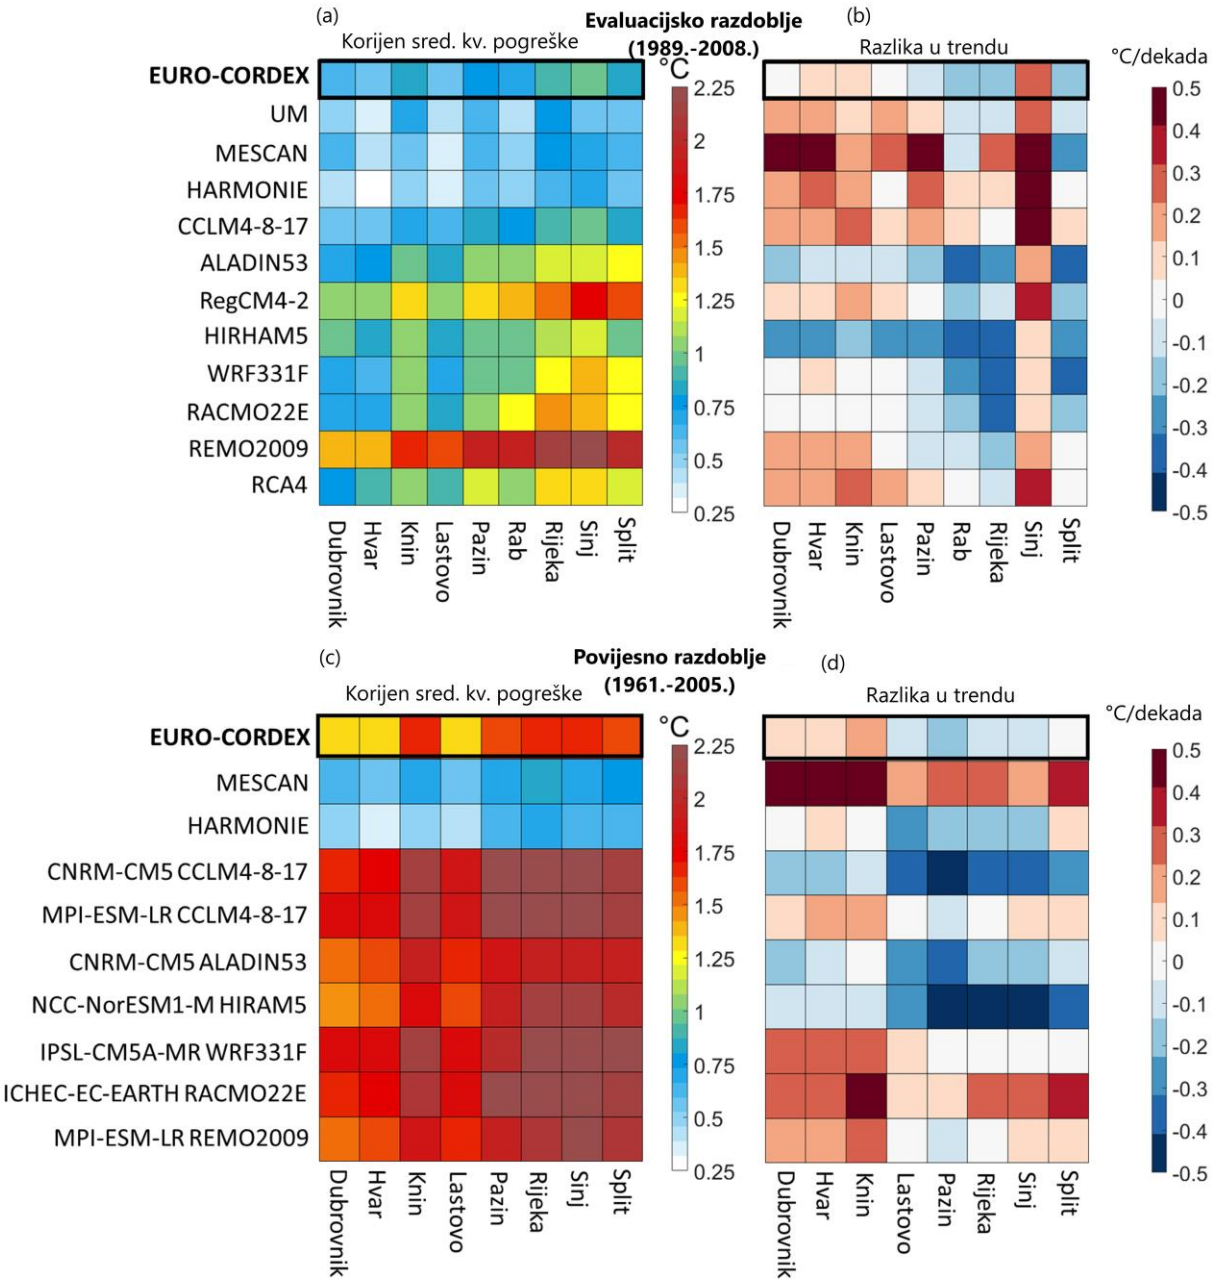
4.1 Temperatura zraka na 2m (T2m)

4.1.1 Lokalna sezonska obilježja i trendovi

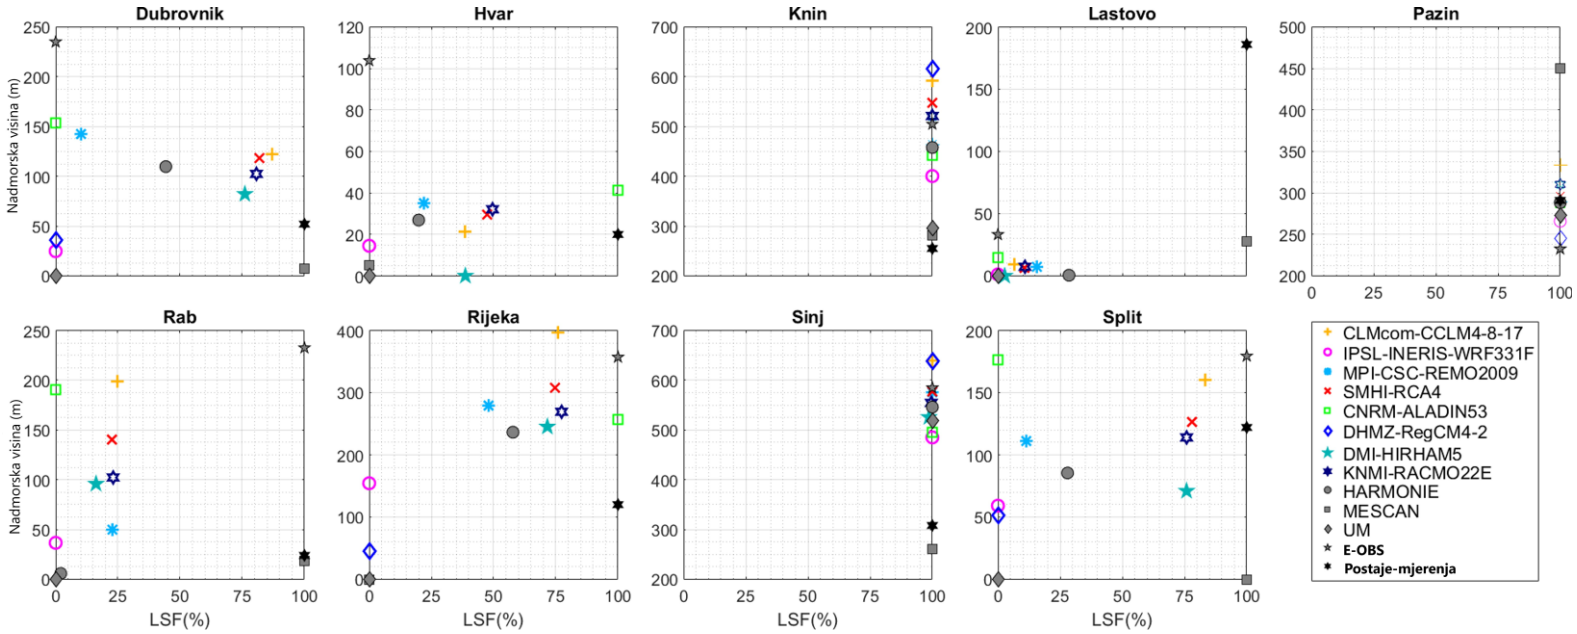
Rezultati analize korijena srednje kvadratne pogreške (RMSE) uvelike se razlikuju kod rezultata modela u povijesnim i evaluacijskim simulacijama. EURO-CORDEX regionalni klimatski modeli bolje predstavljaju temperaturnu promjenjivost kod rezultata evaluacijskih simulacija gdje se vrijednosti kreću od 0,5 °C do 1,5 °C (sl. 6). Ovakvi rezultati su posljedica toga što su evaluacijske simulacije uvjetovane reanalizom (koja asimilira podatke) pa je njihova promjenjivost manja od one za povijesne simulacije. Promjenjivost temperature dobivene povijesnim simulacijama je veća (korijen srednje kvadratne pogreške je u rasponu od 1,75 °C do 2,25 °C) jer različiti globalni modeli utječu na veću raspršenost rezultata u odnosu na mjerenja. Možemo naglasiti da jedino model REMO2009 pokazuje veću promjenjivost (> 1,3 °C) i kod rezultata evaluacijske simulacije (također i na svim postajama duž jadranske obale). Mogući razlog za takvo ponašanje rezultata ovog modela je povećana pristranost u rezultatima na jadranskim područjem (sl. 6.).

Ansambl EURO-CORDEX daje rezultate evaluacijskih simulacija koji pokazuju manju promjenjivost (0,6 – 0,8 °C) u odnosu na pojedini RCM, dok je kod povijesnih simulacija promjenjivost nešto viša (> 1,25 °C). Ovakav rezultat ukazuje na poboljšanje rezultata samih RCM-ova kada se uzimaju u obliku ansambla. Reanalize UERRA pokazuju podjednaku promjenjivost bez obzira na razdoblje i njegovu duljinu. Promjenjivost u oba razdoblja (povijesno i evaluacijsko) je između 0,25 °C i 0,8 °C (sl. 6). Manja promjenjivost je prisutna posebno na južnojadranskim postajama Hvar, Lastovo i Dubrovnik.

Sjeverno-jadranske postaje pokazuju promjenjivost veću od 1 °C za razliku od srednje i južno-jadranskih postaja kao što su Hvar, Lastovo i Dubrovnik. To ukazuje na kompleksnost topografije i terena na sjevernom Jadranu koja je uvjetovana višim razlikama između nadmorske visine položaja postaja i omjera kopno-more (sl. 7).



Slika 6. Rezultati regionalnih klimatskih modela za temperaturu na 2 metra nadmorske visine (T2m). Grafikoni (a) i (c) pokazuju korijen srednje kvadratne pogreške dok (b) i (d) pokazuju razlike u trendovima između rezultata modela i mjerenja. Gornji red pokazuje analizu rezultata evaluacijskih simulacija dok donji red pokazuje analizu povijesnih simulacija



Slika 7. Nadmorska visina (u metrima) i omjer kopna i mora (LSF; %) unutar ćelije modela gdje se nalazi položaj mjerne postaje. Stvarna nadmorska visina svake od mjernih postaja se nalazi na slici za usporedbu.

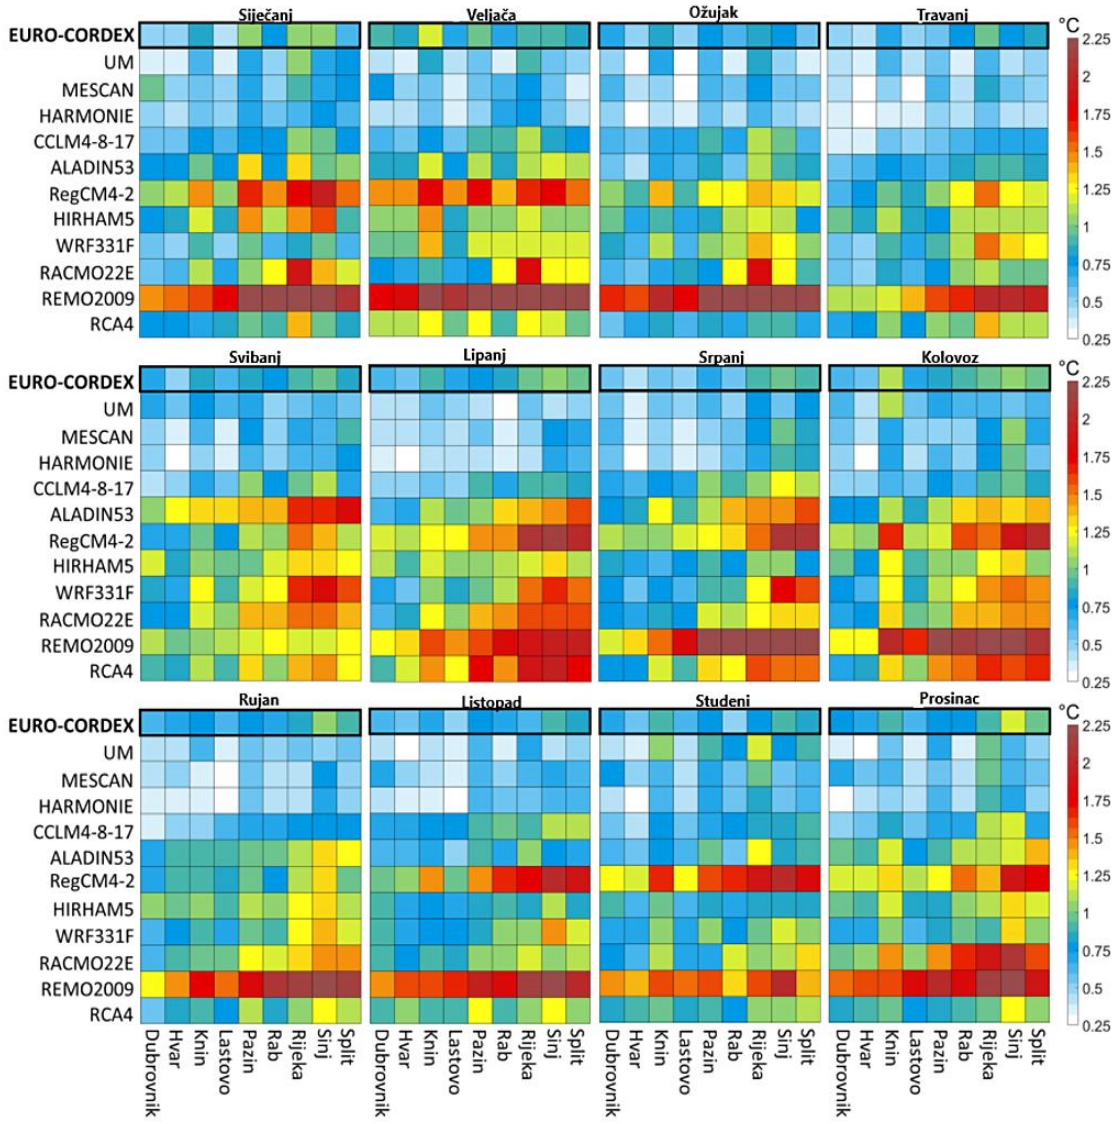
Kod svih modela se uočava nešto lošije ponašanje kod obalnih i otočnih položaja postaja. Takve rezultate možemo objasniti slabijom interpretacijom kompleksne orografije (omjerom kopna i mora; eng. *„LSF“*) u obalnom području (sl. 7).

Pokazuje se da modeli (RCM-ovi i reanalize) veće razlučivosti bolje interpretiraju topografiju. MESCAN reanaliza (horizontalne razlučivosti 5,5 km) ima rezultate najbliže mjerenjima, gledajući omjer kopna i mora, na svim postajama a posebno na otočnim postajama Rab i Lastovo. Kod ansambla regionalnih klimatskih modela EURO-CORDEX razlike u omjeru kopna i mora se „izglađuju“ što omogućuje da sveukupni rezultati budu bolji nego kod pojedinih modela. Omjer kopna i mora uvelike utječe na rezultate regionalnih modela u pogledu pristranosti i razlike u trendu. Sam prikaz orografije te omjer kopna i mora su uvelike uvjetovani razlučivošću jer, primjerice, MESCAN i HARMONIE koriste isti površinski model (SURFEX), ali reanaliza MESCAN ima generalno bolji učinak kod pristranosti T2m. Stoga, razlučivost modela ima ograničavajući faktor u prikazivanju mjerenja na istočnoj obali Jadrana.

Dodatno rezulatima modela u evaluacijskim simulacijama, gdje svi modeli koriste početne i rubne uvjete iz reanalize ERA-Interim (skupa s asimilacijom mjerenja), napravljena je statistička analiza po mjesecima (sl. 8 i 9). Analiza rezultata modela po mjesecima pokazala je da je promjenjivost RCM-ova znatno veća u ljetnim sezonama (lipanj, srpanj i kolovoz; sl. 8). REMO2009 pokazuje između 1 °C i 2,25 °C kao gornju granicu, a CCLM4-8-17 prikazuje promjenjivost između 0,5 °C i 1,25 °C kao donju granicu. Reanalize UERRA i ansambl imaju sličnu i malu promjenjivost tijekom cijele godine (manje od 1,25 °C). REMO2009 i RegCM4-2 pokazuju veliku promjenjivost tijekom cijele godine, a CCLM4-8-17 najmanju. CCLM4-8-17 se pokazao nešto boljim od ostalih regionalnih modela. Ne postoji razlika u promjenjivosti između otočnih, obalnih i kopnenih položaja ni između sjevernog i južnog Jadrana.

Ne postoji izražajnija razlika u razlici trendova između regionalnih modela i mjerenja na položajima postaja kod rezultata obje vrste simulacija (evaluacijske i povijesne; s. 6). Predznak razlike u trendovima je dosljedan na svim položajima. Kod rezultata povijesnih simulacija to je posebno izraženo kod modela NCC-NorESM1-M HIRHAM i CNRM-CM5 CCLM4-8-17 gdje izraženi trendovi podcjenjuju mjerenja (veće od 0,1 °C dekada^{-1}). Model ICHEC-EC-EARTH RACMO22E pokazuje značajno precjenjivanje trenda T2m (manje od 0,3 °C dekada^{-1}). Rezultati modela i reanaliza na položaju postaje Sinj, koja se nalazi u dolini, pokazuje na precjenjivanje trendova T2m. Podjednake razlike u trendu, bez obzira na vrstu simulacija,

pokazuje ansambl EURO-CORDEX. Različita razlučivost između pojedinih reanaliza UERRA uzrokovala je izrazite razlike u trendovima uspoređujući ih s mjerenjima (MESCAN ima najveću razliku u trendu).



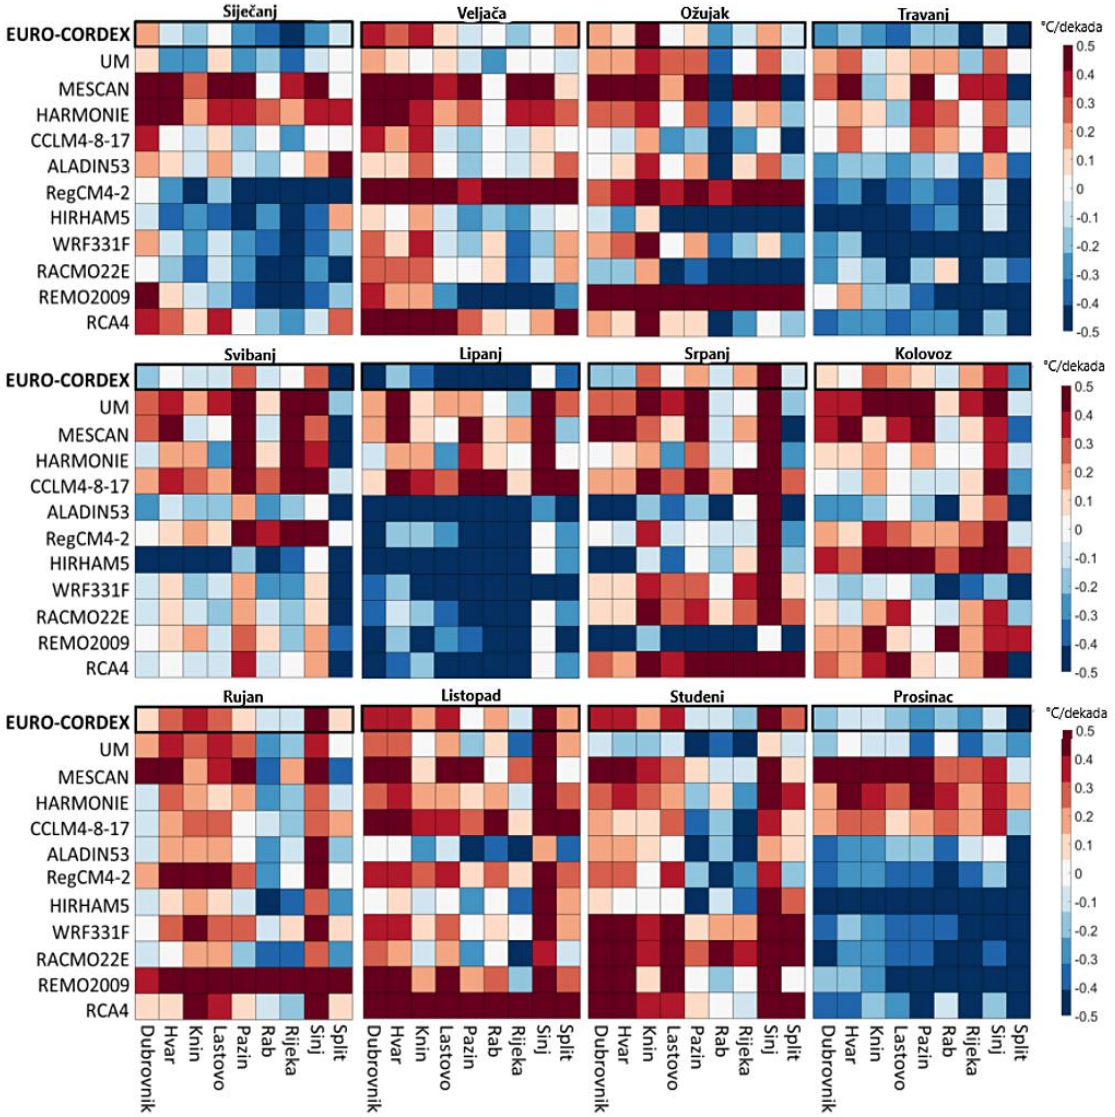
Slika 8. Korijen srednje kvadratne pogreške (RMSE) rezultata regionalnih klimatskih modela u evaluacijskim simulacijama za temperaturu na 2 metra nadmorske visine (T2m). Rezultati su usrednjeni za svaki mjesec. Razdoblje je od 1989. do 2008. godine.

Postoji velika heterogenost u razlici trendova T2m među modelima na položajima svih postaja (sl. 9). Nema značajnog uzorka u razlikama u trendu između otočnih, obalnih i kopnenih postaja ni između sjevernog i južnog Jadrana. Reanaliza UM pokazuje manju razliku u trendu s E-OBS-om u usporedbi s druge dvije reanalize UERRA. Općenito, svi modeli podcjenjuju trendove T2m na svim postajama u siječnju, travnju, lipnju i prosincu izuzev regionalnog modela CCLM4-8-17. Ovakvo ponašanje CCLM4-8-17 modela se može objasniti manjom promjenjivošću, visokim koeficijentom korelacije (sl. 12) te dobrim prikazom orografije (nadmorska visina u ćeliji modela najsličnija stvarnoj nadmorskoj visini na većini postaja).

Rezultati regionalnih modela u evaluacijskim simulacijama, kao i reanalize UERRA za razdoblje od 1989. do 2008. godine, analizirani su i po sezonama (sl. 10). Gledajući sve modele i reanalize vidljivo je da su ljeto i zima najpromjenjivije sezone za sve modele za razliku od proljeća i jeseni. Jedino regionalni model CCLM4-8-17 ima sličnu malu promjenjivost kao i reanalize (0,25 °C – 0,6 °C) što upućuje na to da taj model može najviše relativno točno reprezentirati mjerenja i opservacije na svim položajima postaja i to kroz sve sezone usporedno s ostalim modelima.

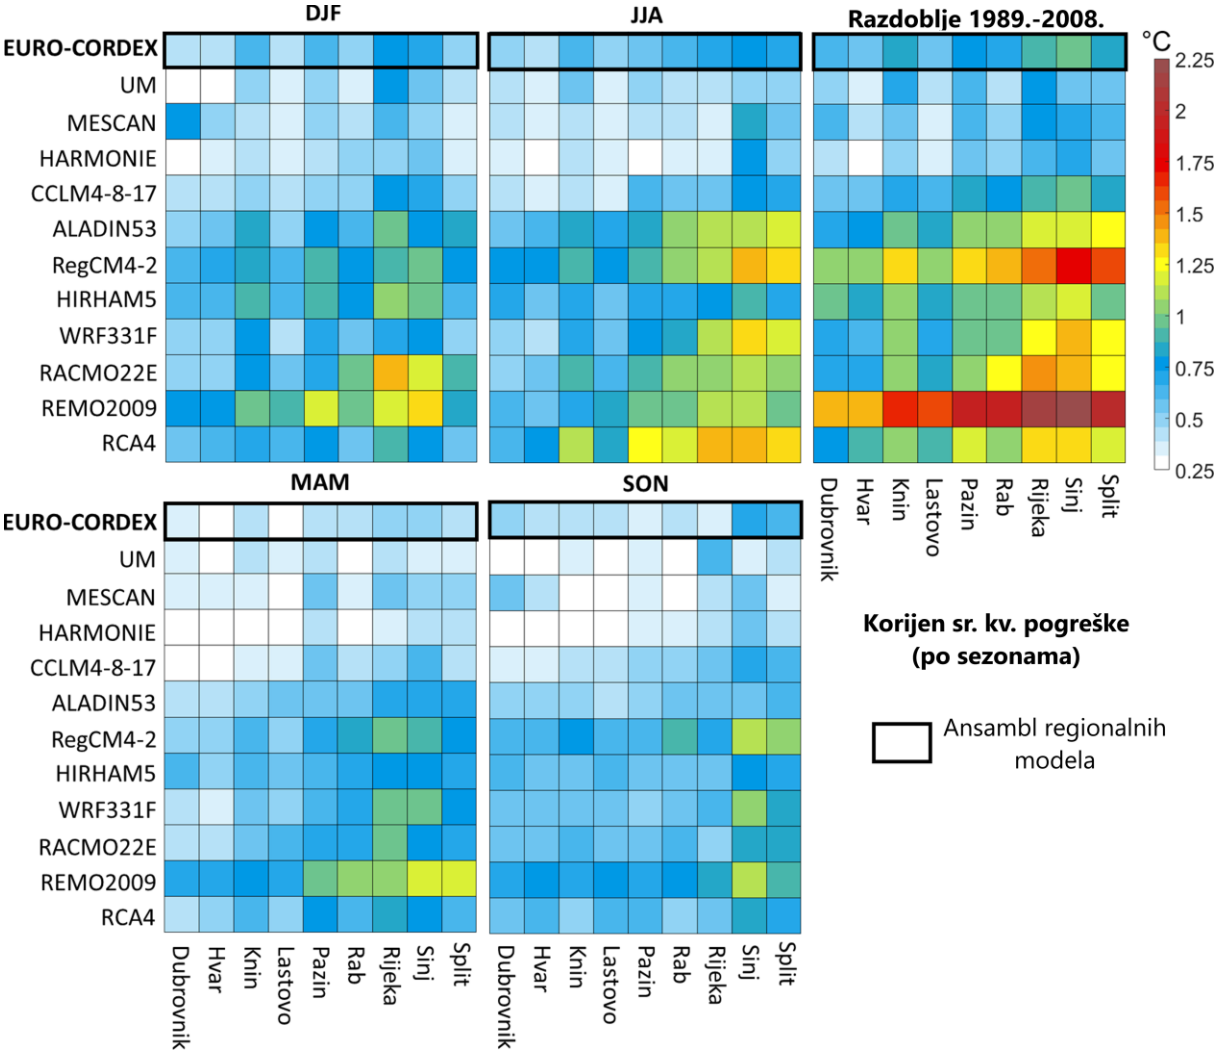
Vidljivo je i da ansambl regionalnih modela na većini postaja ima sličnu promjenjivost kao i reanalize što potvrđuje rezultat da ansambli poboljšavaju rezultate modela što na nekim položajima postaja doseže poboljšanje od 30%, dok je u prosjek 15% - 20% (sl. 10). Kod svih modela najveća promjenjivost, a ujedno i slaba reprezentativnost mjerenja, se najviše očituje na postajama koje se nalaze u području sa strmom orografijom i kod kojih se lokalno najbrže mijenja LSF. To su priobalne postaje Split i Rijeka te kopnena postaja Sinj. Najmanja promjenjivost se očituje na južnim postajama Hvar i Dubrovnik (sl. 10).

U ljetnim sezonama model RCA4 doseže promjenjivost od 1,5 °C na postajama Rijeka i Sinj slično kao RegCM4 na postaji Sinj, unatoč tome što model REMO2009 ima, općenito, najveću promjenjivost (sl. 8 i 10). Zimi modeli REMO2009 i RACMO22E pokazuju veliku promjenjivost (od 1 °C – 1,3 °C), dok su ostali modeli i ansambl ispod 1 °C. Reanalize UERRA, zbog asimilacije podataka, pokazuju promjenjivost do 0,75 °C u svim sezonama (sl. 10).



Slika 9. Razlika u trendu temperature na 2 metra nadmorske visine (T2m) rezultata regionalnih klimatskih modela u evaluacijskim simulacijama, Reanaliza UERRA i Produkta E-OBS. Rezultati su usrednjeni za svaki mjesec. Razdoblje je od 1989. do 2008. godine.

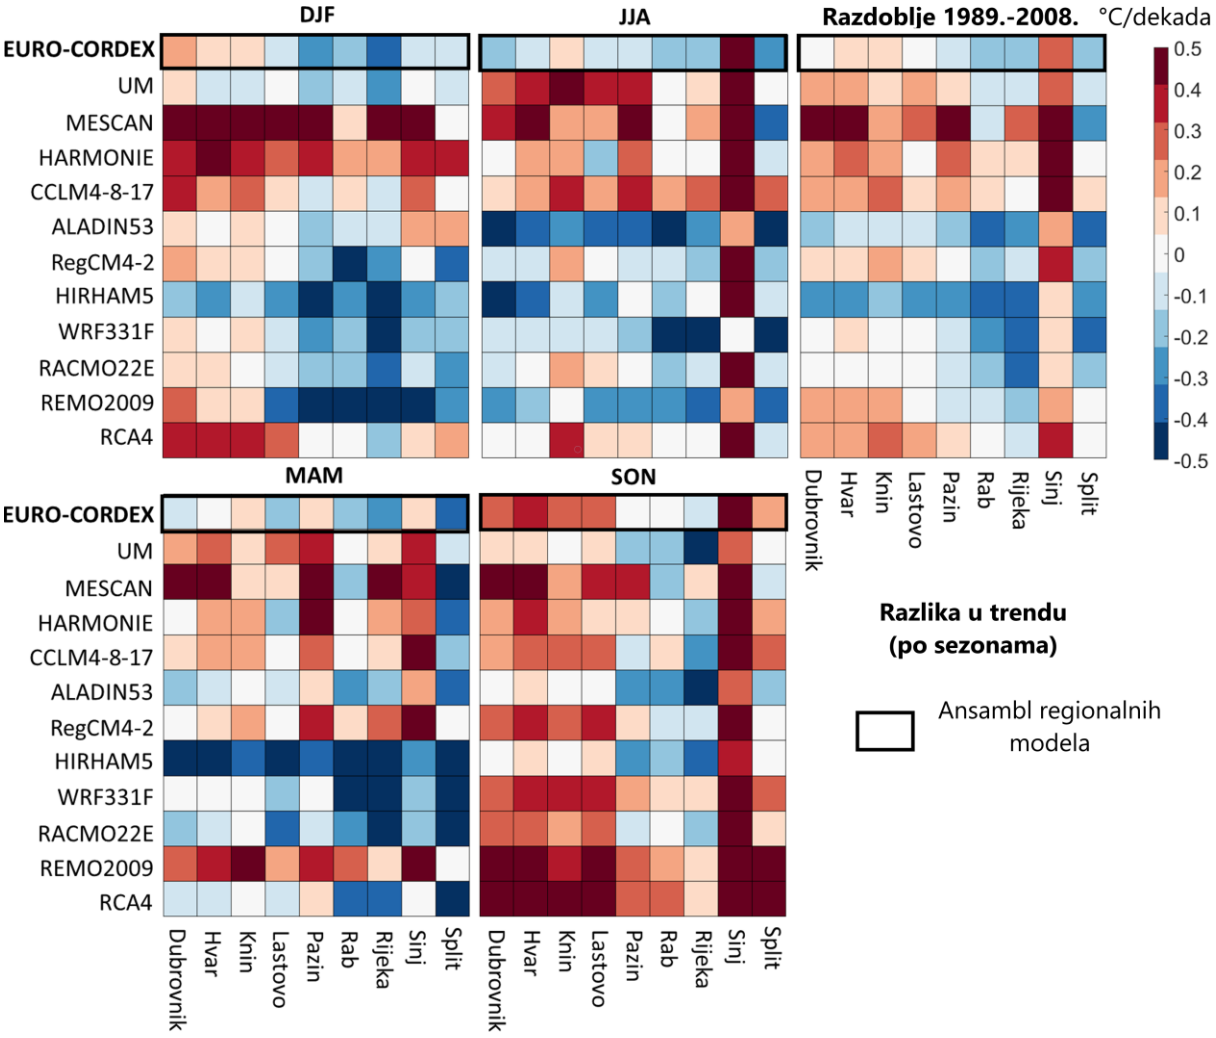
Za razliku od promjenjivosti (korijena srednje kvadratne pogreške), razlike u trendu pokazuju značajno veću raspršenost rezultata (sl. 9 i 11). Najveće razlike u trendovima između modela i mjerenja se javljaju u jesenskoj sezoni. Na šest od devet postaja srednjeg i južnog Jadrana regionalni modeli REMO2009 i RCA4 precjenjuju izmjereni trend za više od 0,4 °C dekada^{-1} . Za postaje sjevernog Jadrana dobivena je manja razlika u trendu, što se može barem djelomično povezati s utjecajem kopna i hladnog strujanja iz unutrašnjosti kontinenta koji onda



Slika 10. Korijen srednje kvadratne pogreške (RMSE) rezultata regionalnih klimatskih modela u evaluacijskim simulacijama za temperaturu na 2 metra nadmorske visine (T2m) po sezonama. DJF – zima, MAM – proljeće, JJA – ljeto, SON – jesen. Razdoblje je od 1989. do 2008. godine.

smanjuju utjecaj visokih temperatura koje dolaze sa Sredozemlja. Takvo ponašanje se uočava i kod utjecaja mora na temperaturu zraka (poglavlje 4.2) gdje većina toplinskih valova u Jadranu počinje porastom površinske temperature Jonskog mora koje se onda kroz Otrantska vrata širi u Jadran u smjeru jug-sjever. Također valja naglasiti da se trajanje epizoda toplinskih valova u moru i u atmosferi produžuje na mjesec rujan (kod ekstremnih epizoda čak i na početak listopada) što uzrokuje još veće razlike u trendovima dobivenih regionalnim modelima u odnosu na mjerenja. Razlike u trendu dobivenog ansamblom EURO-CORDEX s izmjerenim trendom su manje od onih za pojedinačne modele izuzev za postaju Sinj gdje se zbog, već spomenute,

karakteristične mikroklime i položaja na dnu doline javlja precjenjivanje trendova kod svih modela i reanaliza (sl. 6, 9 i 11).

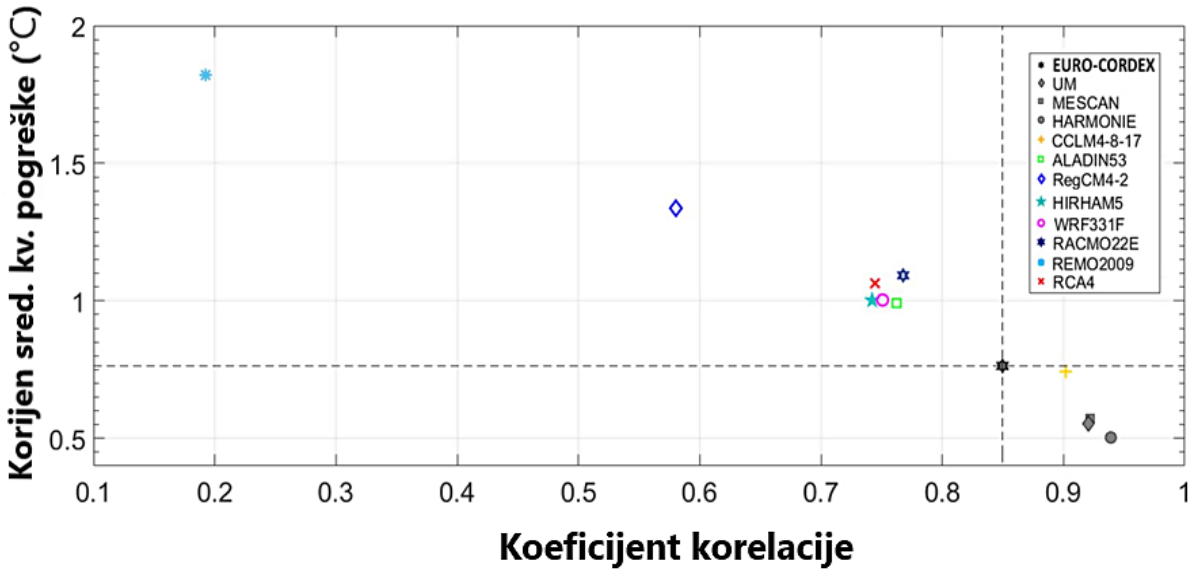


Slika 11. Razlika u trendu temperature na 2 metra nadmorske visine (T2m) rezultata regionalnih klimatskih modela u evaluacijskim simulacijama, Reanaliza UERRA i Produkta E-OBS po sezonama. DJF – zima, MAM – proljeće, JJA – ljeto, SON – jesen. Razdoblje je od 1989. do 2008. godine.

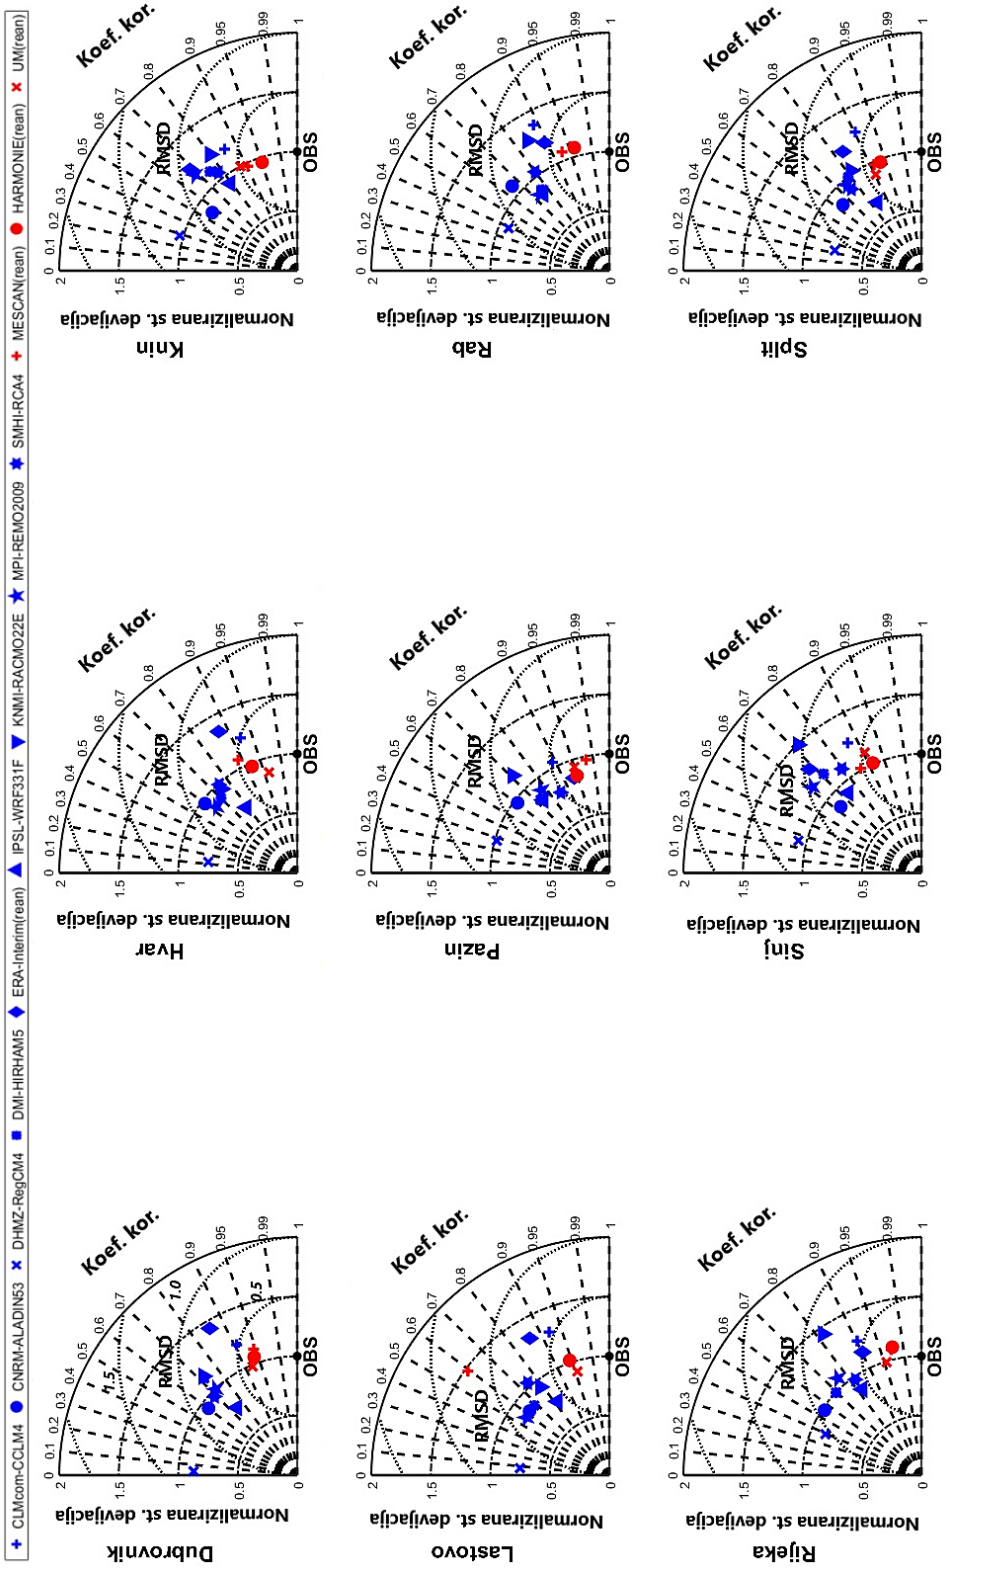
Kod reanaliza UERRA se uočava različito ponašanje između reanalize UM s jedne strane i reanaliza MESCAN i HARMONIE reanaliza s druge (sl. 11). U zimskoj sezoni UM blago podcjenjuje trendove mjerenja od -0,2 °C dekada^{-1} do 0 °C dekada^{-1} (postaja Dubrovnik) dok MESCAN i HARMONIE precjenjuju trendove za više od 0,3 °C dekada^{-1}. Slični rezultati ovih dviju reanaliza se mogu objasniti time što MESCAN i HARMONIE dijele istu 3D varijacijsku shemu modela ALADIN za poboljšanje razlučivosti za razliku od reanalize UM.

4.1.2 Rangiranje regionalnih modela kroz ljetne (JJA) i zimske (DJF) sezone te prednosti korištenja ansambla

Očekivano, reanalize UERRA visoke razlučivosti imaju najviše koeficijente korelacije (veće od 0,9) i najnižu promjenjivost na mjestima postaja zbog asimilacije mjerenja (sl. 12). EURO-CORDEX ansambl, također, pokazuje poboljšanje u korelaciji i promjenjivosti u usporedbi s drugim modelima. Općenito, ponašanje promjenjivosti u odnosu na koeficijent korelacije pokazuje da smanjenje promjenjivosti rezultata uzrokuje povećanjem koeficijenta korelacije (sl. 12). REMO2009 je model s najvišom promjenjivošću i najnižim koeficijentom korelacije (0,19). Budući da je u svim regionalnim modelima pristranost korigirana, REMO2009 je model s najvećom pristranosti što znači da koristi različitu metodu korekcije pristranosti u usporedbi s ostalim RCM-ovima. Većina modela ima slične koeficijente korelacije (oko 0,75 izuzev već spomenutog modela REMO2009 i RegCM4-2), dok model CCLM4-8-17 pokazuje još bolje rezultate u usporedbi s drugim modelima i ansamblom (koeficijent korelacije veći od 0,85).



Slika 12. Rangiranje i izvedba modela (UERRA, RCM-ovi i ansambl), u evaluacijskom načinu rada, prikazana korijenom srednje kvadratne pogreške naspram koeficijenata korelacije za devet mjernih postaja. Korijen srednje kvadratne pogreške i korelacija se izračunavaju kao srednja vrijednost korijena srednje kvadratne pogreške i srednja vrijednost koeficijenata korelacije po svim postajama.



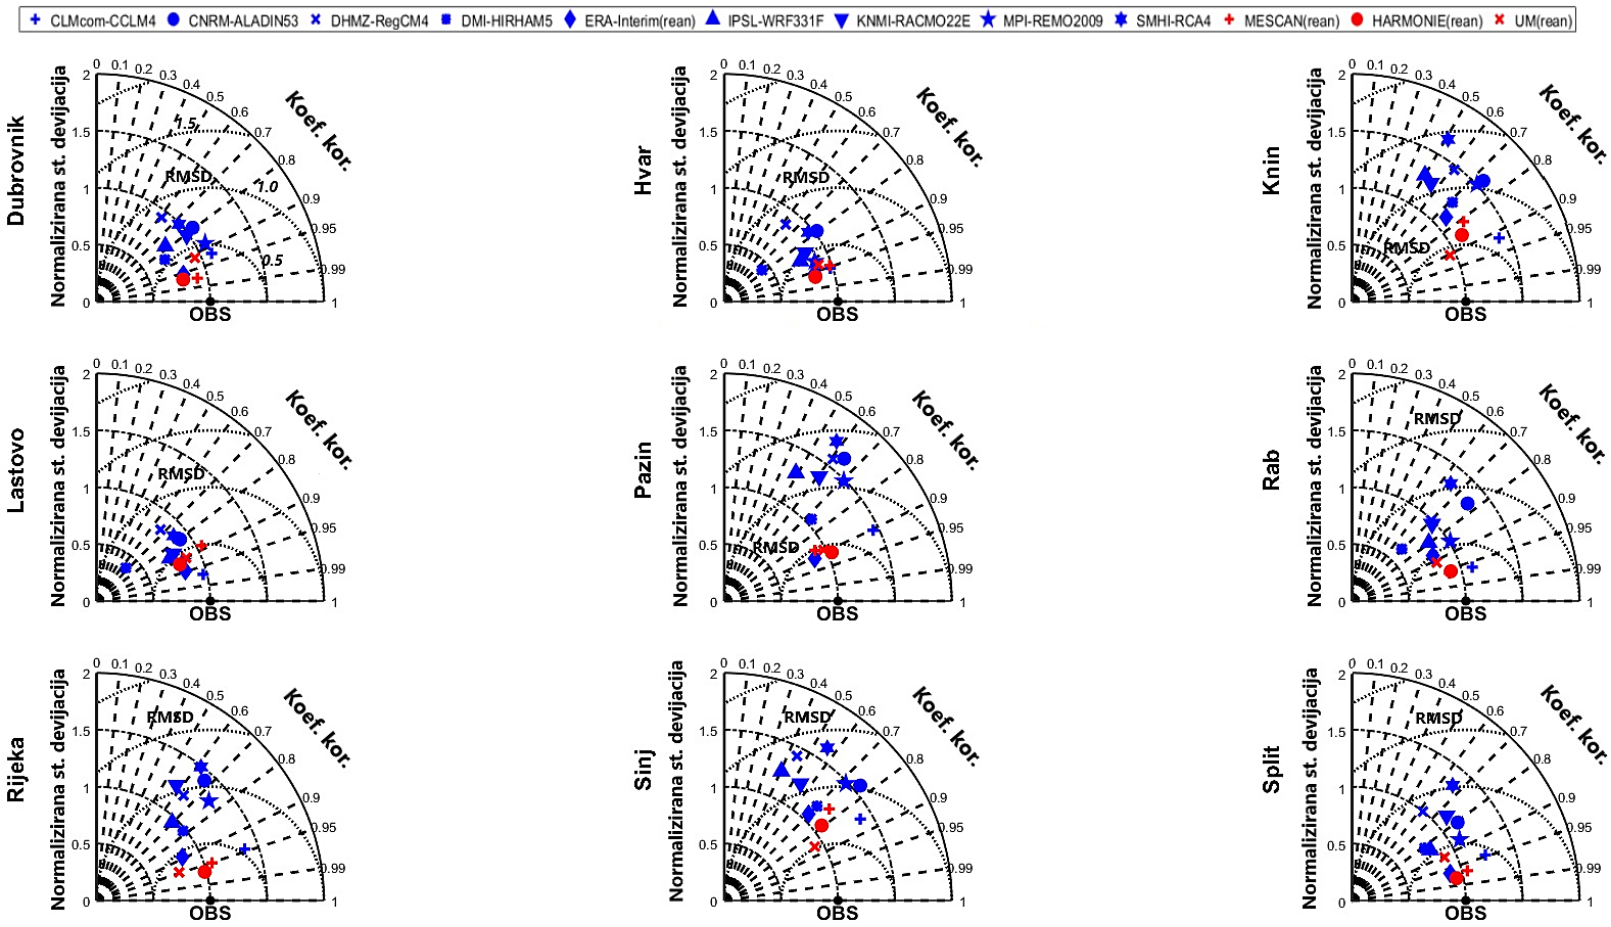
Slika 13. Normalizirani Taylorov dijagram rezultata evaluacijskih simulacija na lokacijama postaja. Prikazane su izvedbe modela s obzirom na prostornu promjenjivost (standardna devijacija) srednje vrijednosti T2m u zimskim sezonama (DJF). Udaljenost između RCM-ova, reanaliza i mjerenja (OBS) odgovara normaliziranom i centriranom korijenu srednje kvadratne pogreške (RMSD; interval = 0,5 °C) koja ne uzima u obzir pristranost modela.

Promjenjivost ljetne i zimske T2m analizirana je Taylorovim dijagramima preko standardne devijacije i korijena srednje kvadratne pogreške u odnosu na mjerenja (sl. 10 i 14). Reanaliza UERRA visoke razlučivosti (MESCAN) ima mali korijen srednje kvadratne pogreške u svim godišnjim dobima i najbliža je mjerenjima. Taj se rezultat dodatno poboljšava na otočnim postajama (npr. Lastovo) jer ova reanaliza ima najmanji prostorni korak pa točka mreže modela može doći bliže stvarnom položaju postaje.

Kod regionalnih modela, model simulira T2m na položaju otočnih i obalnih postaja (posebno one s malim LSF-om), dok za kopnene postaje koristi temperaturu površine kopna kroz algoritme ravnoteže površinske energije koji stvaraju T2m. Topografska složenost i učinak kopna uzrokuju veću varijabilnost T2m pa zbog toga vremenska korelacija raste udaljavanjem od kopna i obale jer slabi njihov utjecaj. Slijedom toga, korelacija okomito na obalu se povećava idući iz unutrašnjosti prema moru. To znači da najmanja korelacija u svim godišnjim dobima, između RCM-ova, reanaliza i mjerenja je u unutrašnjosti, na položaju postaje Knin, a najviša je na otočnom položaju postaje Lastovo. Zimske sezone ne pokazuju gotovo nikakvu korelaciju kod svih modela. To ukazuje na to da RCM-ovi ne mogu dobro reproducirati mjerenja u uvjetima značajne sinoptičke promjenjivosti (zimi), dok slabija ljetna promjenjivost omogućava bolje podudaranje između rezultata modela, reanaliza i mjerenja.

Korelacija duž obale je slična na sjeveru i jugu (npr. usporedba rezultata za Rijeku i Dubrovnik). Stanice na kopnu i obali imaju tendenciju precijeniti vremensku promjenjivost (normalizirana standardna devijacija veća je od 1) dok je promjenjivost dobro reproducirana na otočnoj postaji Lastovo (standardna devijacija iznosi približno 1). To pokazuje veću simuliranu varijancu kopnene temperature (i u unutrašnjosti i u primorju) za razliku od mora. Artegiani i sur. (1997a) primijetili su veće odstupanje u pogledu sezonskih oscilacija temperature zraka u iznosu od 20 °C na području cijelog jadranskog bazena. Na sjeveru prevladava veći uzdužni gradijent temperature, a poprečni gradijent je dominantan na jugu. Zbog sveg navedenog, vjerojatnost ekstremnih temperatura trebala bi se i dalje povećavati, ovisno o veličini promjena srednje vrijednosti T2m i prirode odgovora varijance temperature.

Razlike u temperaturnim trendovima (sl. 6 i 9), rangiranju modela (sl. 12 i 15), promjenjivosti i korelacije (sl. 12, 13 i 14) pokazuju da postoji prednost korištenja ansambla



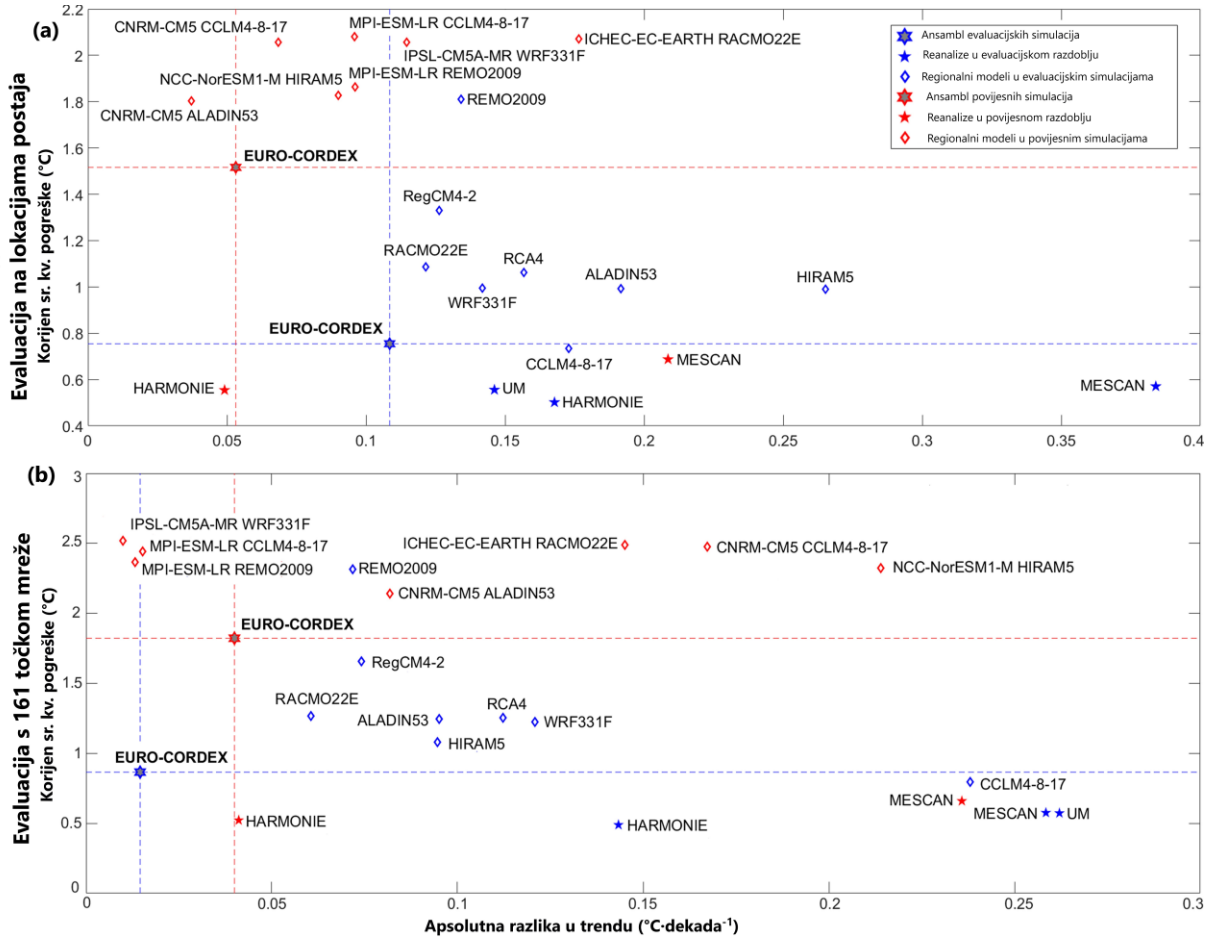
Slika 14. Normalizirani Taylorov dijagram rezultata evaluacijskih simulacija na lokacijama postaja. Prikazane su izvedbe modela s obzirom na prostornu promjenjivost (standardna devijacija) srednje vrijednosti T2m u ljetnim sezonama (JJA). Udaljenost između RCM-ova, reanaliza i mjerenja (OBS) odgovara normaliziranom i centriranom korijenu srednje kvadratne pogreške (RMSD; interval = 0,5 °C) koja ne uzima u obzir pristranost modela.

modela u odnosu na rezultate svakog regionalnog modela zasebno, posebno za donošenje općih zaključaka o klimi i temperaturnim kretanjima na istočnom Jadranu.

Sljedeća vrsta rangiranja modela napravljena je uspoređujući prosječni korijen srednje kvadratne pogreške svakog modela i apsolutne razlike u trendu koristeći podatke mjernih postaja (sl. 15a) i mreže E-OBS (sl. 15b). Rezultati regionalnih klimatskih modela u obje vrste simulacija su grupirani u klastere i razdvojeni u dvije grupe. Klaster modela povijesnih simulacija ima veći korijen srednje kvadratne pogreške (1,5 – 2,1 °C) i manju razliku u trendu (0 °C dekada^{-1} – 0,12 °C dekada^{-1}), dok je ICHEC-EC-EARTH RACMO22E iznimka s apsolutnom razlikom u trendu od 0,17 °C dekada^{-1}. Kod klastera modela evaluacijskih simulacija iznimke su modeli REMO2009 s korijenom srednje kvadratne pogreške od 1,81 °C i HIRHAM5 s razlikom u trendu od 0,27 °C dekada^{-1}.

EURO-CORDEX ansambli RCM-ova i povijesnih i evaluacijskih simulacija i u ovoj usporedbi poboljšavaju rezultate u usporedbi s pojedinim modelom. Reanalize UERRA imaju najmanji rasap korijena srednje kvadratne pogreške (0,4 – 0,7 °C) kod obje vrste simulacija ali i veliki rasap kod razlika u trendovima (0,05 °C dekada^{-1} – 0,38 °C dekada^{-1}). To je rezultat procesa asimilacije mjerenja kod evaluacijskih simulacija gdje su njihovi rezultati bliže mjerenjima pa je zbog toga i promjenjivost manja. Premda, zbog toga što je kod evaluacijskih simulacija (vremensko razdoblje 1989. do 2008. godine) znatno manji broj podataka (samo 20), razlika u trendu je veća nego kod povijesnih simulacija.

Na slici 15b uzeta je u analizu 161 točka modela (sl. 3) koja predstavlja obalni pojas. Usporedba RCM-ova s produktom E-OBS pokazuje slične rezultate za cijeli obalni pojas, ali oba EURO-CORDEX ansambla i reanalize UERRA pokazuju manji korijen srednje kvadratne pogreške i slične razlike u trendovima kao i regionalni modeli. U klasteru evaluacijskih simulacija REMO2009 je iznimka s korijenom srednje kvadratne pogreške od 2,3 °C dok CCLM4-8-17 pokazuje najveću razliku u trendu od 0,24 °C dekada^{-1}.



Slika 15. Rangiranje regionalnih klimatskih modela, Reanaliza UERRA i EURO-CORDEX ansambla po rezultatima temperature zraka na 2 metra nadmorske visine (T2m). Na y-osi se nalazi korijen srednje kvadratne pogreške (°C) dok je na x-osi apsolutna razlika u trendu između pojedinog modela i (a) mjerenja, (b) produkta E-OBS. (a) Evaluacija na lokacijama postaja i (b) Evaluacija s 161 točkom E-OBS duž jadranske obale u evaluacijskom (1989. - 2008.) i povijesnom (1961. - 2005.) načinu rada.

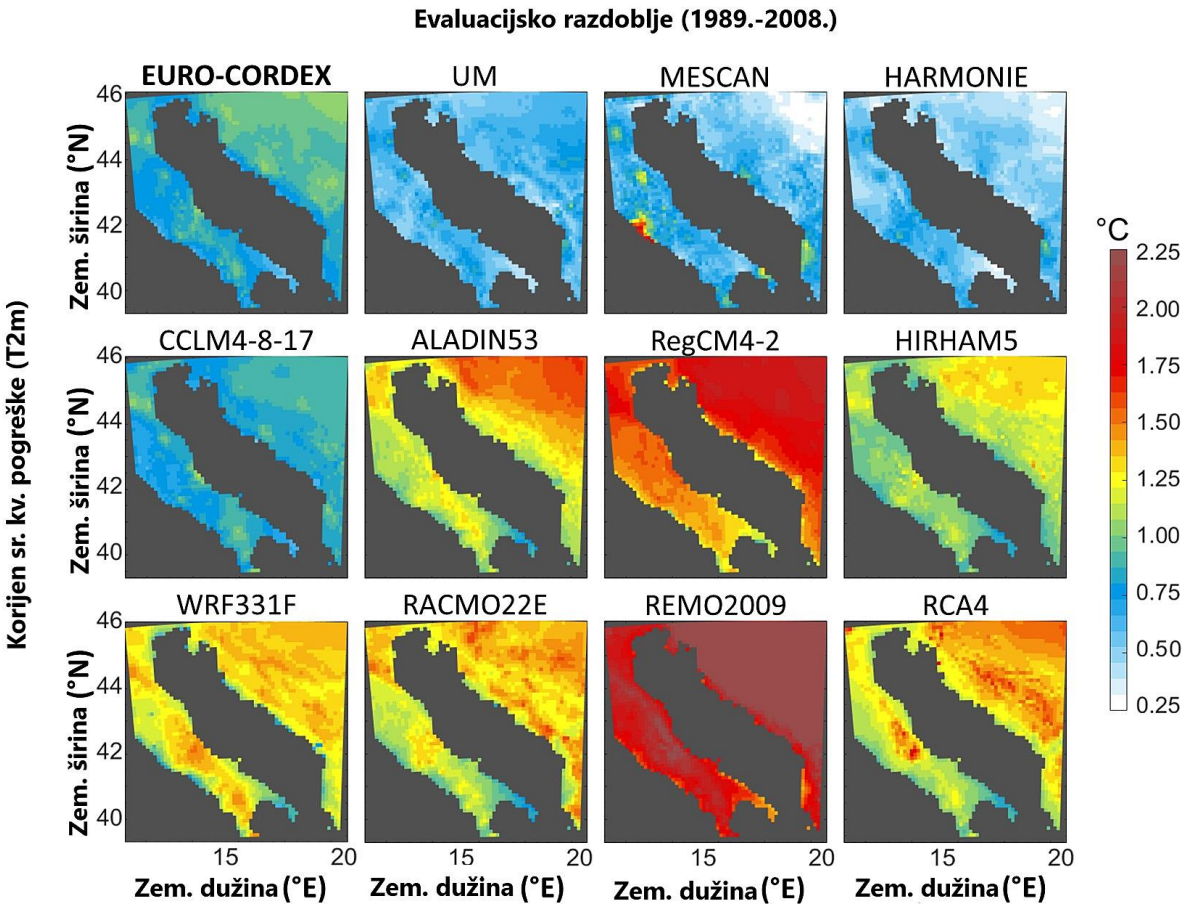
4.1.3 Prostorna, regionalna obilježja i trendovi

Prostorna raspodjela korijena srednje kvadratne pogreške na jadranskom području pokazuje slično ponašanje kao i kod usporedbe modela na položajima postaja (sl. 16 i 18). Sve tri reanalize UERRA pokazuju mali korijen srednje kvadratne pogreške iznad istočne obale Jadrana (0,25 °C - 1 °C). Rezultati analize su slični kod obje vrste simulacija što ukazuje na to da vremenska duljina razdoblja analize (i količina podataka) ne utječe na promjenjivost. Većina RCM-ova ima korijen srednje kvadratne pogreške između 1 °C i 1,75 °C kod evaluacijskih simulacija, izuzev dva regionalna modela, RegCM4-2 i REMO2009 koji imaju veliku promjenjivost od 1,25 °C do 2,25 °C. Ova dva regionalna modela pokazuju, ujedno, i najveću promjenjivost u usporedbi modela na položajima postaja (sl. 6a i 12).

Kod rezultata povijesnih simulacija imamo drugačije ponašanje modela. Svi RCM-ovi pod utjecajem raznih globalnih modela (čak i oni modeli sa istim GCM-om) imaju veliki korijen srednje kvadratne pogreške (veći od 1,75 °C). Rubni uvjeti stvaraju razlike u korijenu srednje kvadratne pogreške lokalno (sl. 6c) i regionalno na istočnom Jadranu (sl. 16 i 18). Ove se razlike očituju i kod ansambala obje vrste simulacija.

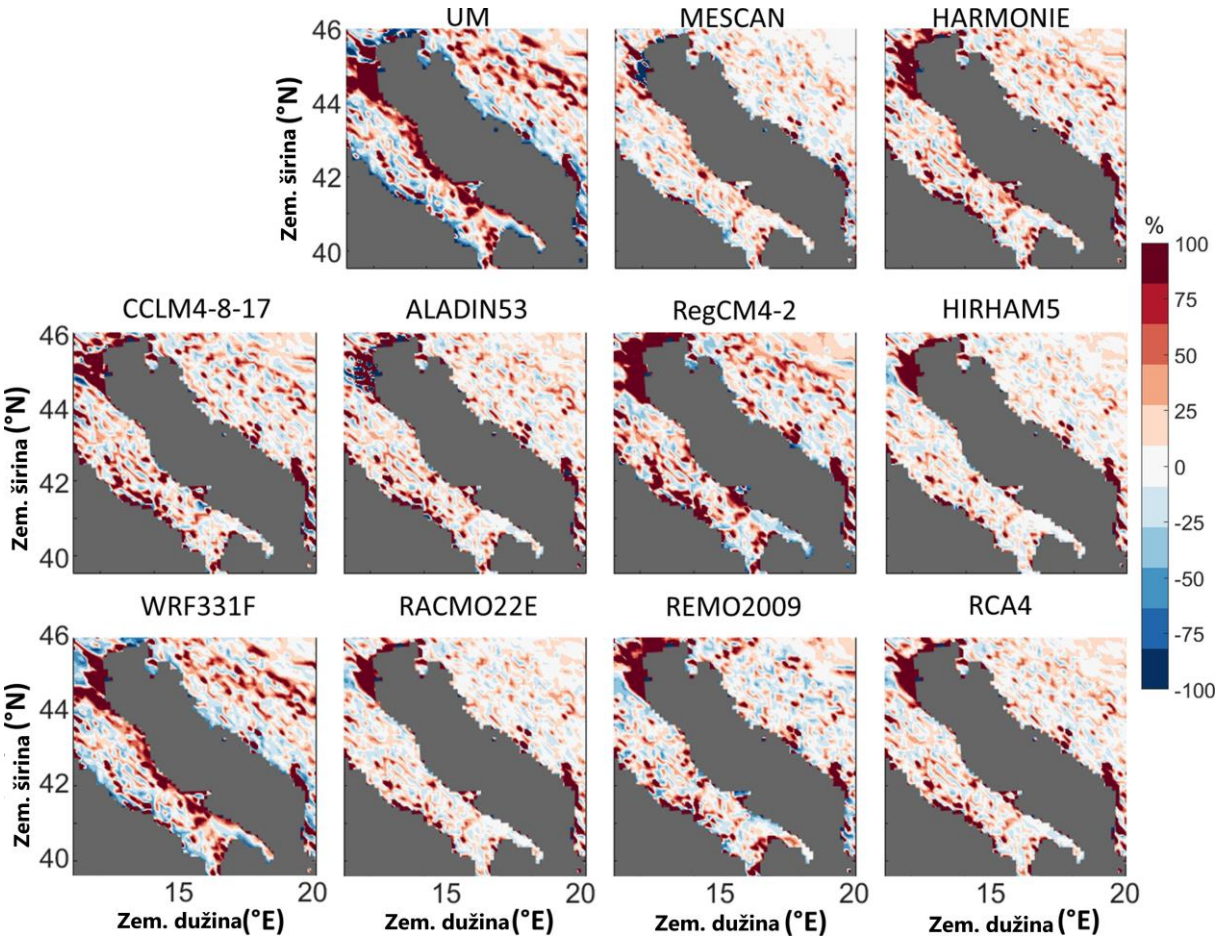
Ansambl rezultata evaluacijskih simulacija ima manji korijen srednje kvadratne pogreške, koji poprima vrijednosti od 0,75 °C na priobalju do 1 °C u unutrašnjosti Balkanskog poluotoka. Za razliku, ansambl rezultata povijesnih simulacija ima vrijednost od 1,5 °C na priobalju do 2 °C u unutrašnjosti. Ovakav rezultat ukazuje na poboljšanje rezultata RCM-ova čiji su rubni i početni uvjeti preuzeti iz reanaliza s asimilacijom podataka (evaluacijske simulacije) u odnosu na modele s početnim i rubnim uvjetima iz različitih globalnih modela vrlo „grubih“ razlučivosti (povijesne simulacije). Poboljšanje iznosi od 15% do 20% u odnosu na svaki model pojedinačno (sl. 16).

Veliki korijen srednje kvadratne pogreške se većinom uočava u središnjem djelu istočne obale Jadrana, gdje prevladava planinsko i brdovito područje, odnosno strma orografija. Zbog toga su razlike između izmjerene i modelirane temperature zraka znatno veće.



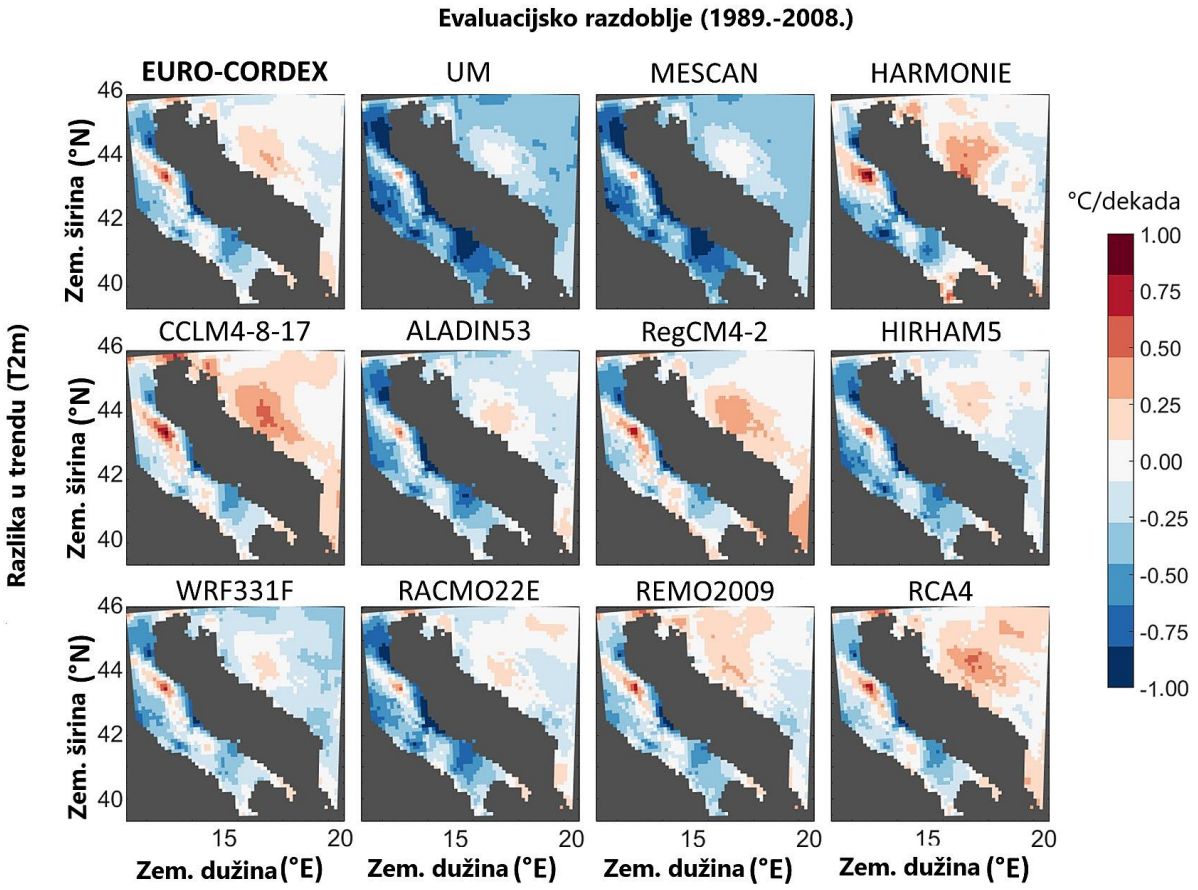
Slika 16. Prostorna raspodjela korijena srednje kvadratne pogreške T2m (*RMSE*) za područje Jadrana kod rezultata simulacija u evaluacijskom načinu rada za razdoblje od 1989. do 2008. godine.

Prostorna usporedba razlika u trendu temperature zraka (T2m) regionalnih modela s mrežnim podacima E-OBS-a pokazuje da svi modeli imaju razlike između -0,5 °C dekada^{-1} i 0,5 °C dekada^{-1} nad istočnim dijelom jadranske obale (sl. 20). Ne postoji izravna poveznica između omjera kopna i mora (LSF) odnosno razlike orografije model-E-OBS s uzorcima razlika T2m za rezultate simulacija ni u povijesnom ni u evaluacijskom razdoblju (sl. 17). Na primjer, postoji dosljedan obrazac precjenjivanja trendova od strane RCM-ova duž srednje jadranske obale, ali omjer kopna i mora i razlika u orografiji model-E-OBS nije se drastično razlikovala od postavki Produkta E-OBS.



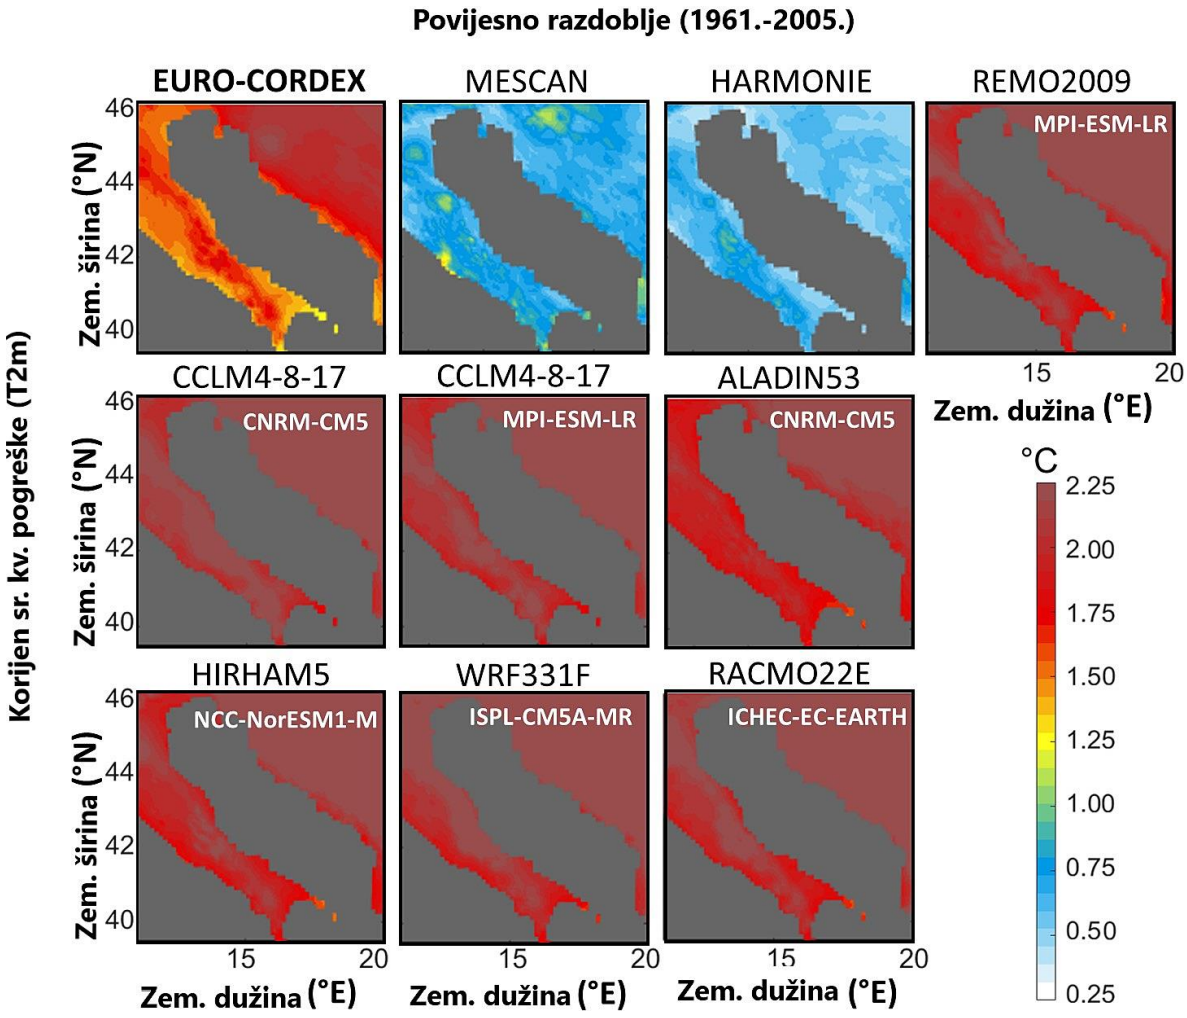
Slika 17. Prostorna raspodjela visinske razlike u orografiji (%) između modela i interpolirane mreže mjerenja (E-OBS). Razlučivosti svih modela su skalirane na razlučivost Produkta E-OBS

Simulirana temperaturna neodređenost kod rezultata modela u konačnici je određena gustoćom postaja, a nedostupnost velike količine podataka (ograničenost brojem mjernih postaja) za cijelu istočnu jadransku obalu ograničava usporedbu modela. Dvije reanalize UERRA, MESCAN i UM, prostorno pokazuju podcjenjivanja temperaturnih trendova E-OBS-a kod rezultata evaluacijskih simulacija (sl. 18), dok se RCM-ovi i EURO-CORDEX ansambl više slažu s HARMONIE reanalizom, bez značajnih razlika u trendovima na sjevernom i južnom dijelu istočne obale Jadrana. Zanimljivo je primijetiti da se, iako RegCM4-2 i REMO2009 pokazuju značajno različito ponašanje u pogledu korijena srednje kvadratne pogreške od ponašanja ostalih RCM-a u evaluacijskim simulacijama (sl. 19), ovi modeli ponašaju se slično ostalim modelima u smislu razlika u trendovima. Kod rezultata povijesnih simulacija, svi RCM-ovi i reanalize pokazuju još manje razlike (sl. 20).



Slika 18. Prostorna raspodjela razlike u koeficijentu trendova T2m između modela i interpolirane mreže mjerenja (E-OBS) za područje Jadrana. Prikazani su rezultati simulacija u evaluacijskom načinu rada za razdoblje od 1989. do 2008. godine

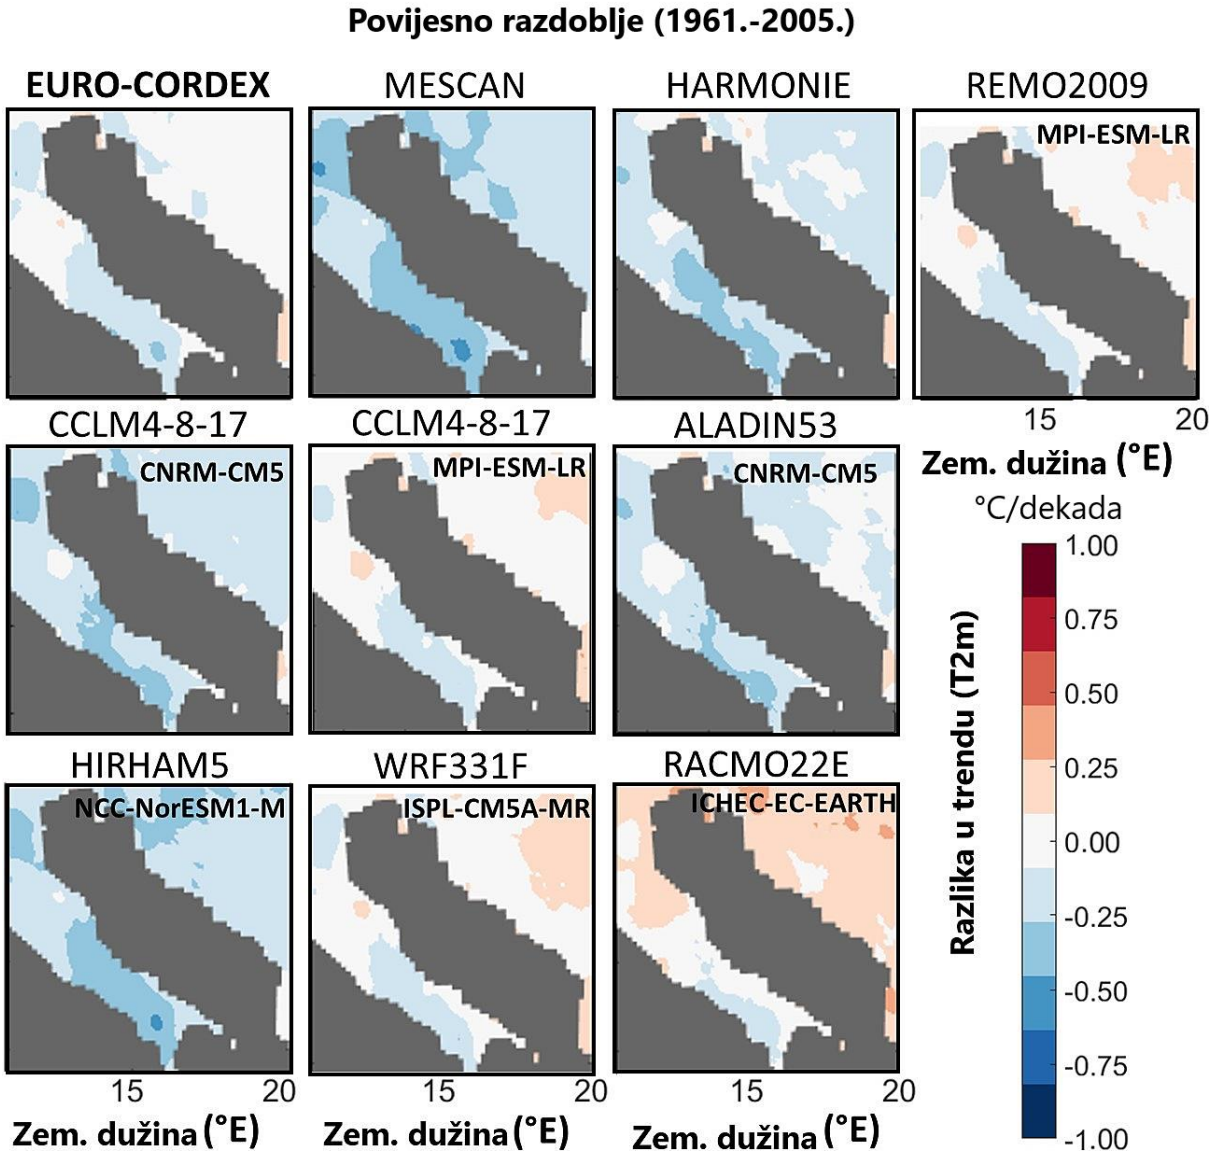
Modeli koji su forsirani istim globalnim modelom imaju snažan utjecaj istih početnih i rubnih uvjeta pa ujedno i pokazuju slične obrasce (npr. CCLM4-8-17 i REMO2009 s globalnim modelom MPI-ESM-LR; CCLM4-8-17 i ALADIN53 s CNRM-CM5 globalnim modelom). EURO-CORDEX ansambl u povijesnim simulacijama pokazuje male razlike u trendovima (od −0,1 °C dekada^{-1} do 0,1 °C dekada^{-1}). Ne postoje značajne razlike u trendovima za RCM-ove i reanalize UERRA između rezultata povijesnih i evaluacijskih simulacija, iako postoji značajna razlika u promjenjivosti u povijesnom razdoblju za RCM-ove zbog forsiranja različitim globalnim modelima (sl. 6c i 18).



Slika 19. Prostorna raspodjela korijena srednje kvadratne pogreške T2m (*RMSE*) za područje Jadrana kod rezultata simulacija u povijesnom načinu rada za razdoblje od 1961. do 2005. godine. Unutar svake kućice se nalaze nazivi globalnih modela čije postavke uvjetuju početne i rubne uvjete za regionalne modele.

Regionalni modeli koji početne i rubne uvjete uzimaju iz MPI-ESM-LR globalnog modela (RCM-ovi REMO2009 i CCLM4-8-17) imaju vrlo malu razliku trendova (manju od 0,15 °C dekada^{-1}) u priobalnom dijelu istočnog Jadrana dok ta razlika raste prema unutrašnjosti Balkanskog poluotoka (sl. 20). Najveće precjenjivanje trenda E-OBS-a iznad kopna pokazuje RACMO22E s globalnim modelom ICHEC-EC-EARTH. Suprotno ponašanje podcjenjivanja trenda E-OBS-a, uz reanalizu MESCAN, pokazuje model HIRHAM5 s globalnim modelom NCC-NorESM1-M. Podcjenjivanje mjestimično (južna Italija i sjeverni Jadran) prelazi i -0,5 °C dekada^{-1}. Iz slike 16 očito je da ansambl rezultata povijesnih simulacija otklanja utjecaje

različitih GCM-ova te uvelike smanjuje razliku u trendovima između modela i Produkta E-OBS.



Slika 20. Prostorna raspodjela razlike u koeficijentu trendova T2m između modela i interpolirane mreže mjerenja (E-OBS) za područje Jadrana. Prikazani su rezultati simulacija u povijesnom načinu rada za razdoblje od 1989. do 2008. godine. Unutar svake kućice se nalaze nazivi globalnih modela čije postavke uvjetuju početne i rubne uvjete za regionalne modele.

4.2 Površinska temperatura mora

4.2.1 Trendovi površinske temperature mora i evaluacija metode za detekciju toplinskih valova u moru

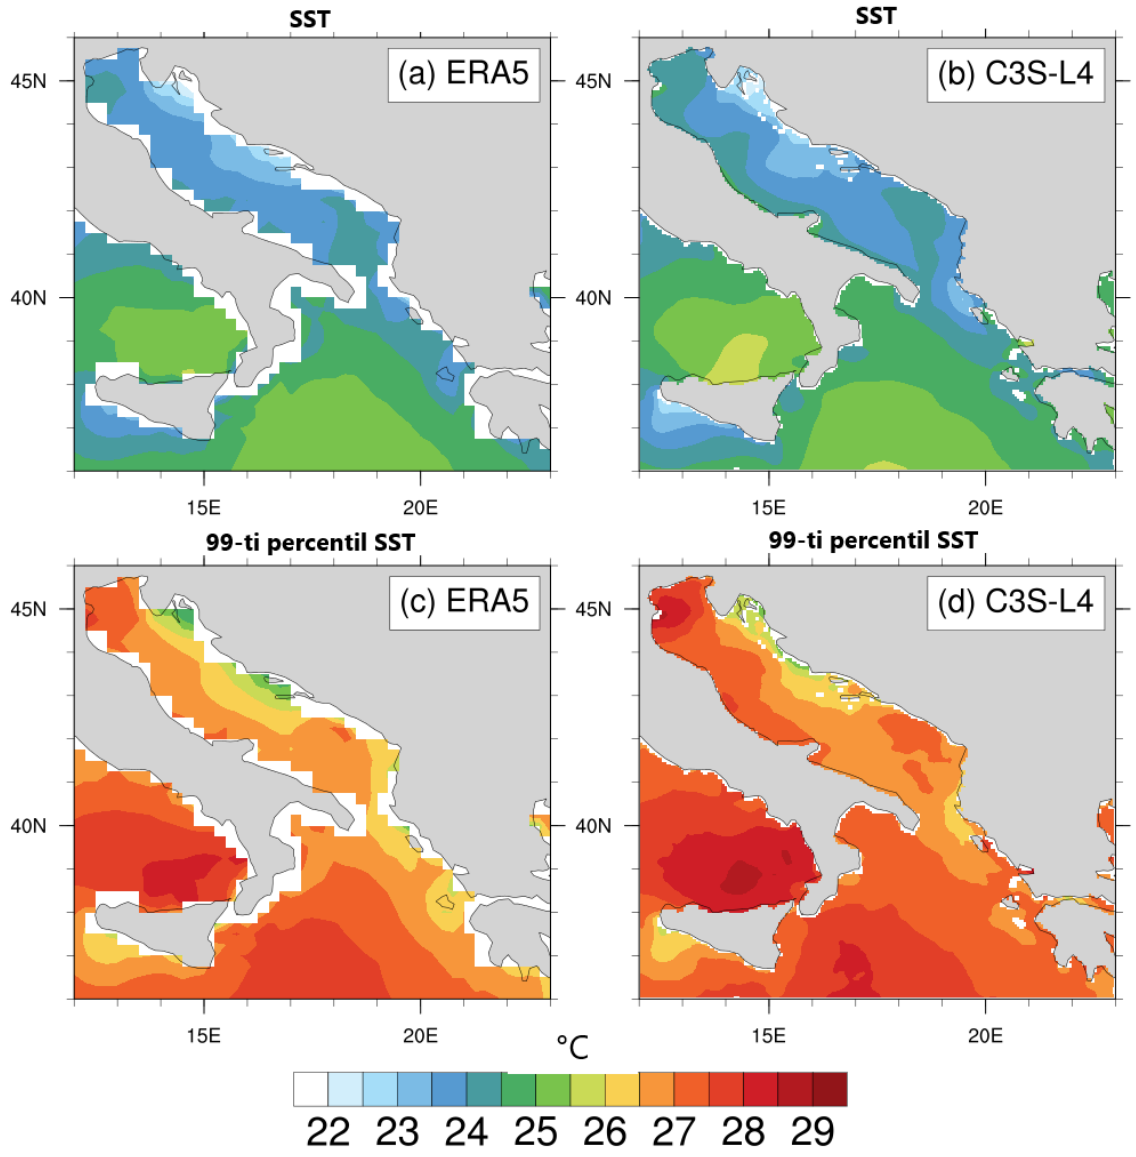
Tijekom promatranog razdoblja zapadni dio Jadrana bio je u prosjeku topliji od istočnog za 2 °C (sl. 21). Izmjerena i simulirana prosječna površinska temperatura mora (SST) u ljetnim sezonama za razdoblje od 1982. do 2018. godine pokazuje sjeveroistočno-jugozapadni gradijent hladno-toplih temperatura u rasponu od 22 °C do 25 °C. Karte pragova 99. percentila pokazuju da je razlika u ekstremima površinske temperature mora između zapadnog i istočnog dijela veća za oko 3 ºC do 3,5 ºC.

Najviši 99. percentil SST-a zabilježen je na plitkom sjevernom dijelu Jadrana gdje površinska temperatura mora doseže 29 °C, dok je najniži oko 22 °C te je zabilježen u priobalnom dijelu istočnog Jadrana. Godišnji prosječni zonalni gradijent površinske temperature mora povećava se od istočne jadranske obale do zapadnog Jadrana, dijelom i zbog sredozemne površinske cirkulacije (Grbec i sur. 2018).

Prosječni vremenski nizovi pokazuju tendenciju zagrijavanja površinske temperature mora i njenog 99. percentila (sl. 22, tablica 2). Iako i rezultati ERA5 reanaliza pokazuju slične trendove za Jadran, odgovarajući trendovi za sjeverni, srednji i južni dio jadranskog bazena kreću se između 0,04 i 0,06 °C godina^{-1}. Promatrani satelitski podaci pokazuju više trendove (medijan 0,05 °C godina^{-1}) u odnosu na ERA5 čiji medijan iznosi 0,04 °C godina^{-1}.

Sa slike 21 je vidljivo da satelitski podaci C3S-L4 pokazuju izraženu tendenciju zagrijavanja na južnom Jadranu, slično kao i ERA5 reanaliza gdje srednji Jadran ima najveći porast od 0,05 °C godina^{-1}. Takvo ponašanje može biti posljedica različitog broja točaka mreže, tj. utjecaja različitih vremenskih i prostornih koraka reanalize i satelitskih podataka (ERA5 ima satne podatke dok C3S-L4 ima dnevne vrijednosti). I ERA5 i C3S-L4 pokazuju da su ekstremni trendovi 99. percentila površinske temperature mora viši od trendova srednjih godišnjih vrijednosti za oko 0,02 °C godina^{-1} i da su najizraženiji na južnom dijelu Jadrana. To može ukazivati na povećani dotok tople sredozemne vode iz Jonskog mora kroz Otrantska vrata, kao što se može vidjeti na slici 21.

Trendovi 99. percentila površinske temperature mora za Jadran su viši od trendova 99. percentila SST-a Jonskog mora, što dovodi do zaključka da su rubna mora Sredozemlja najviše pogođena globalnim zatopljenjem (Nykjaer, 2009; Skliris i sur. 2012; Shaltout i Omstedt 2014). Jedan od mogućih utjecaja na veću površinsku temperaturu Jonskog mora je zonalna razlika u osunčanosti morske površine. Budući da je Jonsko more na nižim zemljopisnim širinama, osunčanost je jača. Svi trendovi pokazuju statističku značajnost veću od 95% razine pouzdanosti pomoću Mann-Kendalovog neparametarskog testa.

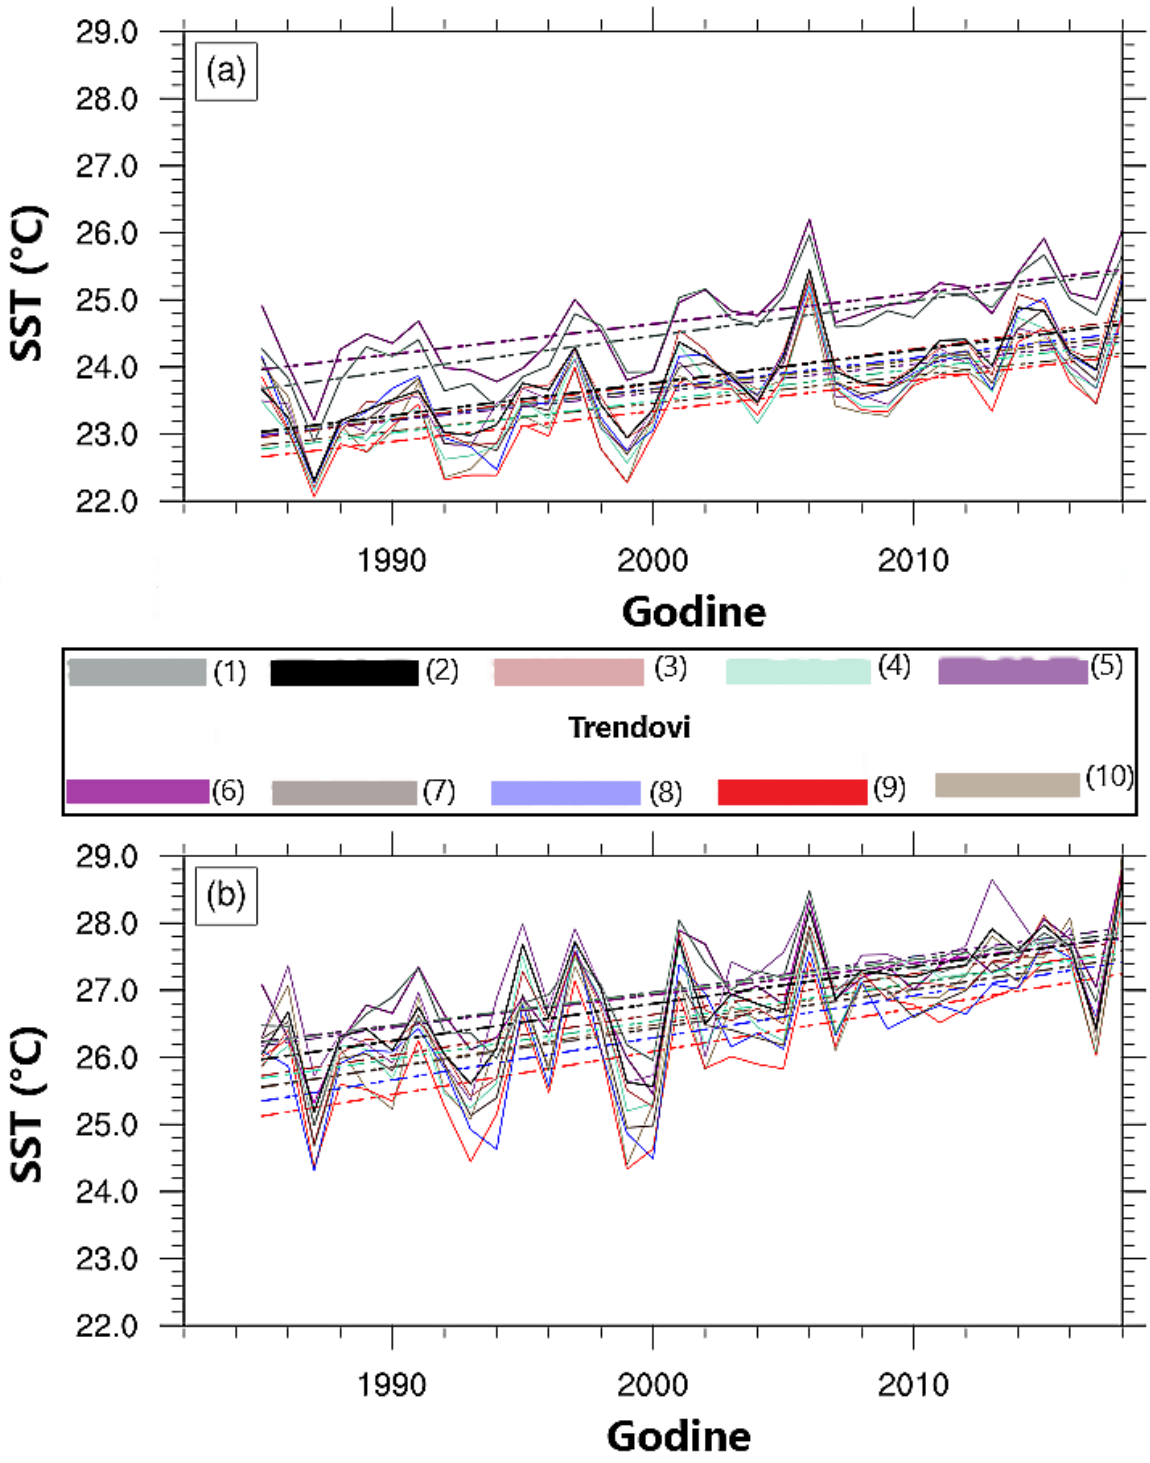


Slika 21. Srednjak površinske temperature mora (*SST*) za (a) ERA5 reanalizu i (b) C3S-L4 satelitske podatke te srednjak 99. percentila površinske temperature mora za (c) ERA5 reanalizu i (d) C3S-L4 satelitske podatke. Razdoblje je od 1982. do 2018. godine.

Prosječna površinska temperatura mora veća je na području Jonskog mora (24 - 26 °C) u odnosu na Jadran (22 - 25 °C), iako imaju slične trendove. To se slaže s radom Shaltouta i Omstedta (2014) koji su utvrdili da površinska temperatura Jonskog bazena ima najviši trend među svim sredozemnim bazenima (uključujući i Jadran). Površinska temperatura mora na Jadranu povećava se od istoka prema zapadu, zbog uspona hladnije vode (eng. *„upwelling"*) duž istočne obale (Bakun i Agostini 2001) i toplije vode duž zapadne obale. Hladne vode odlaze s hrvatske obale u srednjem Jadranu, vodeći se prema otvorenom moru i talijanskoj obali (sl. 21), što također primjećuju Borzelli i sur. (1999). Zbog ove pojave meridionalni gradijenti površinske temperature mora djelomično slabe pa je temperatura mora ljeti niža u srednjem Jadranu nego u sjevernom Jadrana. Kratko razdoblje površinskog hlađenja dogodilo se tijekom razdoblja od 1991. do 1995. godine (sl. 22), koje je izraženo i u Jadranskom i u Jonskom moru. To se može povezati s duljim zahlađenjem u atlantskom području zapadno od Gibraltara (Rixen i sur. 2005; Skliris i sur. 2012).

Tablica 2. Godišnji koeficijenti trendova površinske temperature mora (SST) i 99. percentila površinske temperature mora (SST_{99Q}). Koeficijenti trendova za cjelokupno Jadransko i Jonsko more su navedeni podebljanim slovima. Pomoću Mann-Kendalovog neparametarskog testa svi trendovi pokazuju značajnost veću od 95%.

		Površinska temperatura mora - SST (°C godina^{-1})		***99. percentil površinske temperature mora - SST_{99Q} (°C godina^{-1})***	
Područje		**C3S-L4**	**ERA5**	**C3S-L4**	**ERA5**
Jadran	Sjeverni	0,042	0,041	0,053	0,062
	Srednji	0,048	0,046	0,057	0,064
	Južni	0,053	0,046	0,061	0,063
JADRANSKO MORE		**0,049**	**0,044**	**0,055**	**0,058**
JONSKO MORE		**0,052**	**0,045**	**0,049**	**0,047**

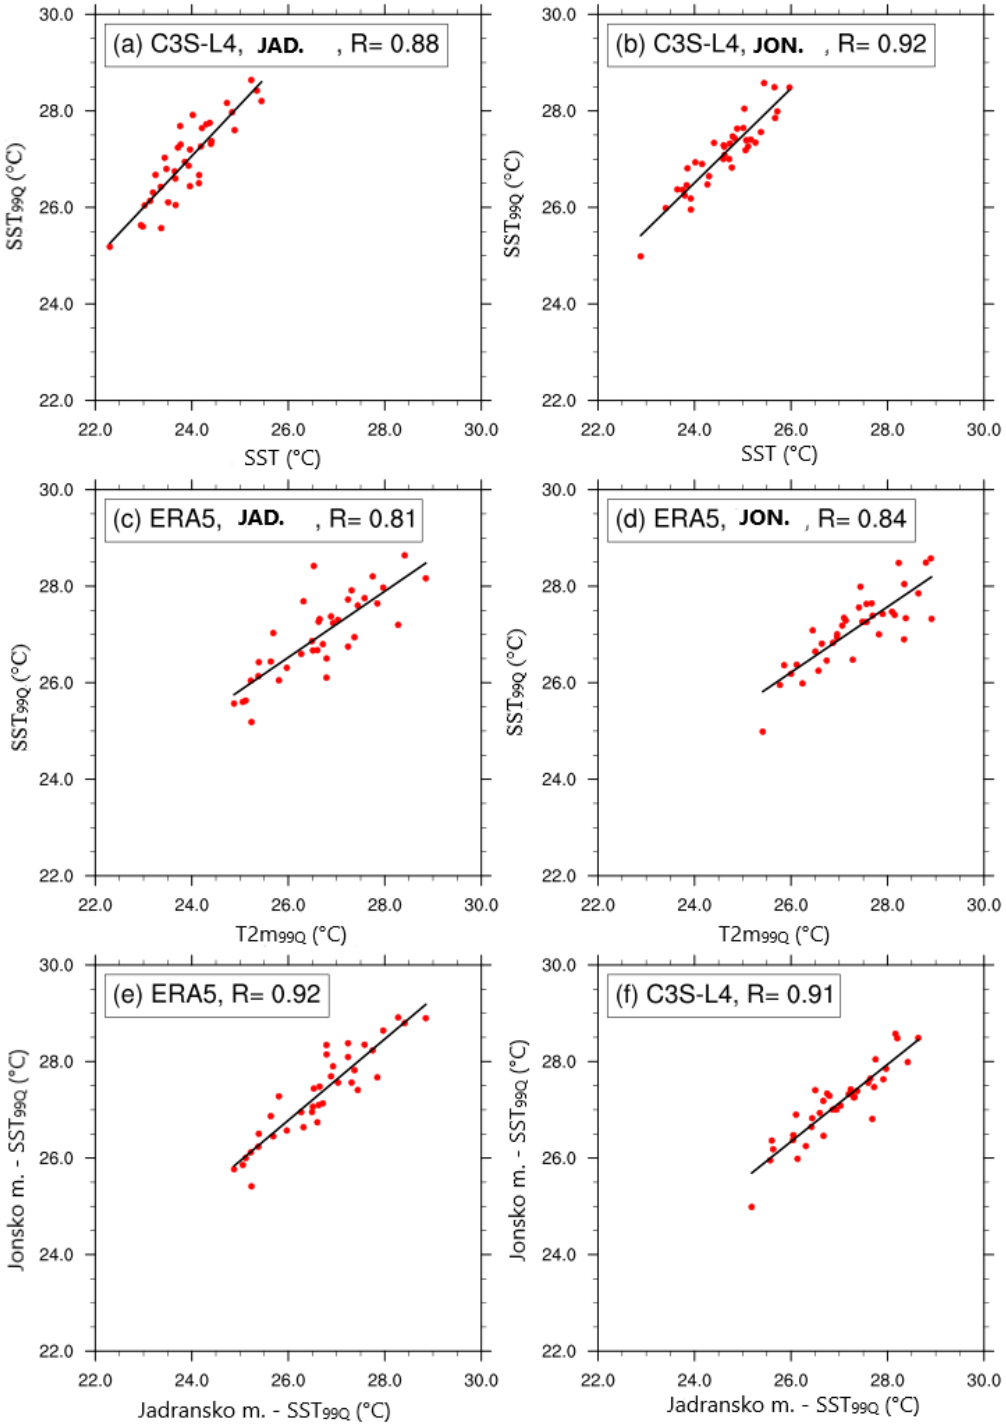


Slika 22. Vremenski nizovi prostorno usrednjene (a) površinske temperature mora (SST) i (b) 99. percentila površinske temperature mora (SST_{99Q}) za razdoblje od 1982. do 2018. godine. Punim linijama su prikazani vremenski nizovi dok su njihovi pripadajući trendovi prikazani isprekidanim linijama. Brojevi označavaju vremenske nizove: (1) C3S-L4 - cjelokupno Jonsko more, (2) C3S-L4 - cjelokupno Jadransko more, (3) C3S-L4 - južni Jadran, (4) C3S-L4 - srednji Jadran, (5) C3S-L4 - sjeverni Jadran, (6) ERA5 - cjelokupno Jonsko more, (7) ERA5 - cjelokupno Jadransko more, (8) ERA5 - južni Jadran, (9) ERA5 - srednji Jadran, (10) ERA5 - sjeverni Jadran.

Temperatura zraka ima značajan učinak na površinsku temperaturu mora u cijelom Jadranskom i Jonskom moru i u velikoj je korelaciji s površinskom temperaturom mora na Sredozemlju (Skliris i sur. 2012; Shaltout i Omstedt 2014).

Viši koeficijent korelacije između ekstrema površinske temperature mora i njenog 99. percentila ima Jonsko more (R = 0,92) za razliku od Jadrana (R = 0,88) dok i SST i SST_{99Q} slijede linearni trend (sl. 23a i 26b). Niža korelacija između površinske temperature mora i njenog 99. percentila na Jadranu može biti posljedica veće varijabilnosti temperature mora u plitkom dijelu sjevernog Jadrana, dok je na južnom Jadranu i Jonskom moru površinska temperatura mora mnogo ujednačenija (sl. 23). Slična situacija se uočava između 99. percentila temperature mora i 99. percentila temperature zraka (sl. 23). To sugerira da je varijabilnost površinske temperature mora kontrolirana neto protokom topline između atmosfere i mora te lokalnim oceanskim procesima što se slaže sa sličnim studijama (npr. Marotti 2010; Skliris i sur. 2012; Shaltout & Omstedt 2014).

Površinska temperatura mora je značajno korelirana s temperaturom zraka i nad Jadranom i nad Jonskim morem (sl. 23c i 26d) gdje su koeficijenti korelacije 0,81 i 0,84. Takav rezultat pokazuje relativno jaku povezanost između temperatura mora i zraka na sezonskim (godišnjim) vremenskim skalama. Ovakav rezultat je zanimljiv jer je neočekivana ovako visoka povezanost temperatura mora i zraka zbog primjerice miješanja površinskih voda s hladnijim vodama iz intermedijarnog sloja, obalnog uzdizanja („*upwelling*“) te utjecaja vjetra. Svaka buduća promjena u temperaturi zraka na Jadranu će se odraziti i na površinsku temperaturu mora na sezonskoj i godišnjoj skali, uzimajući u obzir mehanizme povezanosti između zraka i mora kao i prijenos topline između ova dva medija. Također je vidljivo da globalne klimatske promjene na Sredozemlju uvelike utječu i na porast temperature rubnih mora kao što je Jadran. To je vidljivo iz jako visoke korelacije između površinske temperature Jadranskog i Jonskog mora (R = 0,91 i R = 0,92) koje pokazuju satelitski podaci i reanaliza ERA5 (sl. 23e i 26f).



Slika 23. Raspršenost prostorno usrednjene, godišnje površinske temperature mora (SST), 99. percentila površinske temperature mora (SST_{99Q}) i 99. percentila temperature zraka na 2 metra ($T2m_{99Q}$) za: satelitske podatke (a, b, f) i ERA5 reanalizu (c d, e). (a) i (c) paneli pokazuju usporedbu između temperature mora i temperature zraka za Jadran, dok (b) i (d) predstavljaju jonsku regiju. Usporedba površinske temperature Jadranskog i Jonskog mora nalazi se na e) i f) grafikonima. Trendovi su označeni punim crtama, a R označava Pearsonov koeficijent korelacije.

4.2.2 Analiza toplinskih valova u moru u ljetnim sezonama (JJA) u razdoblju od 1982. do 2018.

Toplinski valovi u moru (MHW) u ljetnim sezonama nisu rijetki događaji kako na Sredozemlju tako i na jadranskom području. U razdoblju od 1982. do 2018. zabilježene su ukupno 23 epizode MHW-a (Tablica 3). Od ukupnog broja epizoda, kod 11 epizoda dnevna površinska temperatura mora je poprimala vrijednosti od minimalno 0,5 °C iznad praga 99. percentila što ih svrstava u ekstremne epizode. Od ovih 11 ekstremnih epizoda, 7 je zabilježeno u razdoblju od 2008. do 2018. godine. To pokazuje da su ekstremni toplinski valovi u moru češći u posljednjem desetljeću nego u svim prethodnim desetljećima. Većina ljetnih epizoda toplinskih valova u moru započinje u srpnju i završava početkom rujna, iako se neke ekstremne epizode (poput 2003. godine) čak počinju razvijati u lipnju.

Ljetne sezone za godine 2003. i 2015. su odabrane kao ljeta s najizraženijim toplinskim valovima u Jadranu u posljednja dva desetljeća. Toplinski val je 2003. godine započeo 22. srpnja, a završio 5. rujna. Istodobno, 2003. godine dogodio se atmosferski toplinski val koji je dosegao vrhunac u kolovozu u zapadnoj Europi (Francuska, Španjolska i Italija) i uzrokovao smrt gotovo 11 000 ljudi (Russo i sur. 2015; Muthers i sur. 2017; Lhotka i sur. 2018; Sousa i sur. 2018), dok je u SAD-u, Rusiji i Kini uzrokovao ozbiljne suše i utjecao na zdravlje ljudi (Guirguis i sur. 2018; Schaller i sur. 2018; Wang i sur. 2019). U 2015. godini zabilježen je i ljetni atmosferski toplinski val nad Srednjom Europom (Russo i sur. 2015; Darmaraki 2019c) koji je praćen toplinskim valom na Jadranu od 16. srpnja do 10. rujna. Smale i sur. (2019) navode da su razna područja u svjetskim oceanima posebno osjetljiva na povećanje temperature mora zbog istovremenog postojanja visoke razine biološke raznolikosti. Razlozi su toplinski valovi u moru. Iako su se fizikalna obilježja toplinskih valova u moru znatno razlikovala svi su imali štetne učinke na biološke procese i vrste (koralji, morske trave i kelpi). Posljedice toplinskih valova u moru mogu biti i nestajanje staništa koje uzrokuju dramatične promjene u strukturi ekosustava, jer podržavaju temeljne ekološke procese (Wernberg i sur. 2016).

Toplinski val u ljeto 2015. godine bio je duljeg trajanja i intenziteta u usporedbi s toplinskim valom iz 2003. godine, a više je utjecao na južni Jadran dok je MHW iz 2003. godine bio smješten na sjevernom dijelu Jadrana. Tijekom epizoda 2003. i 2015., izmjerena prosječna površinska temperatura mora iznosila je 23,6 °C i 24,2 °C, dok je prosječni 99. percentil

površinske temperature mora iznosio 26,8 °C, odnosno 27,4 °C. Za te iste ljetne sezone Russo i sur. (2015) pokazuju da su atmosferski toplinski valovi stvorili temperaturnu anomaliju od 4 °C do 6 °C u odnosu na klimatološki 30-godišnji prosjek koji je trajao između 9 i 18 dana. To ukazuje na moguće veze između atmosferskih i morskih toplinskih valova.

Tablica 3. Zabilježene i ekstremne epizode toplinskih valova u moru (MHW) za razdoblje od 1982. do 2018. godine. Crni kružić označava zabilježenu epizodu gdje dnevna površinska temperatura mora premašuje prag SST_{99Q} dulje od 5 uzastopnih dana. Ekstremne ljetne epizode su podebljane crnim slovima (dnevna površinska temperatura mora prekoračuje prag SST_{99Q} za minimalno 0,5 °C)

Godine	Zabilježena epizoda	Ekstremna epizoda
1982.		
1983.	●	
1984.		
1985.		
1986.		
1987.		
1988.	●	
1989.		
1990.		
1991.		
1992.	●	●
1993.		
1994.	●	●
1995.	●	
1996.		
1997.		
1998.	●	●
1999.	●	
2000.	●	
2001.	●	
2002.	●	
2003.	●	●
2004.	●	
2005.		
2006.	●	
2007.	●	
2008.	●	
2009.	●	●
2010.	●	●
2011.	●	●
2012.	●	●
2013.	●	
2014.		
2015.	●	●
2016.		
2017.	●	●
2018.	●	●
UKUPNO	**23**	**11**

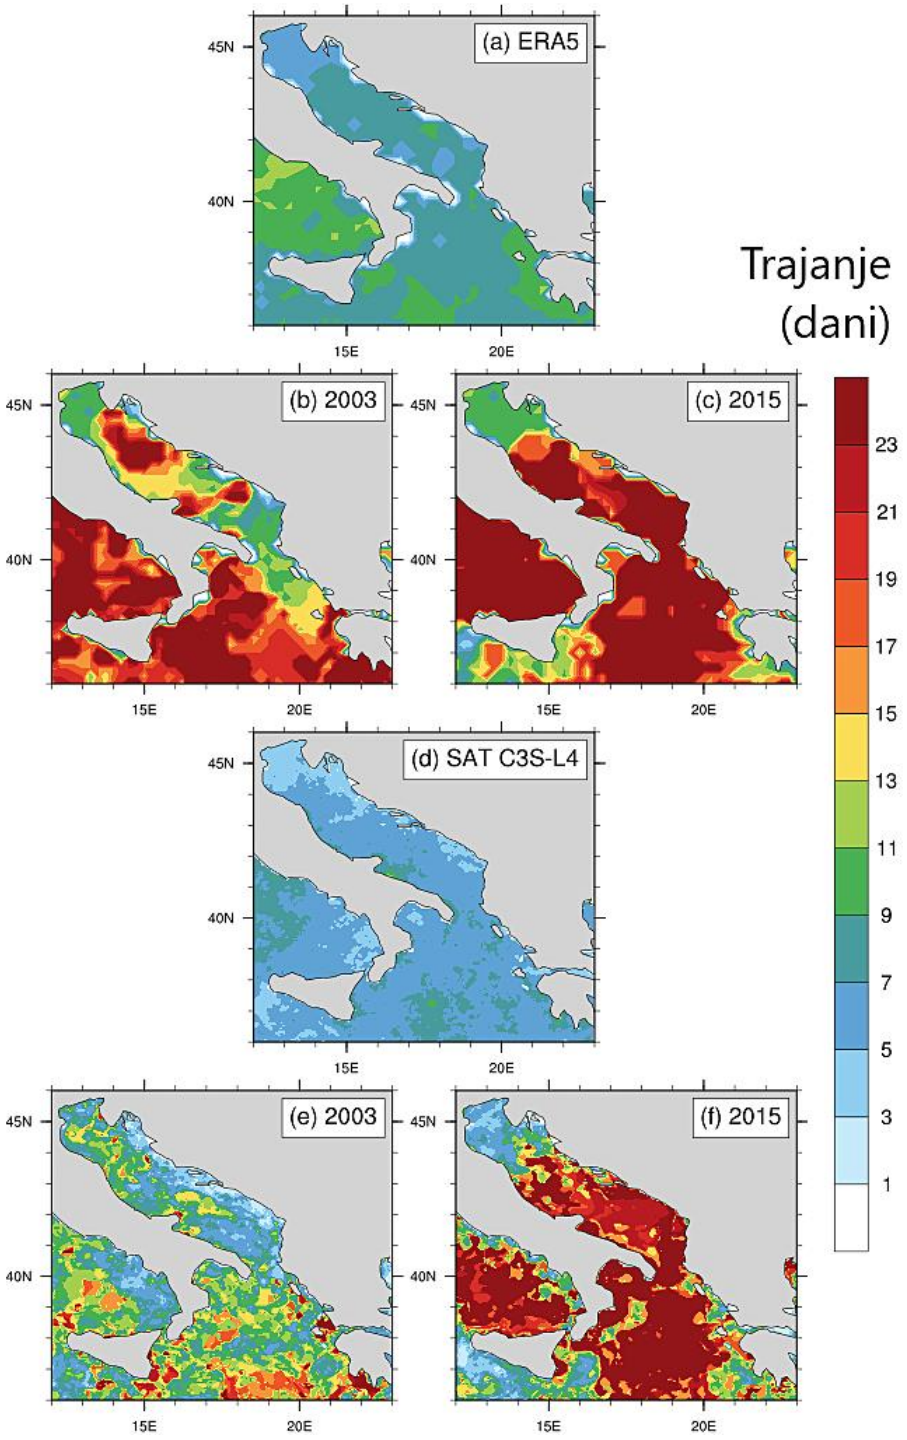
4.2.3 2003. i 2015. godina - ekstremne ljetne epizode toplinskih valova u Jadranu

Prosječno trajanje ljetnih toplinskih valova u Jadranu za razdoblje od 1982. do 2018. godine iznosi oko 6 - 7 dana (sl. 24). To su rezultati reanalize ERA5 i satelitskih podataka C3S-L4. Ljetna epizoda toplinskog vala iz 2003. godine izraženija je na sjevernom i srednjem dijelu Jadrana s maksimalnim trajanjem između 14 i 23 dana. Toplinski val iz 2015. godine široko je rasprostranjen po srednjem i južnom Jadranu, a posebno Jonskom moru. Prosječno trajanje ovih epizoda je duže od 20 dana. To pokazuje da prosječna ljetna površinska temperatura mora u 2015. godini viša nego 2003. godine, što također dokazuju Darmaraki i sur. (2019b) za cijelo područje Sredozemlja.

Srednji intenzitet toplinskih valova (I_{mean}) na Jadranu izračunava se kao prekoračenje praga 99. percentila površinske temperature mora (sl. 25) kako su predložili Hobday i sur. (2016) i Darmaraki i sur. (2019a). I reanaliza ERA5 i satelitski podaci C3S-L4 pokazuju da je srednji intenzitet za cijelo razdoblje oko 0,04 °C (znači temperatura za 0,04 °C veća od 99. percentila). To je mnogo manje u usporedbi s 2003. i 2015. ljetnim sezonama gdje se intenzitet toplinskog vala kretao od 0,16 °C do 0,4 °C za 2003., odnosno od 0,24 °C do 0,6 °C za 2015. godinu.

Visoke anomalije površinske temperature mora (srednji intenzitet MHW-a) kod epizode vala iz ljetne sezone 2003. lokalizirane su na sjevernom Jadranu gdje poprimaju vrijednosti od 0,45 °C dok u priobalnom djelu zapadnog Jadrana (kod Monte Gargana, Italija) iznose 0,56 °C (sl. 25b 28e). Darmaraki (2019c) navodi da je ova epizoda uzrokovala promjenu u sloju miješanja gdje se njegova dubina promijenila s 11 m na početku ljetne epizode na 15 m krajem ljetne epizode.

Srednji intenzitet epizode toplinskog vala iz 2015. godine, koji zahvaća u cijelosti srednji i južni Jadran te većim djelom Jonsko more, iznosi 0,62 °C (sl. 25c i 28f). Ovaj toplinski val posljedica je utjecaja površinske temperature mora Sredozemlja koje onda advekcijom ulaze kroz Otrantska vrata u Jadran. U prilog tome ide već spomenuta visoka korelacija između površinskih temperatura Jadranskog i Jonskog mora.

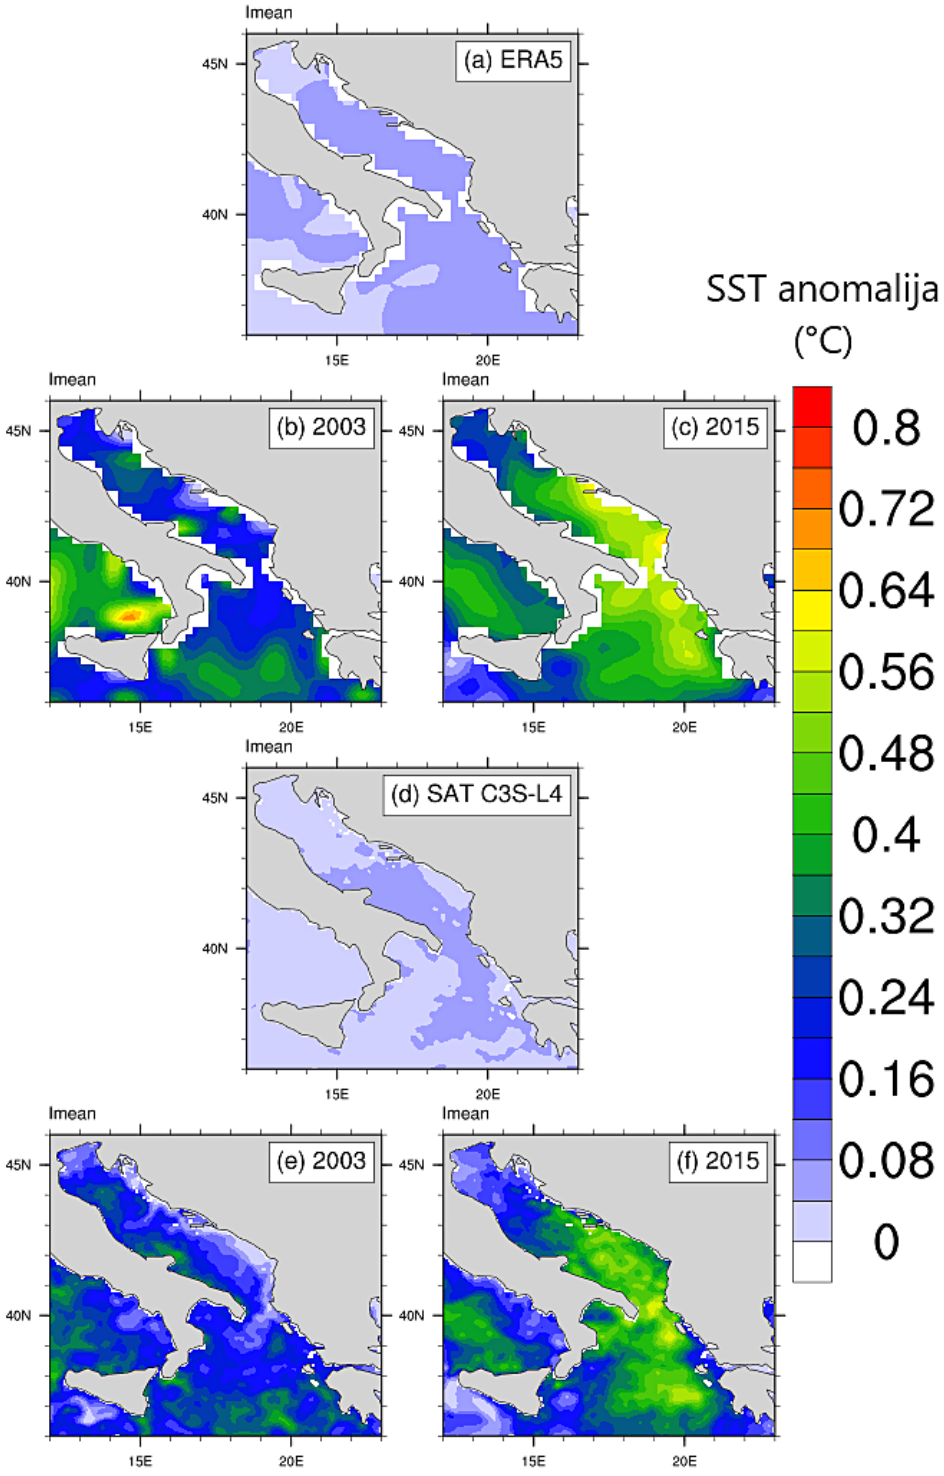


Slika 24. Prosječno trajanje epizoda toplinskih valova u Jadranu (MHW) za razdoblje od 1982. do 2018. godine. Grafikoni (a) i (d) prikazuju cjelokupno razdoblje 1982. - 2018. dok (b), (c) i (e), (f) prikazuju ljetne sezone 2003. i 2015. s ekstremnim temperaturnim anomalijama kod epizoda toplinskih valova.

Kod analize ponašanja i povećanja pojava ekstremnih epizoda toplinskih valova u Jadranu izračunati su trendovi učestalosti epizoda toplinskih valova kada su bile prisutne epizode od 5, 10, 15 ili 20 ekstremno toplih dana (sl. 26). Ti dani su u nizovima od 5, 10, 15 ili 20 dana kad prosječna dnevna površinska temperatura mora prelazi prag 99. percentila. Slika 26 pokazuje kako se učestalost epizoda toplinskih valova mijenja tijekom razdoblja od 1982. do 2018. godine. Iako su trendovi vrlo niski, 5-dnevne epizode povećavaju učestalost za 0,01 do 0,02 događaja godišnje (sl. 26a i 29b). Koeficijenti trenda smanjuju se s povećanjem trajanja epizoda, gdje su najveći trendovi za 5-dnevne epizode, a gotovo zanemarivi (i statistički nisu značajni po Mann-Kendalovom testu) za 20-dnevne epizode (sl. 26g i 29h). To znači da na jadranskom području, u razdoblju između 1982. i 2018. godine, uglavnom prevladavaju epizode ljetnih toplinskih valova u moru koje traju između 5 i 10 dana što u prosjeku iznosi od 6 do 7 dana (sl. 24). ERA5 pokazuje sličnu učestalost epizoda toplinskih valova u Jadranu kao i satelitski podaci.

Razlozi za pojavu toplinskih valova u Jadranu (i Sredozemlju) mogu se pripisati atmosferskom utjecaju te razmjeni topline između mora i zraka a koji su posljedica međudjelovanja površinske temperature mora i zraka. Skliris i sur. (2012) i Shaltout i Omstedt (2014) tvrde da različite komponente toplinskog toka ukazuju na to da toplinski valovi na Sredozemlju mogu biti u korelaciji s temperaturom zraka na 2 metra (T2m), površinskim tokom osjetilne topline (SSHF), ukupnim dugovalnim zračenjem i površinskim tokom latentne topline (SLHF). Dok Skliris i sur. (2012) navode da latentni toplinski tok više objašnjava površinsku temperaturu Sredozemnog mora u usporedbi s ostalim komponentama razmjene topline između mora i zraka, Shaltout i Omstedt (2014) napominju da su sve ove komponente značajne za objašnjenje strukture i razvoja površinske temperature mora, a time i toplinskih valova u moru.

Christidis i sur. (2014) sugeriraju da će vjerojatnost pojave atmosferskih i morskih utjecaja koji pridonose ekstremnim toplinskim valovima, poput ljeta 2003. godine, u budućnosti biti sve veća. Također, uvjeti poput odsutnosti naoblake (a posljedično i oborina) mogu pojačati toplinske valove kako na Jadranu tako i na Sredozemnom moru (sl. 27g i 30h). Dodatni atmosferski utjecaji, koji su pridonijeli toplinskom valu na moru tijekom ljetne sezone 2003. godine, su tropske temperaturne anomalije na Atlantiku u obliku vlažnijih od prosjeka uvjeta u istočnom dijelu Atlantika i snažne pozitivne faze oscilacije istočnog



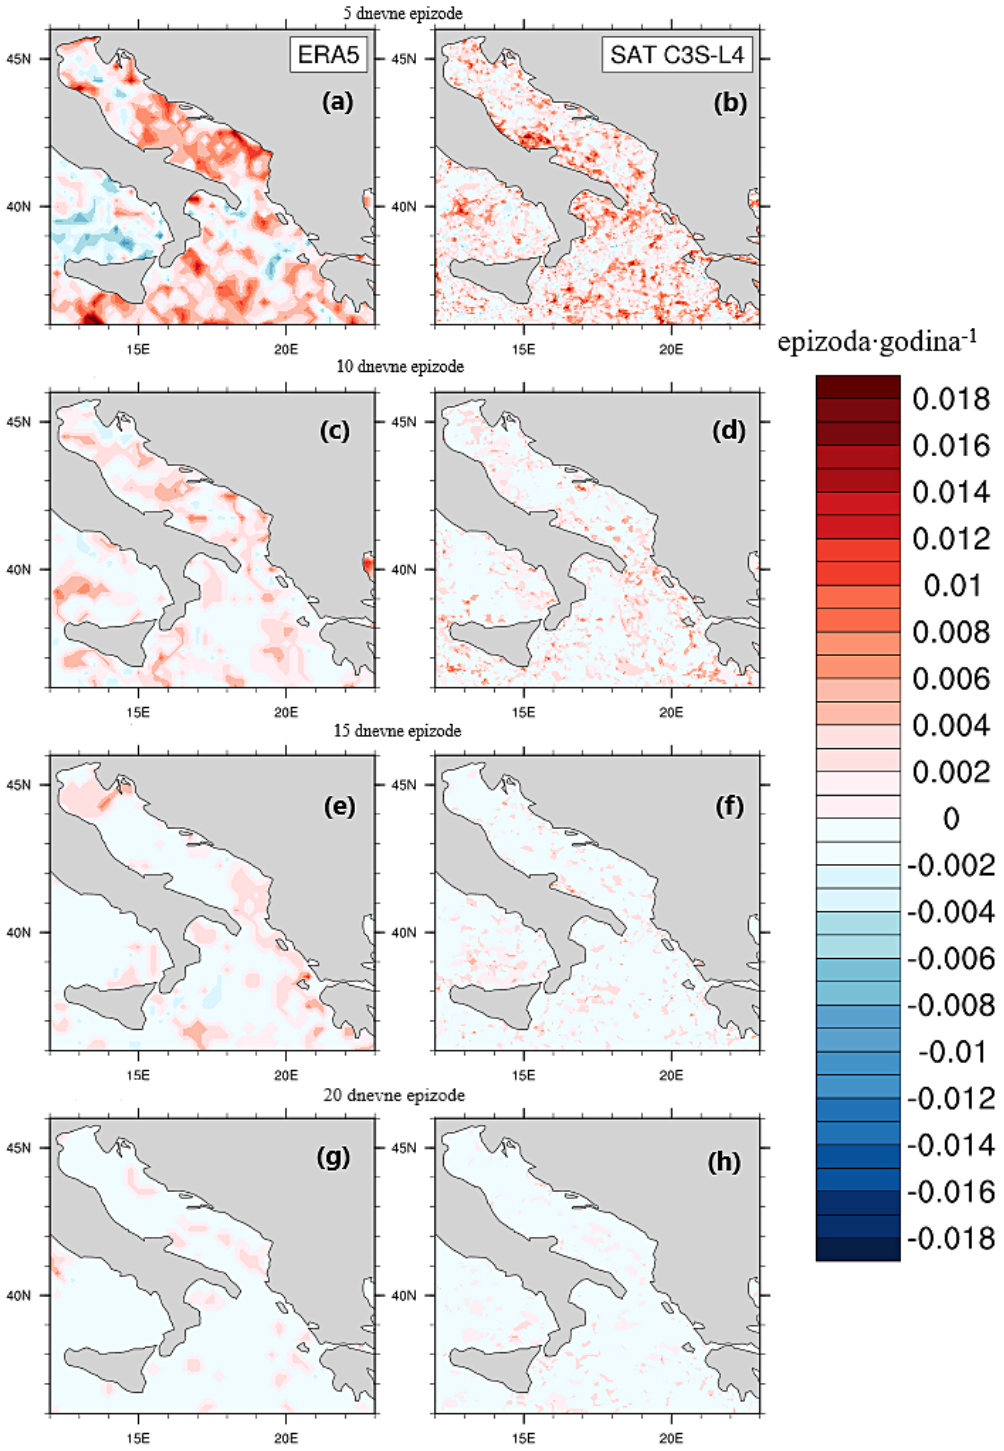
Slika 25. Intenzitet toplinskih valova u Jadranu (I_{mean}) za razdoblje od 1982. do 2018. godine. Intenzitet se prikazuje kao anomalija površinske temperature mora u odnosu na 99. percentil. Grafikoni (a) i (d) prikazuju cjelokupno razdoblje 1982. - 2018. dok (b), (c) i (e), (f) prikazuju ljetne sezone 2003. i 2015. s ekstremnim temperaturnim anomalijama kod epizoda toplinskih valova.

Atlantika (*EA – „East Atlantic“*; García-Herrera i sur. 2010). Moguć je i suprotan utjecaj oceana na atmosferu gdje postoje produljene visoke površinske temperature mora u sjevernom Atlantiku i na Sredozemlju.

Korelacija površinske temperature mora i različitih atmosferskih parametara iznad same površine mora (T2m, WS) te parametara pri površini (SLHF, SSHF; sl. 27) ukazuje na to da se toplinski valovi u Jadranu iz ljetnih sezona 2003. i 2015. godine uglavnom mogu povezati s temperaturom zraka (koeficijenti korelacije veći od 0,8; sl. 27a i 30b) te površinskim tokovima latentne (SLHF) i osjetne (SSHF) topline.

U 2003. godini koeficijent korelacije između površinske temperature mora i SSHF je od 0,2 do 0,5 (sl. 27e), što je više od koeficijenta korelacije između površinske temperature mora i SLHF (sl. 27c). U 2015. godini je prisutna suprotna situacija kada površinska temperatura mora i SLHF imaju koeficijente korelacije od 0,2 do 0,5 (sl. 27d). Također, zanimljivo je uočiti da, kod toplinskog vala iz ljeta 2003. godine, pozitivna korelacija između površinske temperature mora i SSHF prevladava na cijelom Jadranu dok je pozitivna korelacija između površinske temperature i SLHF lokalizirana na plitkom dijelu sjevernog Jadrana. U 2015. godini situacija je obrnuta gdje je površinska temperatura mora više pod utjecajem SLHF (sl. 27d). To dovodi do zaključka da je sjeverni Jadran, ljeti, zbog svoje plitke batimetrije uvelike pod utjecajem površinskih tokova topline dok je na južnom Jadranu značajan i utjecaj ostalih komponenata mehanizma međudjelovanja između zraka i mora.

Korelacija se povećava od južnog prema sjevernom Jadranu, što može značiti da je, za razliku od plitkog dijela sjevernog Jadrana, južni dio koji je i mnogo dublji te samim time i pod mnogo većim utjecajem dubokih voda iz Jonskog mora. U ljeto 2003. morska je površina primila veliku količinu topline koja je koncentrirana u blizini površine zbog slabog vjetra i smanjenog vertikalnog miješanja (Grbec i sur. 2007). Jadran može zadržati temperaturu dubokog sloja konstantnom tijekom nekoliko godina pa utjecaj na površinu i promjene temperature na površini možda neće biti vidljive iste godine, već u sljedećim godinama.

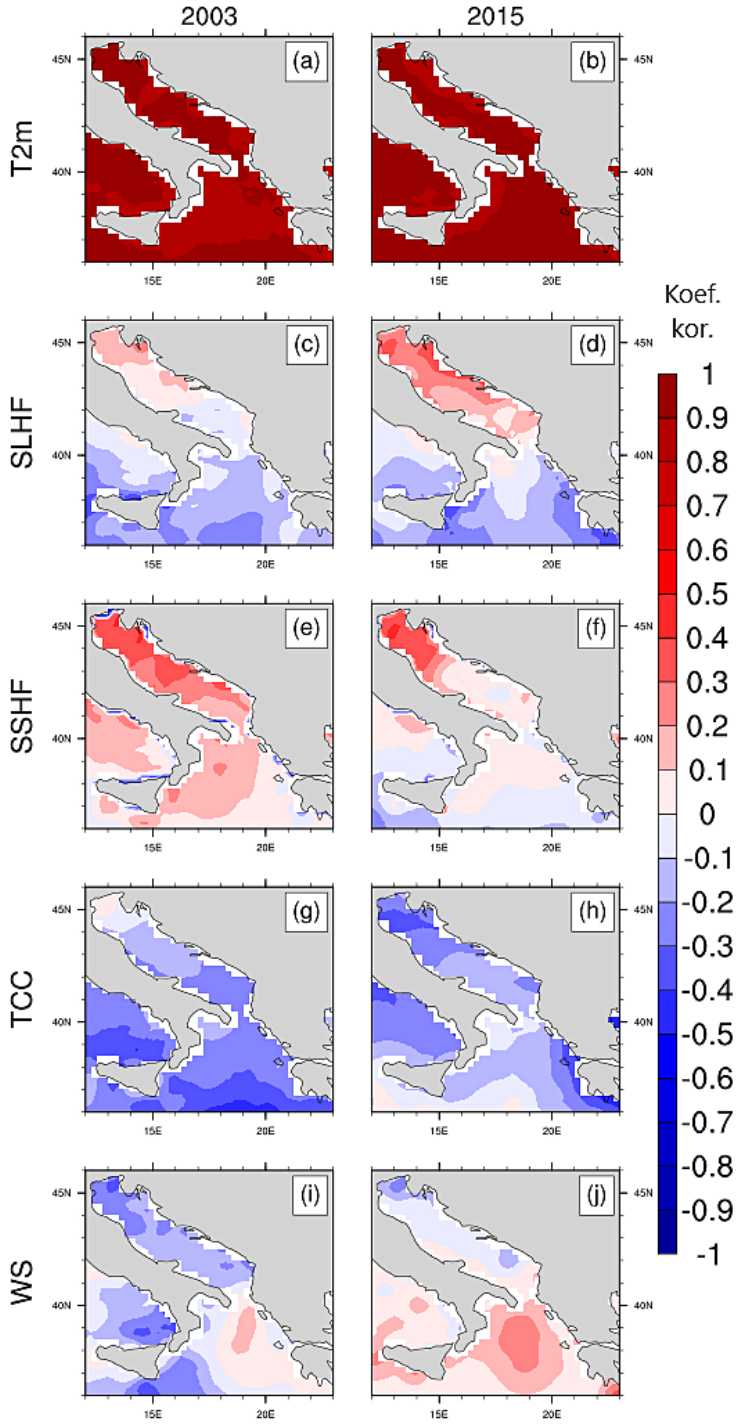


Slika 26. Učestalost 5-dnevnih, 10-dnevnih, 15-dnevnih i 20-dnevnih epizoda toplinskih valova u Jadranu u razdoblju od 1982. do 2018. godine. Učestalost epizoda iz rezultata ERA5 reanalize se nalaze na grafikonima (a), (c), (e) i (g) a iz C3S-L4 satelitskih podataka na grafikonima (b), (d), (f) i (h).

Vilibić i Orlić (2002) procijenili su vrijeme zadržavanja duboke jadranske vode na oko 2 - 3 godine. Jadransko more reagira na atmosfersko forsiranje, dok su razlike uvedene prostornom nehomogenošću bure i razmjene otvorenih i obalnih voda od sekundarne važnosti u stvaranju anomalija površinske temperature mora na istočnom Jadranu (Grbec i sur. 2018). Na to ukazuje i slika 30i i 30j gdje je koeficijent korelacije između površinske temperature mora i napetosti vjetra (WS) na Jadranu u 2003. godini koji je između -0,1 i -0,4, a u 2015. je beznačajan. To znači da je utjecaj vjetra na morsku površinu bio slab tijekom ljetnog toplinskog vala 2003. godine. Toplinski val je utjecao na sjeverni dio Jadrana više nego na južni dio zbog varijacija grijanja u odnosu na batimetriju i režim vjetra.

U epizodi MHW iz 2015. godine, visoki negativni koeficijenti korelacije ukupne naoblake (TCC) za sjeverni Jadran (između -0,3 i -0,5; sl. 27h, 30f i 30d) odgovaraju pozitivnim površinskim osjetnim i latentnim toplinskim tokovima što pokazuje da more pokušava osloboditi energiju u atmosferu i nakon toga se ohladiti. Ova je situacija posebno značajna za sjeverni Jadran gdje smanjena naoblaka povećava kratkovalno zračenje i uzrokuje zatopljenje mora.

Black i sur. (2004) sugeriraju da je anomalija latentnog toplinskog toka iz 2003 (izračunata kao odstupanje od 40-godišnje klimatologije reanaliza) u početku bila pozitivna, a zatim je poprimila negativnu vrijednost i postajala sve izraženija. To ukazuje na pojavu suše pri tlu tijekom ljeta, dok je anomalija osjetnog toplinskog toka ostala pozitivna i ujedno povećana zbog porasta površinske temperature mora. Negativna korelacija površinskog toka latentne topline s površinskom temperaturom Jadrana u ljetnim mjesecima (sl. 27e) sugerira da atmosfera uvelike zagrijava površinu Jonskog mora pa posljedično i Jadran kroz Otrantska vrata.



Slika 27. Korelacija između površinske temperature mora (SST) i: temperature zraka na 2 metra (a), (b); površinskog toka latentne temperature (c), (d); površinskog toka osjetne topline (e), (f); ukupne naoblake (g), (h); napetosti vjetra (i), (j) za epizode ljetnih toplinskih valova u Jadranu 2003. (lijevo) i 2015. godine (desno).

5. ZAKLJUČAK

Ovaj rad prikazuje analizu promjenjivosti temperature zraka i mora te njihovih trendova na istočnoj obali Jadrana. Zbog porasta temperature zraka i mora te globalnog zatopljenja sve češće dolazi do pojave fenomena koji su posljedica takvih promjena, a to su toplinski valovi u Jadranu. Temperatura zraka je analizirana pomoću izmjerenih podataka na postajama, produkta E-OBS, tri reanalize UERRA i seta od osam regionalnih klimatskih modela EURO-CORDEX baze rezultata regionalnih klimatskih modela. Simulacije modela detaljno su istražene pomoću osnovnih statističkih metoda (korijen srednje kvadratne pogreške, razlika u trendu između mjerenja/E-OBS i rezultata modela, korelacija, standardna devijacija) te je napravljena analiza sezonskih i mjesečnih vrijednosti.

Toplinski valovi u Jadranu analizirani su pomoću podataka površinske temperature mora relativno nove reanalize visoke razlučivosti ERA5 i satelitskih podataka C3S-L4. Metoda detekcije toplinskih valova u Jadranu, koja se temelji na površinskoj temperaturi mora, primijenjena je na cijelom području Jadrana i Jonskog mora. Uz to, detaljna analiza je napravljena za dvije istaknute epizode ljetnih toplinskih valova u Jadranu koje su se dogodile 2003. i 2015. godini. Metoda koristi klimatološki prag od 99. percentila na temelju 30-godišnjeg razdoblja od 1982. do 2012. i uvažava temperaturni prag koji varira u prostoru. Uz statističke metode kao što su učestalost pojave, trajanje i srednji intenzitet, dodatno je uključena i analiza međudjelovanja između zraka i mora kao jednog od važnih pokretačkih mehanizama toplinskih valova u moru. Poseban fokus stavljen je na korelaciju površinske temperature mora s različitim atmosferskim parametrima: temperaturom zraka, površinskim tokovima osjetne i latentne topline, ukupnom naoblakom i silom vjetra.

Kod evaluacijskih simulacija (1989. - 2008.), regionalni modeli su reproducirali uzorke temperature zraka s dovoljnom točnošću (korijen srednje kvadratne pogreške iznosi od 0,8 °C do 1,5 °C) što je posljedica korištenja početnih i rubnih uvjeta iz reanalize. Međutim, kod povijesnih simulacija (1961. – 2005.) koje koriste početne i rubne uvjete uzete iz globalnih modela, korijen srednje kvadratne pogreške je veći od 1,75 °C. Rezultati ukazuju da početni i rubni uvjeti imaju dominantan utjecaj na rezultate regionalnih modela. Naime, različiti regionalni modeli čiji su rubni i početni uvjeti preuzeti iz istog globalnog modela pokazuju slične obrasce

ponašanja i točnost. Unatoč nekim iznimkama (REMO2009 i RegCM4-2), ansambli kod obje vrste simulacija pokazuju poboljšanja od 15% do 20% u odnosu na pojedinačne modele. Reanalize UERRA slijede obrasce ponašanja izmjerenih temperatura zraka u evaluacijskom i povijesnom razdoblju.

Karakterizacija trendova temperature zraka je puno teža od reproduciranja strukture temperature zraka korištenjem regionalnih modela i reanaliza. Na temelju staničnih mjerenja, najveća razlika u trendu izmjerene temperature zraka u povijesnom razdoblju iznosi 0,12 °C desetljeće^{-1}. Vidljivo je i značajno precjenjivanje trendova od strane reanalize MESCAN koje zahtijeva daljnju procjenu. Svi rezultati regionalnih klimatskih modela su u širem rasponu od 0,37 °C desetljeće^{-1}, dok raspon ansambla pokazuje da se oba ansambla (povijesni i evaluacijski) nalaze u gornjem dijelu ljestvice rangiranja izmjerenih trendova (razlika trenda od 0,02 °C desetljeće^{-1}). Točnost simuliranih vrijednosti temperature u odnosu na izmjerene vrijednosti ovisi položaju same postaje. Naime, regionalni modeli reproduciraju s manjom točnošću temperaturna obilježja na položajima postaja na sjevernom dijelu Jadrana zbog jake sezonske varijabilnosti režima vjetra i pliće batimetrije od onih u južnom dijelu (Orlić i sur. 1992.). Jedno od mogućih objašnjenja ovakvog rezultata je da u području pliće batimetrije dolazi do bržeg zagrijavanja i hlađenja morske površine, a time i stvaranja većih razlika u temperaturi zraka.

Grafikoni rangiranja apsolutnih razlika u trendu naspram korijena srednje kvadratne pogreške na položajima postaja i prostorno (usporedno s produktom E-OBS) prikazuju odvojene skupine regionalnih modela za povijesne i evaluacijske rezultate simulacija. Sve tri reanalize UERRA pokazuju najmanju promjenjivost (tj. imaju najmanji korijen srednje kvadratne pogreške), ali zato imaju slične razlike u trendovima kao regionalni modeli bilo da se analizira na položajima postaja ili prostorno u usporedbi s produktom E-OBS. Prostorna usporedba trendova između reanaliza UERRA i produkta E-OBS pokazuje mjestimično široka područja povećanih ili smanjenih razlika u trendovima. Razlike mogu biti uzrokovane nedostatkom mjernih postaja na istočnoj obali Jadrana te unutrašnjosti Balkanskog poluotoka, razlikama u osnovnim modelima koji se koriste u reanalizama UERRA te različitim shemama asimilacije podataka. Usporedba mjerenja i reanaliza UERRA može također biti otežana pogreškama u samim mjerenjima i raznim specifičnostima mikrolokacija na kojima se nalaze mjerne postaje. Rezultati ovog istraživanja su u skladu sa zaključcima Thornea i Vosae (2010) koji navode potrebu za

kreiranjem dviju vrsta reanaliza: one koja zadržava dugotrajnu točnost i one koja daje najbolju trenutnu procjenu jer samo jedna vrsta reanaliza ne može zadovoljiti različite svrhe.

Na promjenjivost površinske temperature Sredozemnog mora utječe kombinacija atmosferskih i oceanskih procesa, ali se pokazuje značajne regionalne razlike. Kod analize ljetnih sezona od 1982. do 2018. godine, satelitski podaci C3S-L4 za površinsku temperaturu Jadranskog i Jonskog mora ukazuju na srednje ljetne temperature mora između 22 °C i 26 °C, dok maksimalne vrijednosti dosežu i 29 °C. Ljeta s ekstremnim vrijednostima površinske temperature mora podudaraju se s epizodama toplinskih valova u Jadranu u posljednjih nekoliko desetljeća, a najistaknutije su epizode 2003. i 2015. godine. Površinska temperatura Jonskog mora (24 °C - 26 °C) veća je od površinske temperature Jadranskog mora (22 °C - 25 °C) za 2 °C do 3 °C u prosjeku, ali trendovi su slični što ukazuje na učinak globalnog zatopljenja nad cijelim Sredozemljem.

Površinska temperatura Jadranskog i Jonskog mora se značajno povećavala (za 0,05 °C godina^{-1}), dok maksimalna vrijednost trendova ekstremnih vrijednosti površinske temperature mora južnog Jadrana iznosi 0,06 °C godina^{-1}. Sezonski regionalni trendovi zagrijavanja mora konzistentni su s prethodnim studijama Nykjaer (2009), Skliris i sur. (2012) te Shaltout i Omstedt (2014). Jaka korelacija postoji između površinske temperature Jadranskog i Jonskog mora (satelitski podaci C3S-L4 pokazuju koeficijent korelacije 0,91, a ERA5 pokazuje koeficijent 0,92), što znači da je Jadran pod velikim utjecajem Sredozemnog mora kroz Otrantska vrata. Također, koeficijenti korelacije između 99. percentila površinske temperature mora i temperature zraka (T2m) su veliki i za Jadransko (0,81) i Jonsko more (0,84). Zbog te će se velike povezanosti svaka buduća promjena u temperaturi zraka na Jadranu, na sezonskim i godišnjim skalama, odraziti i na površinsku temperaturu mora.

Prosječno trajanje ljetnih toplinskih valova u Jadranu u razdoblju od 1982. do 2018. godine je oko 6 do 7 dana. Najistaknutije epizode toplinskih valova u Jadranu u posljednja dva desetljeća su se dogodile 2003. i 2015 godine. Epizoda iz 2015. godine prisutna je na srednjem i južnom Jadranu te Jonskom moru s prosječnim trajanjem većim od 20 dana, dok je epizoda iz 2003. lokalizirana na sjevernom i srednjem Jadranu, s maksimalnim trajanjem između 14 i 23 dana. Na temelju reanaliza i satelitskih podataka, srednji intenzitet epizoda toplinskih valova u Jadranu u razdoblju od 1982. do 2018. iznosi 0,04 °C. Ukupni intenzitet je niži u usporedbi s najznačajnijim epizodama 2003. i 2015. godine za koje su srednji intenziteti između 0,16 °C –

0,40 °C i 0,24 °C – 0,60 °C. Trend učestalosti pojavljivanja je u porastu za 0,01 – 0,02 događaja godišnje za 5-dnevne epizode. S povećanjem trajanja epizoda toplinskih valova, koeficijenti trenda se smanjuju što ukazuje da se učestalost kratkotrajnih epizoda toplinskih valova povećavala u razdoblju od 1982. do 2018. godine.

Korelacija površinske temperature mora u odnosu na temperaturu zraka (T2m), ukupnu oblačnost (TCC), napetost vjetra (WS) i površinske tokove latentne i osjetne topline (SLHF, SSHF) ukazuje na to da se ljetni toplinski valovi iz 2003. i 2015. mogu u velikoj mjeri povezati s temperaturom zraka (koeficijenti korelacije veći su od 0,8 u cijeloj jadranskoj regiji). Kao sekundarni učinak, epizoda iz 2003. može se povezati s površinskim tokom osjetne topline (koeficijent korelacije s temperaturom mora između 0,2 i 0,5) što može značiti da toplinski procesi dominiraju u procesima međudjelovanja zraka i mora, dok je epizoda iz 2015. više povezana s vlažnim procesima kod kojih je površinski tok latentne topline u pozitivnoj korelaciji s površinskom temperaturom mora (0,2 – 0,5). To se može povezati sa suhom advekcijom zraka iznad Jadrana. Slaba je korelacija između napetosti vjetra i površinske temperature mora tijekom ljetne epizode 2015., no 2003. negativni koeficijenti (između -0,4 i -0,1) na Jadranu sugeriraju da slabije brzine vjetra, u područjima gdje prevladava topla površinska voda, smanjuju tok latentne topline. Zbog toga se povećava površinska temperatura mora čime se sprječava stvaranje konvektivnih oblaka (koeficijenti korelacije između temperature mora i ukupne naoblake su između -0,3 i -0,5). Primjetna korelacija između površinske temperature Jadrana i ukupne naoblake slaže se s studijom Brierley i Fedorov (2010) koji imaju slična otkrića za otvoreni ocean koja su dobili korištenjem modela opće atmosferske cirkulacije s horizontalnom razlučivošću od 1 stupnja. Osim toga, jadranski i jonski trendovi povećavanja površinske temperature mora slijede negativni trend gubitka topline kroz površinu mora prema Sklirisu i sur. (2012) za Sredozemno more u razdoblju od 1985. do 2008. godine. Uzimajući u obzir analizirani porast trendova srednje i ekstremne temperature mora, vjerojatno će se učestalost pojavljivanja i intenzitet epizoda toplinskih valova u Jadranu povećavati i u budućnosti. To je pogotovo značajno za vremenski kratke epizode od 5 dana koje su se povećale za 0,18 događaja po desetljeću u posljednjih 37 godina, dok su se u istom razdoblju ekstremi površinske temperature mora i njenog 99. percentila povećali za 0,6 °C desetljeće^{-1}.

Ovaj rad može biti o velike pomoći budući da donosi potrebu za daljnjom evaluacijom različitih vrsta reanaliza i regionalnih modela s različitim prostornim i vremenskim karakteristikama.

Potrebno je istražiti razloge za razlike među regionalnim modelima i reanalizama u vidu različitih razlučivosti i raznih početnih i rubnih uvjeta iz globalnih modela. Jedna od glavnih stavki je istražiti kako parametrizacije regionalnih klimatskih modela, uključujući površinske procese, hidrologiju i omjer kopna i mora utječu na promjenjivost temperature zraka u obalnim područjima. Također, znanstvena zajednica posljednjih godina istražuje utjecaj aerosola (posebice SO_2) na zagrijavanje zraka i mora (Nabat i sur. 2014, 2015a, 2015b) gdje su pokazali da se dio zagrijavanja na području Sredozemlja može jedino simulirati modelima koji uključuju smanjenje aerosola SO_2. U suprotnom dolazi do podcjenjivanja površinskog zračenja i temperaturnih trendova. Kao posljedicu globalnog zatopljenja, uz temperaturu zraka, potrebno je dodatno istražiti i druge epizode toplinskih valova u Jadranu (uključujući dugoročne i kratkoročne učinke istih) te atmosferske i oceanografske mehanizme povezane s toplinskim valovima u moru. Javlja se potreba da se istraže mogućnosti regionalnih združenih atmosfersko-oceanskih modela s ciljem predviđanja toplinskih valova u rubnim morima (kao što je Jadran). Ovo istraživanje potvrđuje potrebu identifikacije područja pogodnih za razvoj ovih ekstremnih fenomena jer oni imaju velik utjecaj na morske ekosustave.

6. LITERATURA

Artegiani, A., Bregant, D., Paschini, E., Pinardi, N., Raicich, F., & Russo, A. (1997a). The Adriatic Sea general circulation - Part 1 - Air-sea interactions and water mass structure. *Journal of Phys. Oceanography* **(27)**, 1492-1514.

Bakun, A., & Agostini, A. (2001). Seasonal pattern of wind induced upwelling/downwelling in the Mediterranean Sea. *Sci. Mar.*, 243-257. doi:10.1016/j.pocean.2009.04.011

Baldauf, M., & Schulz, J. P. (2004). Prognostic precipitation in the Local Modell (LM) of DWD. *COSMO Newsletter* **(4)**, str. 177–180.

Bergant, K., Belda, M., & Halenka, T. (2007). Systematic errors in the simulation of European climate (1961–2000) with RegCM3 driven by NCEP/NCAR reanalysis. *Int. J. Clim.*, pp. 455–472.

Biel, E. R. (1927). Klimatographie des ehemaligen österreichischen Kustenlandes. *Denkschriften der mathem.-naturw*, str. 137-193.

Black, E., Blackburn, M., Harrison, G., Hoskins, B., & Methven, J. (2004). Factors contributing to the summer 2003 European heatwave . *Weather, **59,*** 217-223. doi:10.1256/wea.74.04

Böhm, U., Keuler, K., Österle, H., Kücken, M., & Hauffe, D. (2008). Quality of a climate reconstruction for the CADSES regions. *Meteorol. Z.*, pp. 477–485.

Borzelli, G., Manzella, G., Marullo, S., & Santoleri, R. (1999). Observations of coastal filaments in the Adriatic Sea. *J. Marine Syst.* **(20)**, 187-203. doi:10.1016/S0924-7963(98)00082-7

Brands, S., Herrera, S., Fernández, J., & Gutiérrez , J. M. (2013). How well do CMIP5 Earth System Models simulate present climate conditions in Europe and Africa? *Clim. Dyn.* **(41)**, str. 803-817. doi:10.1007/s00382-013-1742-8

Branković, Č., Güttler, I., & Gajić-Čapka, M. (2013). Evaluating climate change at the Croatian Adriatic from observations and regional climate models' simulations. *Clim. Dyn.*, pp. 2353-2373. doi:10.1007/s00382-012-1646-z

Branković, Č., Patarčić, M., Güttler, I., & Srnec, L. (2012). Near-future climate change over Europe with focus on Croatia in an ensemble of regional climate model simulations. *Clim. Res.* **(52)**, 227–251. doi:10.3354/cr01058

Brierley, M., & Fedorov, V. (2010). Relative importance of meridional and zonal sea surface temperature gradients for the onset of the ice ages and Pliocene-Pleistocene climate evolution. *Paleoceanography, **25*** **(2)**. doi:10.1029/2009PA001809

Bucchignani, E., Cattaneo, L., Panitz, H. J., & Mercogliano, P. (2015). Sensitivity analysis with the regional climate model COSMO-CLM over the CORDEX-MENA domain. *Meteorol. Atmos. Phys., **128*** **(1)**, str. 73–95. doi:10.1007/s00703-015-0403-3

Buljan, M. (1965). Anomalije temperature i kloriniteta mora na postaji Stončica kod otoka Visa. *Pomorski zbornik 3*, (str. 949-994).

Cantu, V. (1977). The climate of Italy. *Wallen CC (ed) Climates of Central and Southern Europe - World Survey of Climatology 6*, str. 127-184.

Christensen, J. H., Carter, T. R., Rummukainen, M. R., & Amanatidis, G. (2007). Evaluating the performance and utility of regional climate models: The PRUDENCE project. *Clim. Chang.***(81)**, 31-52. doi:10.1007/s10584-006-9211-6

Christensen, J. H., Hewitson, B., Busuioc, A., Chen, A., Gao, X., Held, I., Jones, R; Kolli, R K; Kwon, W T; Laprise, R; Magana Rueda, V; Mearns, L; Menéndez, C G; Raisanen, J; Rinke, A; Sarr, A; & Whetton, P. (2007). Regional climate projections. U S. Q. Solomon, *Climate Change: The Physical Science Basis* (str. 847–940). NY: Cambridge University Press.

Christidis, N., Jones, G. S., & Stott, P. A. (2014). Dramatically increasing chance of extremely hot summers since the 2003 European heatwave. *Nature Clim. Change, **5***, 46-50. doi:10.1038/nclimate2468

Civitarese, G., Gačić, M., Lipizer, M., & Eusebi Borzelli, G. L. (2010). On the impact of the Bimodal Oscillating System (BiOS) on the biogeochemistry and biology of the Adriatic and Ionian Seas (Eastern Mediterranean). *Biogeosciences***(7)**, pp. 3987–3997. doi:10.5194/bg-7-3987-2010

Colin, J., Déqué, M., Radu, R., & Somot, S. (2010). Sensitivity study of heavy precipitation in limited area model climate simulations: influence of the size of the domain and the use of the spectral nudging technique. *Tellus A: Dynamic Meteorology and Oceanography, **62*****(5)**, str. 591–604.

Cornes, R. C., van der Schrier, G., van den Besselaar, E. J., & Jones, P. D. (2018). An Ensemble Version of the E-OBS Temperature and Precipitation Data Sets. *J. Geophys. Res. Atmos.***(123)**. doi:10.1029/2017JD028200

Cuxart, J., Bougeault, P., & Redelsperger, J. -L. (2000). A turbulence scheme allowing for mesoscale and large-eddy simulations. *Q. J. Roy. Meteor. Soc.***(126)**, str. 1-30. doi:10.1002/qj.49712656202

Darmaraki, S. (2019c). *Canicules océaniques en Méditerranée : détection, variabilité passée et évolution future.* Sveučilište Toulouse.

Darmaraki, S., Somot, S., Sevault, F., & Nabat, P. (2019b). Past Variability of Mediterranean Sea Marine Heatwaves. *Gophy. Res. Lett.***(46)**, str. 9813–9823. doi:10.1029/2019GL082933

Darmaraki, S., Somot, S., Sevault, F., Nabat, P., Cabos Narvaez, W. D., Cavicchia, L., Djurdjevic, V; Li, L; Sannino, G, & Sein, D. V. (2019a). Future evolution of Marine Heatwaves in the Mediterranean Sea . *Clim. Dyn.***(53)**, pp. 1371–1392. doi:10.1007/s00382-019-04661-z

Denamiel, C., Pranić, P., Quentin, F., Mihanović, H., & Vilibić I. (2020). Pseudo-global warming projections of extreme wave storms in complex coastal regions: the case of the Adriatic Sea. *Clim. Dyn.***(55),** 2483–2509 doi:10.1007/s00382-020-05397-x

Denamiel, C., Pranić, P., Ivanković, D., Tojčić, I., & Vilibić, I. (2021): Performance of the Adriatic Sea and Coast (AdriSC) climate component – a COAWST V3.3-based coupled atmosphere-ocean modelling suite: atmospheric part , Geosci. Model Dev. Discuss. doi:10.5194/gmd-2021-3

Dickinson, R. E., Errico, R. M., Giorgi, F., & Bates, G. T. (1989). A regional climate model for the western United States. *Clim. Chang.***(15)**, 383–422.

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 (No. NCAR/TN-387+STR). *University Corporation for Atmospheric Res.* doi:10.5065/D67W6959

Doms, G., Forstner, J., Heise, E., Herzog, H. -J., Mironov, D., Raschendorfer, M., Reinhardt, T; Ritter, B; Schrodin, R; Schulz, J -P; & Vogel, G. (2011). A description of the non-hydrostatic regional COSMO model, Part II: physical parameterization. *Technical report, Consortium for Small-Scale Modelling*. Dohvaćeno iz www.cosmo-model.org/content/model/documentation/core/cosmoPhysParamtr.pdf

Dyson, G. (2012). *Turing's Cathedral: The Origins of the Digital Universe.* New York: Vintage.

Edwards, P. N. (2010). *A Vast Machine: Computer Models, Climate Data, and the Politics of Global Warming.* MIT Press.

Ek, M. B., Mitchell, K. E., Lin, Y., Rogers, E., Grunmann, P., Koren, V., Gayno, G; & Tarpley, J. D. (2003). Implementation of Noah land surface model advances in the National Centers for Environmental Prediction operational mesoscale Eta model. *J. Geophys. Res. Atmos.*, ***108*****(D22)**, str. 8851. doi:10.1029/2002JD003296

Fischer, E. M., Rajczak, J., & Schär, C. (2012). Changes in European summer temperature variability revisited. *Geophys. Res. Lett., L19702*. doi:10.1029/2012GL052730

Fouquart, Y., & Bonnel, B. (1980). Computations of solar heating of the Earth's atmosphere – a new parameterization. *Contributions to Atmos. Phys.***(53)**, str. 35-62.

Furlan, D. (1977). The climate of southeast Europe. *Wallen CC (ed) Climates of Central and Southern Europe - World Survey of Climatology 6*, str. 185-235.

Gačić, M., Marullo, S., Santoleri, R., & Bergamasco, A. (1997). Analysis of the seasonal and interannual variability of the sea surface temperature field in the Adriatic Sea from AVHRR data (1984-1992). *J. Geophys. Res.***(102)**, 22937-22946. doi:10.1029/97JC01720

Gao, X. -J., Shi, J., & Giorgi, F. (2016). Comparison of convective parameterizations in RegCM4 experiments over China with CLM as the land surface model. *Atmos. Ocean. Sci. Lett.*, ***9*****(4)**, str. 246–254. doi:10.1080/16742834.2016.1172938

García-Herrera, R., Díaz, J., Trigo, R. M., Luterbacher, J., & Fischer, E. M. (2010). A review of the European summer heat wave of 2003 . *Crit. Rev. Env. Sci. Tec.*, ***40*****(4)**, 267-306. doi:10.1080/10643380802238137

Gettelman, A., & Rood, R. B. (2016). *Demystifying Climate Models.* Earth Systems Data and Models 2. doi:10.1007/978-3-662-48959-8_3

Giorgetta, M. A., & Wild, M. (1995). The water vapour continuum and its representation in ECHAM4. **(162)**, str. 47.

Giorgi, F. (2006). Climate change hot-spots. *Geophys. Res. Lett.*, ***33*****(8)**. doi:10.1029/2006GL025734

Giorgi, F. (2008). Regionalization of climate chnage information for impact assessment and adaptation. *WMO Bulletin***(57)**, pp. 86-92.

Giorgi, F. (2019). Thirty years of regional climate modeling: Where are we and where are we going next? *J. Geophys. Res.***(124)**, 5696–5723. doi:10.1029/2018JD030094

Giorgi, F., & Bates, G. T. (1989). The climatological skill of a regional model over complex terrain. *Mon. Weath. Rev.***(117)**, 2325–2347.

Giorgi, F., & Mearns, L. O. (1999). Introduction to special section: regional climate modelling revisited. *J. Geophys. Res.***(104)**, 6335–6352. doi:10.1029/98JD02072

Giorgi, F., Coppola, E., Solmon, F., Mariotti, L., Sylla, M. B., Bi, X., Elguindi, N; Diro, G T; Nair, V; Giuliani, G; Turuncoglu, U U; 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.***(52)**, str. 7–29. doi: 10.3354/cr01018

Giorgi, F., Jones, C., & Asrar, G. R. (2009). Addressing climate information needs at the regional level: the CORDEX framework. *WMO Bulletin***(58)**, pp. 175–183.

Grazzini, F., & Viterbo, P. (2003). Record-breaking warm sea surface temperature of the Mediterranean Sea. *ECMWF Newslett.***(98)**, pp. 30–31.

Grbec, B., Matić, F., Beg Paklar, G., Morović, M., Popović, R., & Vilibić, I. (2018). Long-term trends, variability and extremes of in situ sea surface temperature measured along the eastern Adriatic coast and its relationship to hemispheric processes. *Pure Appl. Geophys.*, ***175***, 4031-4046. doi:10.1007/s00024-018-1793-1

Grbec, B., Vilibić, I., Bajić, A., Morović, M., Beg Paklar, G., Matić, F., & Dadić, V. (2007). Response of the Adriatic Sea to the atmospheric anomaly in 2003. *Ann. Geophys.*, str. 835-846. doi:10.5194/angeo-25-835-2007

Grell, G. A. (1993). Prognostic evaluation of assumptions used by cumulus parameterizations. *Mon. Weath. Rev.***(121)**, str. 764–787.

Grell, G. A., & Dévényi, D. (2002). A generalized approach to parameterizing convection combining ensemble and data assimilation techniques. *Geophys. Res. Lett.***(29)**, str. 38-1–38-4. doi:10.1029/2002GL015311

Grisogono, B., & Belušić, D. (2009). A review of recent advances in understanding the meso- and microscale properties of the severe bora wind. *Tellus*(61A), str. 1-16. doi:10.1111/j.1600-0870.2008.00369.x

Guirguis, K., Gershunov, A., Despalatović, M., Grbec, B., & Beg Paklar, G. (2004). Effects of climatic fluctuations on the distribution of warm-water coral Astroides calycularis in the Adriatic Sea: new records and review. *J. Mar. Biol. Ass.*, ***84*****(3)**, 599-602. doi:10.1007/s00382-017-3850-3

Gutowski Jr., W. J., Giorgi, F., Timbal, B., Frigon, A., Jacob, D., Kang, H. -S., Raghavan, K; Lee, B; Lennard, C; Nikulin, G; O'Rourke, E; Rixen, M; Solman, S; Stephenson, T; & Tangang, F. (2016). WCRP Coordinated Regional Downscaling Experiment (CORDEX): A diagnostic MIP to CMIP6. *Geosci. Model Dev.***(9)**, 4087–4095. doi:10.5194/gmd-9-4087-2016

Haylock, M. E., Hofstra, N., Klein Tank, A. M., Jones, P. D., & New, M. (2008). A European daily high-resolution gridded dataset of surface temperature and precipitation. *J. Geophys. Res. Atmos.*, ***113*****(D20)**. doi:10.1029/2008JD10201

Heikkilä, U., Sandvick, A., & Sorteberg, A. (2011). Dynamical downscaling of ERA-40 in complex terrain using the WRF regional climate model. *Clim. Dyn.***(37)**, 1551–1564.

Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J; Peubey, C; Radu, R; Schepers, D; Simmons, A; Soci, C; Abdalla, S; Abellan, X; Balsamo, G; Bechtold,

P; Biavati, G; Bidlot, J; Bonavita, M; De Chiara, G; & Dahlgren (2020). The ERA5 global reanalysis. *Q. J. R. Meteorol. Soc.***(146)**, str. 1999–2049. doi:10.1002/qj.3803

Hewitson, B. C., & Crane, R. G. (1996). Climate downscaling: techniques and applications. *Clim. Res.***(7)**, str. 85-95.

Hobday, A. J., Alexander, L. V., Perkins, S. E., Smale, D. A., Straub, S. C., Oliver, E. C., Benthuysen, J A; Burrows, M T; Donat, M G; Feng, M; Holbrook, N J; Moore, P J; Scannell, H A; Sen Gupta, A; & Wernberg, T (2016). A hierarchical approach to defining marine heatwaves. *Progress Oceanogr*.**(141)**, str. 227-238. doi:10.1016/j.pocean.2015.12.014

Holtanova, E., Miksovský, J., Kalvová, J., Pisoft, P., & Motl, M. (2012). Performance of ENSEMBLES regional climate models over Central Europe using various metrics. *Theor. Appl. Climatol.*, pp. 463–470.

Holtslag, A., de Bruijn, E., & Pan, H. (1990). A high resolution air mass transformation model for short-range weather forecasting. *Mon. Weath. Rev*.**(118)**, str. 1561–1575.

Hong, S. -Y., Noh, Y., & Dudhia, J. (2006). A new vertical diffusion package with an explicit treatment of entrainment processes. *Mon. Weath. Rev*.**(134)**, str. 2318–2341. doi:10.1175/MWR3199.1

Hong, Y., Hsu, K. -L., Sorooshian, S., & Gao, X. -J. (2004). Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system. *J. Appl. Meteorol.***(43)**, str. 1834–1853. doi:10.1175/JAM2173.1

Iacono, M. J., Delamere, J. S., Mlawer, E. J., Shephard, M. W., Clough, S. A., & Collins, W. D. (2008). Radiative forcing by long-lived greenhouse gases: calculations with the AER radiative transfer models. *J. Geophys. Res.***(113)**, str. 1-8. doi:10.1029/2008JD009944

Jacob, D., & Podzun, R. (1997). Sensitivity studies with the regional climate model REMO. *Meteorol. Atmos. Phys.***(63)**, str. 119–129. doi:10.1007/BF01025368

Jacob, D., Petersen, J., Eggert, B., Alias, A., Christensen, O. B., Bouwer, L. M., Braun, A; Colette, A; Déqué, M; Georgievski, G; Georgopoulou, E; Gobiet, A; Menut, L; Nikulin, G; Haensler, A; Hempelmann, N; Jones, C; Keuler, K; Kovats, S; Kröner, N; Kotlarski, S; Kriegsmann, A; Martin, E; van Meijgaard, E; Moseley, C; Pfeifer, S; Preuschmann, S; Radermacher, C; Radtke, K; Rechid, D; Rounsevell, M; Samuelsson, P; Somot, S; Soussana, J F; Teichmann, C; Valentini, R; Vautard, R; Weber, B; & Yiou, P (2014). EURO-CORDEX: new high resolution climate change projections for European impact research. *Reg. Environ. Change*, str. 563–578. doi:10.1007/s10113-013-0499-2

Jaeger, E. B., Anders, I., Lüthi, D., Rockel, B., Schär, C., & Seneviratne, S. I. (2008). Analysis of ERA40-driven CLM simulations for Europe. *Meteorol. Z.*, pp. 1-19.

Jones, C., Giorgi, F., & Asrar, G. (2011). The Coordinated regional Downscaling EXperiment: CORDEX. An international downscaling link to CMIP5. *CLIVAR Exchanges***(16)**, 34-40.

Kain, J. S., & Fritsch, J. M. (1993). Convective parameterization for mesoscale models: the Kain-Fritsch scheme. *In: Emanuel, K.A. and Raymond, D.J. (Eds.) The Representation of Cumulus Convection in Numerical Models, Meteorological Monographs*. doi:10.1007/978-1-935704-13-3_16

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). *NCAR Tech. Note*.

Kjellström, E., Bärring, L., Nikulin, G., Nilsson, C., Persson, G., & Strandberg, G. (2016). Production and use of regional climate model projections – a Swedish perspective on building climate services. *Clim. Serv.***(2-3)**, str. 15–29. doi:10.1016/j.cliser.2016.06.004

Kotlarski, S., Block, A., Böhm, U., Jacob, D., Keuler, K., Knoche, R., Rechid, D; & Walter, A (2005). Regional climate model simulations as input for hydrological applications: evaluation of uncertainties. *Adv. Geosci.*, pp. 119–125. doi:10.5194/adgeo-5-119-2005

Kotlarski, S., Keuler, K., Christensen, O. B., Colette, A., Déqué, M., Gobiet, A., Goergen, K; Jacob, D; Lüthi, D; van Meijgaard, E; Nikulin, G; Schär, C; Teichmann, C; Vautard, R; Warrach-Sagi, K; & Wulfmeyer, V (2014). Regional climate modeling on European scales: a joint standard evaluation of the EURO-CORDEX RCM ensemble. *Geosci. Model Dev.*, str. 1297–1333.

Kotroni, V., Lykoudis, S., Lagouvardos, K., & Lalas, D. (2008). A fine resolution regional climate change experiment for the Eastern Mediterranean: analysis of the present climate simulations. *Global Planet. Change***(64)**, str. 93–104. doi:10.1016/j.gloplacha.2008.10.003

Lenderink, G., & Holtslag, A. A. (2004). An updated length-scale formulation for turbulent mixing in clear and cloudy boundary layers. *Q. J. Roy. Meteor. Soc.*, ***130*(604)**, str. 3405–3427. doi:10.1256/qj.03.117

Lhotka, O., Kisely, J., & Farda, A. (2018). Climate change scenarios of heat waves in central Europe and their uncertanities. *Theor. Appl. Climatol.*, ***131***, 1043-1054. doi:10.1007/s00704-016-2031-3

Lima, F. P., & Wethey, D. S. (2012). Three decades of high-resolution coastal sea surface temperatures reveal more than warming. *Nat. Commun.***(3)**, p. 704.

Lohmann, U., & Roeckner, E. (1996). Design and performance of a new cloud microphysics scheme developed for the ECHAM general circulation model. *Clim. Dyn.***(12)**, str. 557–572. doi:10.1007/BF00207939

Lorenz, P., & Jacob, D. (2010). Validation of temperature trends in the ENSEMBLES regional climate model runs driven by ERA40. *Clim. Res.*, pp. 167–177.

Louis, J. -F. (1979). A parametric model of vertical eddy fluxes in the atmosphere. *Bound.-Lay. Meteorol.*(17), str. 187–202. doi:10.1007/BF00117978

Lucas-Picher, P., Wulff-Nielsen, M., Christensen, J. H., Aðalgeirsdóttir, G., Mottram, R., & Simonsen, S. B. (2012). Very high resolution regional climate model simulations over Greenland: identifying added value. *J. Geophys. Res.***(117)**, str. 1-16. doi:10.1029/2011JD016267

Machenhauer, B., Windelband, M., Botzet, M., Christensen, J. H., Déqué, M., & Jones, R. G. (1998). *Validation and analysis of regional present-day climate and climate change simulations over Europe.* Hamburg, Germany: MPI.

MacKenzie, B. R., & Schiedek, D. (2007). Daily ocean monitoring since the 1860s shows record warming of northern European seas. *Global Change Biol.*, ***13*(7)**, pp. 1335–1347. doi:10.1111/j.1365-2486.2007.01360.x

Manca, B. B., Ibello, V., Pacciaroni, M., Scarazzato, P., & Giorgetti, A. (2006). Ventilation of deep waters in the Adriatic and Ionian Seas following changes in thermohaline circulation of the Eastern Mediterranean. *Clim. Res.***(31)**, pp. 239–256.

Marotti, A. (2010). Recent changes in the Mediterranean water cycle: a pathway toward long-term regional hydroclimatic change? *J. Climate, **23***, 1513-1525. doi:10.1175/2009JCLI3251.1

Masson, V., Le Moigne, P., Martin, E., Faroux, S., Alias, A., Alkama, R., Belamari, S; Barbu, A; Boone, A; Bouyssel, F; Brousseau, P; Brun, E; Calvet, J -C; Carrer, D; Decharme, B; Delire, C; Donier, S; Essaouini, K; Gibelin, A -L; Giordani, H; Habets, F; Jidane, M; Kerdraon, G; Kourzeneva, E; Lafaysse, M; Lafont, S; Lebeaupin Brossier, C; Lemonsu, A; Mahfouf, J -F; Marguinaud, P; Mokhtari, M; Morin, S; Pigeon, G; Salgado, R; Seity, Y; Taillefer, F; Tanguy, G; Tulet, P; Vincendon, B; Vionnet, V; & Voldoire, A (2013). The SURFEXv7.2 land and ocean surface platform for coupled or offline simulation of earth surface variables and fluxes. *Geosci. Model Dev.***(6)**, str. 929–960. doi:10.5194/gmd-6-929-2013

Mayer, S., Fox Maule, C., Sobolowski, S., Christensen, O. B., Sørup, H. J., Sunyer, M. A., Arnbjerg-Nielsen, K; & Barstad, I (2015). Identifying added value in high-resolution climate simulations over Scandinavia. *Tellus A***(67)**, 1-18. doi:10.3402/tellusa.v67.24941

Merchant, C. J., Embury, O., Bulgin, C. E., Block, T., Corlett, G. K., Fiedler , E., Good , S A; Mittaz, J; Rayner, N A; Berry, D; Eastwood, S; Taylor, M; Tsushima, Y; Waterfall, A; Wilson, R; & Donlon, C (2019). Satellite-based time-series of sea-Benthuysen, surface temperature since 1981 for climate applications. *Sci. Data, **6*****(223)**. doi:10.1038/s41597-019-0236-x

Merchant, C. J., Embury, O., Roberts-Jones, J., Fiedler, E., Bulgin, C. E., Corlett, G. K., Good, S; McLaren, A; Rayner, N; Morak-Bozzo, S; & Donlon, C (2014). Sea surface temperature datasets for climate applications from Phase 1 of the European Space Agency Climate Change Initiative (SST CCI). *Geosci. Data J.***(1)**, str. 179-191. doi:10.1002/gdj3.20

Mlawer, E. J., Taubman, S. J., Brown, P. D., Iacono, M. J., & Clough, S. A. (1997). Radiative transfer for inhomogeneous atmospheres: RRTM, a validated correlated-k model for the longwave. *J. Geophys. Res., **102*****(D14)**, str. 16663–16682. doi:10.1029/97JD00237

Morcrette, J. -J., Smith, L. D., & Fouquart, Y. (1986). Pressure and temperature dependence of the absorption in longwave radiation parameterizations. *Contributions to Atmos. Phys.***(59)**, str. 455–469.

Muthers, S., Laschewski, G., & Matzarakis, A. (2017). The summers 2003 and 2015 in south-west Germany: heat waves and heat-related mortality in the context of climate change. *Atmos., **8*****(11)**. doi:10.3390/atmos8110224

Nabat, P., Somot, S., Mallet, M., Sanchez-Lorenzo, A., & Wild, M. (2014). Contribution of anthropogenic sulfate aerosols to the changing Euro-Mediterranean climate since 1980. *Geophys. Res. Lett.* **(41)**, 5605–5611, doi:10.1002/2014GL060798

Nabat, P., Somot, S., Mallet, M., Sevault, F., Chiacchio, M., & Wild, M. (2015a). Direct and semi-direct aerosol radiative effect on the Mediterranean climate variability using a coupled regional climate system model. *Clim. Dyn.* **44,** 1127–1155, doi:10.1007/s00382-014-2205-6

Nabat, P., Somot, S., Mallet, M., Michou, M., Sevault, F., Driouech, F., Meloni, D., di Sarra, A., Di Biagio, C., Formenti, P., Sicard, M., Léon, J.-F., & Bouin, M.-N. (2015b). Dust aerosol radiative effects during summer 2012 simulated with a coupled regional aerosol–atmosphere–ocean model over the Mediterranean, *Atmos. Chem. Phys.* **15**, 3303–3326, doi:10.5194/acp-15-3303-2015, 2015

Neggers, R. A., Köhler, M., & Beljaars, A. C. (2009). A dual mass flux framework for boundary layer convection. Part I: transport. *J. Atmos. Sci.***(66)**, 1465–1487. doi:10.1175/2008JAS2635.1

Nordeng, T. E. (1994). Extended versions of the convection parametrization scheme at ECMWF and their impact upon the mean climate and transient activity of the model in the tropics. *ECMWF Research Department. Technical Memorandum*(206).

Nykjaer, L. (2009). Mediterranean sea surface warming 1985-2006. *Climate Res.* ***39***, 11-17. doi:10.3354/cr00794

Olita, A., Sorgente, R., Natale, S., Ribotti, A., Bonanno, A., & Patti, B. (2007). Effects of the 2003 European heatwave on the Central Mediterranean Sea: surface fluxes and the dynamical response. *Ocean Sci., **3*****(2)**, pp. 273–289. doi:10.5194/os-3-273-2007

Oliver, E. C., Benthuysen, J. A., Bindoff, N. L., Hobday, A. J., Holbrook, N. J., Mundy, C. N., & Perkins-Kirkpatrick, S. E. (2018a). The unprecedented 2015/16 Tasman Sea marine heatwave. *Nat. Commun., **8*****(16)**, p. 101.

Oliver, E. C., Donat, M. G., Burrows, M. T., Moore, P. J., Smale, D. A., Alexander, L. V., Benthuysen, J A; Feng, M; Sen Gupta, A; Hobday, A J; Holbrook, N J; Perkins-Kirkpatrick, S E; Scannell, H A; Straub, S C; & Wernberg , T (2018b). Longer and more frequent marine heatwaves over the past century. *Nat. Commun., **9*****(1)**, p. 1324. doi:10.1038/s41467-018-03732-9

Önol, B. (2012). Effects of coastal topography on climate: high resolution simulation with a regional climate model. *Clim. Res.***(52)**, 159-174 . doi:10.3354/cr01077

Orlić, M., Gačić, M., & La Violette, P. E. (1992). The currents and circulation of the Adriatic Sea. *Ocean. Acta***(15)**, 109-124.

Pal, J. S., Small, E. E., & Eltahir, E. A. (2000). Simulation of regional scale water and energy budgets: influence of a new moist physics scheme within RegCM. *J. Geophys. Res. Atmos.***(105)**, str. 29579–29594. doi:10.1029/2000JD900415

Pearson, K. (1895). *Notes on regression and inheritance in the case of two parents* (Svez. 58). London: Proceedings of the Royal Society of London.

Penzar, B., & Penzar, I. (1995). Velebit - klimatska prekretnica. *Simpozij povodom 45. godišnjice NP "Paklenica"*. Starigrad - Paklenica: Paklenički zbornik 1.

Penzar, B., Penzar, I., & Orlić, M. (2001). *Vrijeme i klima hrvatskog Jadrana.* Split: Hrvatski Hidrografski Institut.

Pfeifer, S. (2006). Modeling cold cloud processes with the regional climate model REMO. *PhD thesis, Reports on Earth System Science*.

Prtenjak, M. T., & Grisogono, B. (2007). Sea-land breeze climatological characteristics along the northern Croatian Adriatic coast. *Theor. Appl. Climatol.***(90)**, str. 201-215. doi:10.1007/s00704-006-0286-9

Radilović, S., Koračin, D., Denamiel, C., Belušić, D., Güttler, I., & Vilibić, I. (2019). Simulated and observed air temperature trends in the eastern Adriatic. *Atmos. Sci. Lett.***(e951)**. doi:10.1002/asl.951

Raicich, F. (1996). On the fresh water balance of the Adriatic Sea. *J. of Marine Sys.***(9)**, pp. 305-319.

Rasch, P. J., & Kristjánsson, J. E. (1998). A comparison of the CCM3 model climate using diagnosed and predicted condensate parameterizations. *J. Climate***(11)**, str. 1587–1614. doi:10.1175/1520-0442(1998)011<1587:ACOTCM>2.0.CO;2

Ritter, B., & Geleyn, J. -F. (1992). A comprehensive radiation scheme for numerical weather prediction models with potential applications in climate simulations. *Mon. Weath. Rew.***(120)**, str. 303–325. doi:10.1175/1520-0493(1992)120<0303:ACRSFN>2.0.CO;2

Rixen, M., Beckers, J. M., Levitus, S., Antonov, J., Boyer, T., Maillard, C., Fichaut, M., Balopoulos, E., Iona, S., Dooley, H., Garcia, M -J., Manca, B., Giorgetti, A., Manzella, G., Mikhailov, N., Pinardi, N., & Zavatarelli, M. (2005). The western Mediterranean deep water: A proxy for climate change. *Geophys. Res. Lett., L12608***(32)**. doi:10.1029/2005GL022702

Roeckner, E., Arpe, K., Bengtsson, L., Christoph, M., Claussen, M., Dümenil, L., & Schulzweida, U. (1996). The atmospheric general circulation model ECHAM-4: Model description and simulation of present-day climate. *Technical Report, Max-Planck-Institut für Meteorologie Report Series*(218).

Rummukainen, M. (2016). Added value in regional climate modeling. *WIREs Climate Change***(7)**, 145–159.

Russo, S., Sillmann, J., & Fischer, E. M. (2015). Top ten European heatwaves since 1950 and their occurence in the coming decades. *Environ. Res. Lett., **10***. doi:10.1088/1748-9326/10/12/124003

Ruti, P. M., Somot, S., Giorgi , F., Dubois, C., Flaounas, E., Obermann, A., Dell'Aquila, A; Pisacane, G; Harzallah, A; Lombardi, E; Ahrens, B; Akhtar, N; Alias, A; Arsouze, T; Aznar, R; Bastin, S; Bartholy, J; Béranger, K; Beuvier, J; Bouffies-Cloché, S; Brauch, J; Cabos, W; Calmanti, S; Calvet, J -C; Carillo, A; Conte, D; Coppola, E; Djurdjevic, V; Drobinski, P; Elizalde-Arellano, A; Gaertner, M; Galàn, P; Gallardo, C; Gualdi, S; Goncalves, M; Jorba, O; Jordà, G; L'Heveder, B; Lebeaupin-Brossier, C; Li, L; Liguori, G; Lionello, P; Maciàs, D; Nabat, P; Önol, B; Raikovic, B; Ramage, K; Sevault, F; Sannino, G; Struglia, M V; Sanna, A; Torma, C; & Vervatis, V (2016). The MED-CORDEX initiative for Mediterranean climate studies. *Bull. Amer. Meteor. Soc., **97*(7)**, 1187–1208. doi:10.1175/BAMS-D-14-00176.1

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

Sass, B. H., Rontu, L., Savijärvi, H., & Raisanen, P. (1994). HIRLAM-2 radiation scheme: documentation and tests. *Hirlam Technical Report***(16)**.

Savijärvi, H. (1990). Fast radiation parameterization schemes for mesoscale and short-range forecast models. *J. Appl. Meteorol. Clim.***(29)**, str. 437–447. doi:10.1175/1520-0450(1990)029<0437:FRPSFM>2.0.CO;2

Scannell, H. A., Pershing, A. J., Alexander, M. A., Thomas, A. C., & Mills, K. E. (2016). Frequency of marine heatwaves in the North Atlantic and North Pacific since 1950. *Geophys. Res. Lett., **43*(5)**, pp. 2069–2076. doi:10.1002/2015GL067308

Schaeffer, A., & Roughan, M. (2017). Subsurface intensification of marine heatwaves off southeastern Australia: the role of stratification and local winds. *Geophys. Res. Lett., **44*(10)**, pp. 5025–5033.

Schaller, N., Sillmann, J., Anstey, J., Fischer, E. M., Grams, C. M., & Russo, S. (2018). Influence of blocking on northern European and western Russian heatwaves in large climate model ensembles. *Environ. Res. Lett.,* ***13***. doi:10.1088/1748-9326/aaba55/meta

Shaltout, M., & Omstedt, A. (2014). Recent sea surface temperature trends and future scenarios for the Mediterranean Sea. *Oceanologia,* ***56*****(3)**, pp. 411–443.

Siebesma, A. P. (2007). A combined eddy-diffusivity mass-flux approach for the convective boundary layer. *J. Atmos. Sci.***(64)**, str. 1230–1248. doi:10.1175JAS3888.1

Sijerković, M., & Milković, J. (1995). Obilježja atmosferske cirkulacije i prosječnog vremena tijekom godine na otoku Mljetu. *Ekološke monografije* **(6)**, 181-191.

Sijerković, M., & Zaninović, K. (1996). Meteorološki singulariteti kao obilježja klime Kornatskog otočja. *Ekološke monografije* **(7)**, 121-131.

Sijerković, M., & Zaninović, K. (1998). Meteorološki singulariteti u godišnjem hodu temperature zraka na riječkom području. *Znanstveni skup "Prirodoslovna istraživanja Riječkog područja"* (str. 171-179). Rijeka: Prirodoslovni muzej Rijeka.

Sijerković, M., & Zaninović, K. (1999). Najvažniji meteorološki singulariteti na južnom Jadranu. *2. hrvatska konferencija o vodama* (str. 73-78). Dubrovnik: Zbornik radova.

Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Barker, D., Duda, M. G., Huang, X.-Y., Wang, W. & Powers, J.G. (2008). A Description of the Advanced Research WRF Version 3. str. 3-27.

Skliris, N., Sofianos , S., Gkanasos, A., Mantziafou, A., Vervatis, V., Axaopoulos, P., & Lascaratos, A. (2012). Decadal scale variability of sea surface temperature in the Mediterranean Sea in relation to the atmospheric variability. *Ocean Dyn.,* ***61*****(1)**, 13-30. doi:10.1007/s10236-011-0493-5

Smale, D. A., Wernberg, T, Oliver, E. C. J., Thomsen, M, Harvey, B. P., Straub, S. C., Burrows, M. T., Alexander, L. V., Benthuysen, J. A., Donat, M. G., Feng, M., Hobday, A. J., Holbrook, N. J., Perkins-Kirkpatrick, S. E., Scannell, H. A., Sen Gupta, A., Payne, B. L., & Moore, P. J. (2019). Marine heatwaves threaten global biodiversity and the provision of ecosystem services. *Nat. Clim. Change*, **9**, 306–12.

Sousa, P. M., Trigo, R. M., Barriopedro, D., Soares, P. M., & Santos, J. A. (2018). European temperature responses to blocking and ridge regional patterns. *Clim. Dyn.,* ***50***, 457-477. doi:10.1007/s00382-017-3620-2

Sparnocchia, S., Schiano, M., Picco, P., Bozzano, R., & Cappelletti, A. (2006). The anomalous warming of summer 2003 in the surface layer of the Central Ligurian Sea (Western Mediterranean). *Annal. Geophy.***(24)**, pp. 443–452.

Spillman, C. M., Imberger, J., Hamilton, D. P., Hipsey, M. R., & Romero, J. R. (2007). Modelling the effects of Po River discharge, internal nutrient cycling and hydrodynamics on biogeochemistry of the northern Adriatic Sea. *J. of Marine Sys.* **(68)**, pp. 167–200.

Stipaničić, V. (1975). Odnos temperature mora i zraka. *Vijesti Pomorske meteorološke službe,* ***21*****(2)**, str. 7-8.

Stravisi, F. (1984). Normal climatic data for the Adriatic Sea. *FAO Fisheries Report 290 CGPM/GFC,* str. 59-67.

Supić, N., & Orlić, M. (1992). Annual cycle of sea surface temperature along the east Adriatic coast. *Geofizika,* **(9)**, str. 79-97.

Takle, E. S., Roads, J., Rockel, B., Gutowski Jr., W. J., Arritt, R. W., Meinke, I., Jones, C G; & Zadra, A (2007). Transferability intercomparison: An opportunity for new insight on the global water cycle and energy budget. *Bull. Amer. Meteor. Soc., **88*(3)**, 375–384. doi:10.1175/BAMS-88-3-375

Taylor, G. I. (1916). Skin friction of the wind on the Earth's surface. *Proc. Roy. Soc., **A92***, 196-199. doi:10.1098/rspa.1916.0005

Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *J. Geophys. Res. Atmos., **106***, 7183-7192. doi:10.1029/2000JD900719

Thorne, P. W., & Vose, R. S. (2010). Reanalyses suitable for characterizing long-term trends. *Bull. Amer. Meteor. Soc., **91***, 353-361. doi:10.1175/2009bams2858.1

Tiedtke, M. (1989). A comprehensive mass flux scheme for cumulus parametrization in large-scale models. *Mon. Weath. Rev.***(117)**, str. 1779–1800. doi:10.1175/1520-0493(1989)117<1779:ACMFSF>2.0.CO;2

Tiedtke, M. (1993). Representation of clouds in large-scale models. *Mon. Weath. Rev.***(121)**, str. 3040–3061. doi:10.1175/1520-0493(1993)121<3040:ROCILS>2.0.CO;2

Tomažić, I. (2000). *Analiza površinske temperature Jadrana na osnovi satelitskih mjerenja.* Diplomski rad na PMF-u Sveučilišta u Zagrebu, Zagreb.

Torma, C., Giorgi, F., & Coppola, E. (2015). Added value of regional climate modeling over areas characterized by complex terrain - Percipitation over the Alps. *J. Geophys. Res. Atmos.***(120)**, 3957-3972. doi:10.1002/2014JD022781

Van den Hurk, B. J., Viterbo, P., Beljaars, A. C., & Betts, A. K. (2000). Offline validation of the ERA40 surface scheme. *ECMWF Technical Memorandum 295*.

van der Linden, P., Mitchell, J. F., & Gilbert, P. (2009). *ENSEMBLES. Climate change and its impacts at seasonal, decadal and centennial time scales.* UK Met Office.

van Meijgaard, E., van Ulft, L. H., van de Berg, W. J., Bosveld, F. C., van den Hurk, B. J., Lenderink, G., & Siebesma, A. P. (2008). The KNMI regional atmospheric model RACMO version 2.1. *Technical Report 302, KNMI*.

Vidale, P. L., Lüthi, D., Wegmann, R., & Schär, C. (2007). European summer climate variability in a heterogeneous multi-model ensemble. *Clim. Change,* **(81)**, pp. 209–232.

Vilibić, I., & Orlić, M. (2002). Adriatic water masses, their rates of formation and transport through the Otranto Strait. *Deep-Sea Res., **I*(49)**, 1321-1340. doi:10.1016/S0967-0637(02)00028-6

Wang, P., Tang, J., Sun, X., Liu, J., & Juan, F. (2019). Spatiotemporal characteristics of heat waves over China in regional climate simulations within CORDEX-EA project. *Clim. Dyn., **52***, 799-818. doi:10.1007/s00382-018-4167-6

Wernberg, T., Bennett, S., Babcock, R. C., De Bettignies, T., Cure, K., Depczynski, M., Dufois, F., Fromont, J., Fulton, C. J. Hovey, R. K., Harvey, E. S., Holmes, T. H., Kendrick, G. A., Radford, B., Santana-Garcon, J., Saunders, B. J., Smale, D. A., Thomsen, M. S., Tuckett, C. A., Tuya, F.,

Vanderklift, M. A., & Wilson, S. (2016). Climate-driven regime shift of a temperate marine ecosystem. *Science*, **353**, 169–72. doi: 10.1126/science.aad8745

Wilby, R. L., & Fowler, H. J. (2011). Regional Climate Downscaling, in: Modelling the Impact of Climate Change on Water Resources. (F. L. Fung, Ed.) **(3)**, pp. 34-85.

Wróbel-Niedźwiecka, I., Drozdowska, V., & Piskozub, J. (2019). Effect of drag coefficient formula choice on wind stress climatology in the North Atlantic and the European Arctic. *Oceanologia, **61*(3)**, 291-299. doi:10.1016/j.oceano.2019.02.002

Yelland, M., & Taylor, P. K. (1996). Wind stress measurements from the open ocean. *J. Phys. Oceanogr., **26*(4)**, 541-558. doi:10.1175/1520-0485(1996)026<0541:WSMFTO>2.0.CO;2

Zavatarelli, M., & Pinardi, N. (2002). The Adriatic Sea modelling system: a nested approach. *Annales Geophys.***(21)**, pp. 345–364.

Zavatarelli, M., Baretta, J. W., Baretta-Bekker, J. G., & Pinardi, N. (2000). The dynamics of the Adriatic Sea ecosystem. An idealized model study. *Deep-Sea Res., **I*(47)**, pp. 937-970.

Zore-Armanda, M., & Grbec, B. (1993). *Unusual sea temperature conditions in the Adriatic in summer 1992.* Split: Institute of Oceanography and Fisheries.

Životopis

Slavko Radilović je rođen 19.01.1989. u Splitu. Srednjoškolsko obrazovanje je završio u Prirodoslovno-matematičkoj gimnaziji (III. gimnazija) u Splitu 2007. godine. Diplomski studij završava 2012. godine na Prirodoslovno-matematičkom fakultetu (PMF) u Splitu te stječe zvanje magistra fizike - fizika okoliša. U siječnju 2015. godine upisuje doktorski studij fizike, smjer geofizika u sklopu natječaja Hrvatske zaklade za znanost (HrZZ) „*Projekt razvoja karijere mladih istraživača – izobrazba novih doktora znanosti*“. Od siječnja 2015. godine do travnja 2019. godine zaposlen je na Fizičkom odsjeku PMF-a Sveučilišta u Splitu na radnom mjestu asistenta i kao suradnik na projektu ADIOS. Od svibnja 2019. godine do danas zaposlen je kao znanstveni suradnik - doktorand na Centru izvrsnosti za znanost i tehnologiju – Integracija mediteranske regije (STIM-REI) Sveučilišta u Splitu te je suradnik na projektima CAAT i SHExtreme.

Suradnje na projektima

- 2021 – „SHExtreme“ (Estimating contribution of sub-hourly sea level oscillations to overall sea level extremes in changing climate; ERC Grant id: 853045)
- 2020 – „CAAT“ (Coastal Autopurification Assessment Technology; KK.01.1.1.04.0064)
- 2019 – „STIM-REI“ (Centar izvrsnosti za znanost i tehnologiju – Integracija mediteranske regije; KK.01.1.1.01.0003, KK.01.1.1.01)
- 2019 – „Bilateralna suradnja HRV-SRB“ (Studija za integrirani sistem za prognoziranje onečišćenja priobalnih voda u jadranskom zaljevu korištenjem atmosferskog, oceanskog i disperzijskog modela)
- 2017 – „ADIOS“ (The Adriatic decadal and interannual oscillations: observations, modelling and consequences; IP-2016-06-1955)

Nagrade i priznanja

- Dekanova nagrada za izvrsnost na studiju
- Mobilnost Sveučilišta u Splitu za usavršavanje na Međunarodnom centru za monitoring okoliša (CIMA) u Savoni, Italija
- Treće mjesto na „Laboratoriju slave“ 2011. godine za prezentaciju pod nazivom „Ima li pilota u avionu“
- Stipendist Splitsko-dalmatinske županije
- Stipendist grada Splita

Sudjelovanje u nastavnim aktivnostima:

Nuklearna fizika, Klimatski sustavi, Uvod u meteorologiju, Uvod u geofiziku, Globalne klimatske promjene, Atmosfersko onečišćenje, Numeričko modeliranje vremena i klime, Seminar iz fizike okoliša 1, 2 i 3, Istraživački rad iz fizike okoliša 1, 2 i 3

Popis radova

https://www.bib.irb.hr/pregled/profil/34393

Objavljeni CC radovi:

1. **Radilović, S.**, Koračin, D., Denamiel, C., Belušić, D., Güttler, I., & Vilibić, I. (2019). Simulated and observed air temperature trends in the eastern Adriatic. *Atmospheric Science Letters* (e951). doi:10.1002/asl.951

Prihvaćeni CC radovi:

1. **Radilović, S.**, & Koračin, D. (2021). An analysis of marine heat waves in the Adriatic with the emphasis on the 2003 and 2015 episodes. *International Journal of Climatology*.

Sudjelovanje na konferencijama, radionicama i skupovima:

1. **Radilović, S.**; Fuchs, Ž. (2011). *Third Split Workshop on Atmospheric and Oceanic Physics (SWAP)*, Brač (Hrvatska)

2. **Radilović, S.**; Koračin, D.; Fuchs, Ž. (2015). Comparing the results from RegCM4 with measurements for surface temperature in the Adriatic, *FP7 EMBRACE general assembly*, Dubrovnik (Hrvatska)

3. **Radilović, S.**; Koračin, D.; Fuchs, Ž.; Denamiel, C. (2017). Climate trends in the air and sea temperatures in the eastern Adriatic, *Joint Congress of the 6th International Conference on Meteorology and Climatology of the Mediterranean (MetMed)*, Zagreb (Hrvatska)

4. **Radilović, S.**; Koračin, D.; (2017). Evaluation of the regional climate models from the EURO-CORDEX project applied to the Adriatic region, *ADIOS workshop and kick-off meeting,* Split (Hrvatska)

5. Koračin, D.; **Radilović, S.**; Belušić, D.; Vilibić, I.; Penović, K.; Denamiel, C.; Šepić, J.; Bralić, A. (2018). Observed and simulated characteristics of climate trends in the air and sea temperatures over the coastal eastern Adriatic, *20th European Goesciences Union General Assembly, EGU*, Beč (Austrija)

6. Vilibić, I.; Somot, S.; Mihanović, H.; Denamiel, C.; Dunić, N.; **Radilović, S.**; Koračin D.; Matić, F.; Kalinić, H.; Šepić, J.; Guttler, I. (2019), *ADIOS 2nd workshop*, Split (Hrvatska)

7. Belušić, D.; **Radilović, S.**; Koračin D. (2019). Air temperature trends in the Adriatic region from the UERRA reanalyses, *SMHI workshop*, Norrköping (Švedska)

8. **Radilović, S.**, Koračin, D., Denamiel, C., Belušić, D., Güttler, I., Vilibić, I. (2019). Simulated and observed air temperature trends in the eastern Adriatic, *Interdisciplinarni poduhvati u području nanotehnologije, vode i okoliša (STIM-REI workshop)*, Split (Hrvatska)

9. Andričević, R.; Divić, V.; Grgurić, S.; Koračin, D.; Mihanović, H.; Šerić, Lj**.; Radilović, S.**; Matić, F.; Kvesić, M.; Galešić, M.; Ivanda, A.; Pavlinović, M.; Vitez, H.; Ugrin, N. (2020). *CAAT (Coastal Autopurification Assessment Technology) kick-off workshop*, Split (Hrvatska)

10. **Radilović, S.**; Đurđević, V.; Koračin, D. (2020). *Workshop on the statistical tools (GRADS) for evaluating results of regional climate and coupled models*, Beograd (Srbija)