

Obilježja vjetra u sadašnjoj i budućoj klimi na temelju simulacija regionalnih klimatskih modela za šire područje Jadrana

Belušić Vozila, Andreina

Doctoral thesis / Disertacija

2018

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://um.nsk.hr/um:nbn:hr:217:244235>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-19**



Repository / Repozitorij:

[Repository of the Faculty of Science - University of Zagreb](#)





Sveučilište u Zagrebu

PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Andreina Belušić Vozila

**OBILJEŽJA VJETRA U SADAŠNJOJ I
BUDUĆOJ KLIMI NA TEMELJU
SIMULACIJA REGIONALNIH KLIMATSKIH
MODELA ZA ŠIRE PODRUČJE JADRANA**

DOKTORSKI RAD

Zagreb, 2018.



Sveučilište u Zagrebu

PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Andreina Belušić Vozila

**OBILJEŽJA VJETRA U SADAŠNJOJ I
BUDUĆOJ KLIMI NA TEMELJU
SIMULACIJA REGIONALNIH KLIMATSKIH
MODELA ZA ŠIRE PODRUČJE JADRANA**

DOKTORSKI RAD

Mentori: doc. dr. sc. Maja Telišman Prtenjak
dr. sc. Ivan Güttler

Zagreb, 2018.

Ova je doktorska disertacija izrađena na Geofizičkom odsjeku
Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu pod vodstvom
doc. dr. sc. Maje Telišman Prtenjak i dr. sc. Ivana Güttlera, u sklopu
Sveučilišnog poslijediplomskog doktorskog studija fizike, smjer geofizika.

ZAHVALA



vim doktorskim radom zaokružuje se jedno lijepo i intenzivno razdoblje u mom životu. Zahvala za pomoć u izradi ovog rada i svemu onom što je njemu prethodilo ide mnogim osobama.

Iskrene zahvale doc. dr. sc. Maji Telišman Prtenjak i dr. sc. Ivanu Güttleru, mojim mentorima, na ukazanom povjerenju, strpljenju, savjetima i prenesenom znanju kroz sve godine mojeg doktorskog studija. Brojni zajednički razgovori, diskusije i sugestije podigli su znanstvenu razinu ovog rada.

Zahvalu upućujem svim suradnicima projekta CATURBO na čelu s profesorom dr. sc. Brankom Grisogonom i doc. dr. sc. Majom Telišman Prtenjak čijim je zalaganjem omogućeno moje zapošljavanje i istraživački rad na Geofizičkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu. Zahvalu upućujem i svim suradnicima projekta VITCLC u okviru kojeg su obavljena istraživanja vezana uz izradu doktorske disertacije. Hvala svim djelatnicima Geofizičkog odsjeka Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu na stvaranju poticajne radne sredine.

Želim se zahvaliti i Hrvatskom povjerenstvu za UNESCO pri Ministarstvu kulture i L'Oreal ADRIA što su prepoznali i podržali ovaj rad kroz program stipendiranja "Za žene u znanosti" za 2019. godinu.

Posebno se želim zahvaliti i članovima povjerenstva za ocjenu doktorskog rada dr. sc. Kristianu Horvathu, prof. dr. sc. Branku Grisogonu i prof. dr. sc. Darku Koračinu na uloženom vremenu i trudu, komentarima i sugestijama koji su ovaj rad učinili još potpunijim.

Za kraj, veliko hvala mom Mauru, mojim roditeljima Doris i Marijanu, bratu Ninu, mojoj obitelji na bezuvjetnoj podršci, razumijevanju, strpljenju i ljubavi.

Zagreb, prosinac 2018.

Andreina Belušić Vozila

SAŽETAK

Jadran je područje kompleksne orografije stoga predstavlja izazov za realistično simuliranje polja vjetra regionalnim klimatskim modelima (RCM-ima). Analizirani RCM-i uključuju modele CORDEX inicijative s prostornim korakom od 0.11° i 0.44° te model ETH instituta u Zürichu s prostornim korakom od 0.11° i 0.02° . Simulirani prizemni vjetar usporedio se s prizemnim vjetrom standardne mreže kopnenih meteoroloških postaja, s podacima dobivenih pomoću QuikSCAT satelita te s podacima ERA-Interim reanalize za šire područje Jadrana. U svrhu evaluacije koristilo se nekoliko osnovnih (pristranost, standardna devijacija, itd.), izvedenih (mjere uspješnosti) i naprednih (EOF analiza i spektralna analiza) statističkih metoda. Ova analiza je rezultirala procjenom ograničenja u simuliranju tipičnih vjetrovnih režima današnjom generacijom RCM-a. Uspješnijima su se pokazale simulacije s manjim prostornim korakom mreže, osobito u obalnom području i kod ekstremnih brzina vjetra.

Klimatske promjene u prizemnom vjetru odredile su se usporedbom polja strujanja u sadašnjoj i budućoj klimi iz CORDEX simulacija s prostornim korakom od 0.11° . Analizirao se utjecaj izbora RCM-a, rubnih uvjeta i scenarija koncentracije stakleničkih plinova (RCP4.5 i RCP8.5), a rasap među simulacijama je mjera vjerojatnosti određenih promjena. Polje strujanja analiziralo se u smislu promjena u raspodjeli brzina vjetra i u smjeru vjetra duž Jadrana. Dan je fokus na smjerove vjetra koji odgovaraju buri i jugu. Analiza je pokazala da se buduće promjene intenziviraju odabirom jačeg (RCP8.5) scenarija i približavanjem kraju 21. stoljeća. Buduće su promjene često istog reda veličine kao i interkvartilni raspon među simulacijama, međutim postoje naznake da će se broj događaja bure smanjiti duž Jadrana, ali će srednja brzina porasti u sjevernom Jadranu krajem stoljeća. Za jugo je pokazano da broj događaja u srednjem Jadranu raste, a srednja brzina vjetra opada.

Buduće promjene u buri i jugu povezane su s promjenama u strujanju nad Jadranom koristeći podatke o polju tlaka svedenog na srednju morsku razinu te geopotencijalne visine 500-hPa plohe. Razvijen je novi algoritam za određivanje tipova vremena na sinoptičkoj skali nad širim jadranskim područjem. Pokazano je da se broj ciklona nad Jadranom, osobito zimi, smanjuje te su one uglavnom zamjenjene anticiklonalnim strujanjem.

Ključne riječi: CORDEX, Jadran, klimatski scenariji, regionalni klimatski modeli, režimi vjetra, tipovi vremena

WIND CHARACTERISTICS IN THE PRESENT AND FUTURE CLIMATE OBTAINED FROM REGIONAL CLIMATE MODELS' SIMULATIONS OVER BROADER ADRIATIC REGION

EXTENDED ABSTRACT

Introduction

Over the past few decades the horizontal resolution of regional climate models (RCMs) has steadily improved, leading to a better representation of small-scale orographic features and more details in simulating dynamical aspects, especially in coastal regions and over complex terrain. Due to its complex terrain, the Adriatic region represents a major challenge for the climate simulations in simulating local wind systems realistically. The CORDEX initiative is the latest effort in multi-model regional climate downscaling in a common experimental framework. For the European (EURO-) and Mediterranean (MED-) CORDEX domains, simulations with grid spacing down to 0.11° (approximately 12.5 km) are provided for evaluation, historical periods and climate scenarios. Recently, there has been a progress toward climate simulations with horizontal grid spacing down to 0.02° (approximately 2.2 km) (Prein et al. 2015), at which the parametrization of deep convection can be switched off (Weisman et al. 1997).

For analysing a range of regional and local flow phenomena, global reanalyses and global climate models (GCMs) are not completely adequate tools because of their limited horizontal resolution (Sotillo et al., 2005; Feser et al., 2011; Menendez et al., 2014). Although global reanalyses (e.g. NCEP/NCAR reanalysis at a grid spacing of approximately 210 km or ERA-Interim reanalysis at approximately 80 km) and GCMs can effectively reproduce many large-scale climate features, they often fail in reproducing regional or local climate aspects (Rummukainen, 2010).

The improvement introduced by employing dynamical downscaling depends on various geographical factors, such as the complexity of the coastline and the representation of orography. The added value is pronounced on local scales where the capability to reliably represent small-scale events, such as extremes, increases with resolution (Herrmann et al., 2011; Giorgi et al., 2016). Previous studies on dynamically downscaled climate simulations focus mostly on present-

day temperature and precipitation, as well as their extremes and future changes (Branković et al., 2013; Ban et al., 2015).

Near-surface wind in climate studies has so far typically been assessed for seasonal offshore wind patterns and for area-averaged values (e.g. over the Mediterranean region in Herrmann et al., 2011). Also, there are no climate studies that evaluate wind fields in RCMs on time scales longer than 10 years for the Adriatic region. To complement the existing evaluation studies, we assess the near-surface wind climatology in RCM simulations over the broader Adriatic region, using land-based observations and satellite data. This will give an insight of the RCMs' limitations in reproducing typical wind regimes over the Adriatic and is an introduction to climate change analysis.

Before assessing climate change signal in wind field, it is highly beneficial to look at the pressure field projections, since it is the large scale parameter closely related to the near surface wind. Studies have shown that the Mediterranean region is projected to have less cyclonic and more anticyclonic influence until the end of 21st century (Kjellström et al., 2011; Hueging et al., 2013). Moreover, the track density of Mediterranean cyclones moving southward is projected to decrease (Zappa et al., 2015). Since the meteorological conditions over the Mediterranean region are especially under the influence of cyclones in winter season, we could expect a general decrease in wind speed during winter in the Mediterranean area (Nissen et al., 2010; Pinto et al., 2012). However, wind speed changes are not caused only by changes in large-scale pressure conditions, but also by even stronger changes in local wind systems (e.g. Bora, Sirocco, Mistral, Tramontane), which are better resolved in RCMs than in GCMs. These local wind systems often belong to severe winds and are mainly orographically induced (Horvath et al., 2008; Grisogono and Belušić, 2009; Obermann-Hellhund et al., 2017).

In the Adriatic region, northern Mediterranean, typical winds are Bora (blowing from NE quadrant perpendicular to the Dinaric Alps) and Sirocco (blowing from SE quadrant parallel to the coastline), associated with the interaction between the synoptic atmospheric disturbances passing over the Adriatic and local orography. They usually blow in the cold season, simultaneously in different parts of the Adriatic or appear as consecutive events as a cyclone passes over the Adriatic. Bora in the northern Adriatic is often accompanied with the strong Sirocco over the southern Adriatic (Penzar et al., 2001), belonging to the cyclonic type. Bora can

also gradually extend from north Adriatic along the eastern Adriatic coast to the south Adriatic corresponding often to the anticyclonic type.

A study focusing on the Adriatic Sea by Pasarić and Orlić (2004) analyzed projections for Bora and Sirocco winds from a coarse resolution (1.25°) GCM. Their results reveal that number and intensities of Bora and Sirocco events may decrease, but Sirocco episodes may last longer. However, the spatial resolution of the GCM used in their study may be too coarse to examine the spatially highly variable characteristics of the wind field (typical for Bora). One of the recent studies focusing on the Adriatic region (Pašičko et al., 2012), however, showed that there are indications for an increase in wind speed in the coastal region in the middle of 21st century. In both of these studies, the results of only one GCM or RCM are analysed, with the assumption of only one GHG concentration scenario. Bellafiore et al. (2012) assessed wind and pressure data from two RCMs over the Adriatic Sea. Authors disclose different performances by the models in reproducing wind and pressure fields and suggest using larger ensemble of RCMs in order to provide more robust climate change signal.

Finally, the main goal of this research is to determine the influence of the particular GCM/RCM combination and of the emission scenarios on the future changes in the near-surface wind field, and to detect which aspects of the wind field changes are robust in a large ensemble of CORDEX simulations over the broader Adriatic region. The results obtained for climate change signal in the wind field will be explained in terms of changes in the particular weather types defined by mean sea level pressure and geopotential height spatial distribution.

Data and methods

For the purpose of this study, a multi-model ensemble composed of ten CORDEX regional climate simulations at 0.11° and 0.44° grid spacing, COSMO convection-parameterizing simulation at 0.11° and a COSMO convection-resolving simulation at 0.02° grid spacing are evaluated. The mean daily climate model data of the two 10-m wind components (u , v) and 10-m wind magnitude are used. All CORDEX simulations are available as daily means in the entire evaluation period, forced by the ERA-Interim reanalysis from 1989-2008. For SMHI-RCA4 and DHMZ-RegCM42, sub-daily snapshots are available every 3 h. COSMO simulations are available only for evaluation period and as 1 h snapshots.

In order to evaluate the simulations, surface station observations from this region (43 stations), satellite QuikSCAT data (4 locations) over the Adriatic Sea and ERA-Interim reanalysis data have been compared against daily output obtained from the available simulations. We have grouped the stations in 4 different categories depending on the terrain type: open-sea locations (4), inland stations (22), coastal stations in the flat terrain (10) and coastal stations in the complex terrain (11). The nearest neighbour and bilinear interpolation are used to link models' grid point to geographical location of the station. Several statistical parameters and skill scores have been analysed in order to inspect the limitations of the current generation of RCMs, namely bias, standard deviation, correlation coefficient, Brier skill score, Perkins skill score, EOF analysis and spectral analysis.

For climate change assessment, 7 high-resolution (0.11°) CORDEX models are examined in terms of daily data for wind, mean sea level pressure and geopotential at 500 hPa level. Simulations cover the period from 1971 to 2099. The exception is DHMZ-RegCM42, which simulations cover the period 1971-2070. For SMHI-RCA4 and DHMZ-RegCM42, sub-daily snapshots are available every 6 h for climate projections. A moderate (RCP4.5) and a high-end (RCP8.5) GHG scenarios are considered for all available CORDEX simulations and five different CMIP5 GCMs provide BCs for selected RCMs, to quantify the sensitivity to GCM forcing. The multi-model ensemble therefore consists of 19 simulations for each scenario.

The near-surface wind over the Adriatic region is examined in near present-day ($P0$: 1971-2000) and future climate conditions ($P1$: 2011-2040, $P2$: 2041-2070, $P3$: 2071-2099). The influence of particular combination of RCM and GCM, and emission scenario on the future changes in the near-surface wind, pressure and geopotential field has been explored. The ensemble spread among different climate realizations is used to access the uncertainty in climate change projections. Two direction ranges are analysed in detail on the daily and sub-daily scale: NNE (22.5°) - ENE (67.5°) and ESE (112.5°) - SSE (157.5°), which correspond to Bora and Sirocco directions respectively. Possible links between changes in Bora and Sirocco to changes in synoptic systems (cyclones and anticyclones) are assessed. For this purpose a new objective method for defining weather types (16 categories) over the entire domain is introduced. The algorithm uses mean sea-level pressure data and 500hPa geopotential height data to identify the corresponding weather type for each day over the entire domain (5° E - 21° E, 35° N - 50° N). There is another smaller domain (11° E - 20° E, 40° N - 48° N) inside which the points have

weights 2 in the calculation. Taking into account the sign of the pressure and geopotential laplacian and the position of the pressure minimum/maximum, one of 16 weather types is assigned for each day. Finally, for each grid point the Bora/Sirocco days are overlapped with the weather types. Therefore, we have the weather type distribution for Bora and Sirocco days.

Results and concluding remarks

Results disclose that refining the grid spacing to a few km is needed to capture the small-scale wind systems properly. More details in the spatial structure of the 10-m wind are present as the grid spacing decreases. This is accompanied by more intensive wind in parts of the domain where e.g., Bora wind is a dominant type of the flow. The 0.44° RCMs rarely outperform ERA-Interim reanalysis, while the performance of the high-resolution simulations generally surpasses that of ERA-Interim.

Over the open-sea/inland locations, the models typically underestimate/overestimate the observed wind speed. The observed differences between inland and coastline stations are well captured by the models, with maximum wind speeds over the Adriatic coast decreasing when moving inland. The open-sea and inland stations are found to have a smaller ensemble spread in comparison with coastal stations in the flat terrain, where a large ensemble spread and the overestimation of the small wind speed prevail. Also, all models perform fairly well in reproducing the observed probability density estimate of the wind magnitude.

Regions of the NE wind with higher speed in the DJF (winter) season overlapping with the wind steadiness greater than 60% along the eastern Adriatic coast are observed in the ETHZ-CCLM-02 simulation. They are the part of the well-known Bora jets, which are associated with mountain passes. Opposite to the Bora wind, the Sirocco (SE) wind is not easily distinguishable in the 10-m wind climatology. However, the low wind steadiness over the open-sea area in the DJF season (particularly southward from the Middle South Adriatic) points to the occurrence of such a wind type. In the JJA (summer) season, the ETHZ-CCLM-02 simulation can successfully reproduce the JJA southern Adriatic Etesian with large persistence. In the northern Adriatic and in the JJA season, the ETHZ-CCLM-02 simulation indicates thermally induced winds (sea/land breezes and slope winds) that alternate in wind direction within 24 h. The dominant frequencies

of these wind regimes can also be seen in the spectral analysis, which discloses three large peaks at 24 h, 12 h and 8 h periods, also seen in the observational time series.

In the climate change assessment over the Mediterranean region, RCMs reveal the increase in *MSLP* and decrease in pressure gradient in DJF season and a decrease of *MSLP* in JJA season. The spatial change in the seasonal near-surface wind is related to the *MSLP* gradient, not the *MSLP* itself. Furthermore, there is a plausible link between the *MSLP* gradient signal and local wind systems over the Adriatic region (Bora and Sirocco).

RCMs' simulations indicate a northward shift over Adriatic of winter cyclones whereas Sirocco expands along northern Adriatic but with overall smaller intensity in its mean wind speed. Therefore, the number of cyclonic Bora events over the northern Adriatic is reduced. However, cyclones that reach to the southern Adriatic produce Bora over the northern Adriatic with higher intensity within the well-known Bora jets. In JJA period, we found an increase in number of NNE-ENE flows within the locations of the Bora jets.

The climate change signal strengthens approaching the end of 21st century, but the spread between the simulations on the daily time scale is mostly comparable to the order of magnitude of the changes in ensemble median. The ensemble spread among RCMs simulations is larger in JJA season compared to the DJF season. Over the Adriatic coast in DJF season synoptic (large scale) conditions mostly dominate in the near-surface wind formation. In contrast, in JJA season we could not detect a uniform behavior when looking at the same driving GCM results. This may be due to weaker synoptic influence and larger local effect due to variable wind speeds associated with thermal effects of orography in summer.

The uncertainty introduced by different emission scenario is less pronounced in our results. The difference between two scenarios increases by the end of 21st century. We detected the change in sign of the signal depending on the scenario applied when analysing the station data. This is not surprising since projected changes are not large. Therefore, the necessity for a multi-model ensemble-based assessment given the model-induced spread in the results is especially pronounced when analysing the possible future changes in the wind field.

Keywords: Adriatic region, Climate scenario, CORDEX, Regional climate models, Weather types, Wind regimes

POPIS KRATICA I POJMOVA

<i>BSS</i>	<i>Brier skill score</i>
<i>EOF</i>	<i>empirijske ortogonalne funkcije</i>
<i>ePDF</i>	<i>empirijska funkcija gustoće vjerojatnosti</i>
<i>GCM</i>	<i>globalni klimatski model</i>
<i>GHG</i>	<i>scenarij emisije stakleničkih plinova</i>
<i>IJI</i>	<i>istok-jugoistok</i>
<i>ISI</i>	<i>istok-sjeveroistok</i>
<i>JI</i>	<i>jugoistok</i>
<i>JJI</i>	<i>jug-jugoistok</i>
<i>JZ</i>	<i>jugozapad</i>
<i>MSLP</i>	<i>tlak sveden na srednju morsku razinu</i>
<i>PCC</i>	<i>klimatski parametar izveden pomoću PSS parametra</i>
<i>PSS</i>	<i>Perkins skill score</i>
<i>QQ</i>	<i>kvantil-kvantil</i>
<i>RCM</i>	<i>regionalni klimatski model</i>
<i>RCP</i>	<i>mjera porasta koncentracije stakleničkih plinova</i>
<i>RMSD</i>	<i>korijen srednjeg kvadratnog odstupanja</i>
<i>RMSE</i>	<i>korijen srednje kvadratne pogreške</i>
<i>SI</i>	<i>sjeveroistok</i>
<i>SSI</i>	<i>sjever-sjeveroistok</i>
<i>SZ</i>	<i>sjeverozapad</i>

SADRŽAJ

SAŽETAK.....	i
EXTENDED ABSTRACT.....	iii
POPIS KRATICA I POJMOVA.....	ix
1 UVOD.....	3
1.1 Neka obilježja bure i juga na Jadranu.....	3
1.2 Klimatsko modeliranje globalnim i regionalnim modelima.....	5
1.2.1 Klimatske projekcije u globalnim i regionalnim modelima.....	8
1.2.2 Klimatsko modeliranje nad Jadranom.....	12
1.3 Motivacija i ciljevi istraživanja.....	13
2 PODACI.....	14
2.1 Prizemna mjerenja vjetra.....	14
2.2 Mjerenja vjetra QuikSCAT satelitom.....	15
2.3 ERA-Interim reanaliza.....	16
2.4 Regionalni klimatski modeli (RCM).....	17
3 METODOLOGIJA.....	20
3.1 Statistički parametri.....	20
3.2 Definicija tipova vremena.....	24
4 REZULTATI I DISKUSIJA.....	28
4.1 Evaluacija simulacija u sadašnjoj klimi.....	28
4.1.1 Prostorna obilježja vjetra.....	28
4.1.2 Osnovne statističke mjere u vremenu i prostoru.....	29
4.1.3 Mjere uspješnosti.....	41
4.1.4 Ruža vjetra i EOF analiza.....	46
4.1.5 Spektralna analiza.....	50
4.2 Usporedba mjerenja i povijesnog razdoblja.....	55
4.3 Klimatske projekcije – promjene u polju prizemnog tlaka.....	60
4.3.1 Sinoptička analiza tlaka.....	60
4.3.2 Tipovi vremena.....	64

4.4 Klimatske projekcije – promjene u polju prizemnog vjetra.....	68
4.4.1 Analiza brzine vjetra.....	68
4.4.2 Čestine vjetra s obzirom na smjer.....	74
4.4.3 Bura i jugo.....	78
4.5 Veza između vremenskih tipova i bure i juga.....	84
4.5.1 Bura.....	84
4.5.2 Jugo.....	86
5 ZAKLJUČAK.....	95
6 LITERATURA.....	100
Dodatak A.....	113
Dodatak B.....	115
Dodatak C.....	117
Dodatak D.....	121
Dodatak E.....	124
Životopis.....	128
Popis radova.....	130

1 UVOD

Nad područjem Jadrana, u sjevernom Sredozemlju, lokalni vjetar kao što je bura (npr. Grisogono i Belušić, 2009) ili jugo (npr. Jurčec i sur., 1996) nastaju uslijed interakcije između sinoptičkih poremećaja koji prolaze preko Jadrana i lokalne orografije. Područje uz Jadran obilježeno je izrazito kompleksnim terenom i ostrim orografskim gradijentima. Tome pridonose Dinaridi koji se pružaju u smjeru sjeverozapad-jugoistok i odvajaju usko obalno područje od nizinske unutrašnjosti. Bura puše iz smjera sjeveroistoka (SI), okomito na Dinaride i osjeća snažan utjecaj terena, dok jugo puše iz smjera jugoistoka (JI) paralelno s obalom Jadrana. Osim bure i juga u jadranskom području javljaju se još i etezije te lokalni termički vjetar (npr. smorac i kopnenjak) uglavnom u toplom dijelu godine (Telišman Prtenjak i sur. 2010a; 2010b).

Pojava bure i juga može se sagledati na nekoliko skala; od sinoptičke skale (~1000 km) preko mezoskalnih efekata (od 1 km do 500 km) do mikroskale (turbulentne skale <1 km). Procesi razmjene na mikroskali, usko povezani s prizemnim vjetrom, iznad kompleksnog terena još nisu ni približno dobro shvaćeni (Serafin i sur., 2018). Svaka prostorna komponenta ima svoje klimatološke karakteristike i podliježe klimatskim promjenama. U ovom doktorskom radu bit će govora o klimatskim obilježjima prizemnog vjetra nad Jadranom s naglaskom na buru i jugo. Fokus je na sinoptičkim i mezoskalnim karakteristikama prizemnog vjetra kako u sadašnjoj tako i u budućoj klimi do kraja 21. stoljeća.

1.1 Neka obilježja bure i juga na Jadranu

Dosadašnje poznavanje vjetra, a time i bure i juga na Jadranu, temelji se na analizama mjerenog prizemnog vjetra (npr. Poje, 1992) i vjetra dobivenog satelitskim mjerenjima (npr. Zecchetto i Cappa, 2001). Prostorno potpuniju sliku omogućile su numeričke simulacije vjetra dobivene mezoskalnim modelima (npr. Horvath i sur. 2008; Stiperski i sur., 2012; Telišman Prtenjak i sur., 2015). Analize pokazuju da je bura najjača, najčešća i najstalnija na sjevernom Jadranu (područje

oko Senja). Osnovna obilježja bure su njena prostorna i vremenska varijabilnost u brzini vjetra (npr. Grisogono i Belušić, 2009; Telišman Prtenjak i sur., 2015) koja se očituje kao izmjena područja pojačanog strujanja zraka (eng. *Bora jets*) i tišina (eng. *Bora wakes*) duž obale. Mlazovi bure povezani su s planinskim prijevojima (npr. Grubišić 2004; Kuzmić i sur., 2013) koji lokalno utječu na intenzitet i trajanje bure. Suprotno tome, jugo je manje pod utjecajem obalne orografije. Maksimalne brzine vjetra su uglavnom manje te se jugo rjeđe javlja nego bura. Analizirana mjerenja (npr. Poje, 1992; Penzar i sur., 2001) su pokazala da je jugo intenzivnije i češće na južnom dijelu Jadrana nego sjeverno od Splita.

Bura i jugo se uglavnom javljaju u hladnom dijelu godine, istovremeno u različitim dijelovima Jadrana ili se pojavljuju kao uzastopni događaji prolaskom ciklone preko Jadrana. Obzirom na položaj sinoptičkih sustava za vrijeme puhanja bure razlikujemo ciklonalnu, anticiklonalnu i frontalnu buru (npr. Pandžić i Likso, 2005; Horvath i sur., 2008; Šoljan i sur., 2018), dok je jugo uglavnom ciklonalno (npr. Pandžić i Likso, 2005), a rjeđe anticiklonalno (Penzar i sur. 2001). Ciklonalna bura u sjevernom Jadranu popraćena je često jakim jugom u južnim dijelom Jadrana (Penzar i sur., 2001), dok se anticiklonalna bura može postepeno proširiti sa sjevernog Jadrana duž jadranske obale sve do južnog Jadrana. Istraživanja pojedinih događaja bure (npr. Gohm i sur., 2008; Prtenjak i sur., 2015; Šoljan i sur., 2018) pokazala su da je anticiklonalna bura češće dublja i slabijeg intenziteta od ciklonalne.

S obzirom na to da i bura i jugo spadaju u vjetar obalnog planinskog područja, smjer puhanja također određuje dinamiku obalnog mora za vrijeme puhanja pojedinog vjetra. Tako bura, zbog snažne interakcije najnižeg sloja zraka i površine mora, ima velik utjecaj na termohalinu cirkulaciju Jadrana (npr. Vilibić i sur., 2013), strujanje (npr. Orlić i sur. 1986) i dinamiku valova (npr. Vilibić i sur., 2017), dok jugo može dovesti do poplavljivanja riva uz samu obalu (npr. Međugorac i sur., 2015; 2018). Ovi rezultati upućuju da je poznavanje vjetra u budućoj klimi važno kako iz meteorološkog i klimatološkog kuta, tako i oceanografije te ostalih struka/djelatnosti koje ovise o atmosferskim uvjetima.

1.2 Klimatsko modeliranje globalnim i regionalnim modelima

Klimatske karakteristike atmosfere mogu se određivati pomoću klimatskih modela opće cirkulacije atmosfere (eng. *general circulation model*, *global climate model*, GCM) i/ili regionalnim klimatskim modelima (eng. *regional climate model*, RCM) te predstavljaju vrlo koristan alat u analizi dosadašnje i procjeni buduće klime. Oni opisuju različite dijelove Zemljinog sustava te njihovo nelinearno međudjelovanje. Profinjenje prostornih polja iz GCM-a može se provesti pomoću RCM-a postupkom dinamičke prilagodbe. Dok u simuliranju sadašnje klime modeli koriste mjerene podatke, za prošlu i buduću klimu modeli sami razvijaju interna gibanja. Za računanje vrijednosti u budućoj klimi primjenjuju se pojedini klimatski scenariji.

Nova generacija RCM-a razvijena je unutar CORDEX inicijative (Giorgi i Gutowski Jr., 2015; Giorgi i sur., 2015). Regionalne klimatske simulacije unutar CORDEX baze čine ansambl modela pomoću kojih se istražuju regionalni i lokalni klimatski fenomeni, njihove promjene i trendovi. CORDEX inicijativa se počela razvijati početkom 2009. godine s ciljem stvaranja usklađene baze podataka koja uključuje dinamičke prilagodbe RCM-ima na dva načina: (i) različiti GCM-i služe za početne i rubne uvjete za isti RCM i (ii) isti GCM služi za početne i rubne uvjete za različite RCM-ove. Postoji i treća opcija dinamičke prilagodbe, ista kombinacija GCM-a i RCM-a koristeći različite inicijalizacije, no ona se rijetko provodi unutar CORDEX projekta.

CORDEX simulacije postoje za tri razdoblja i to redom: *evaluacijsko* (1979./1989.-2008.) gdje RCM-ima početni i rubni uvjeti dolazi iz ERA-Interim reanalize (Dee i sur., 2001), a služi za određivanje sustavnih pogrešaka i ograničenja RCM-a, *povijesno* (1951./1971.-2005.) te *projekcije* (2006.-2100.). Za procjenu budućeg stanja početni i rubni uvjeti za RCM dolaze iz GCM-a izračunatih unutar CMIP5 projekta (Williams i sur., 2011.), a uključuju nekoliko scenarija emisije stakleničkih plinova. S obzirom na koncentraciju stakleničkih plinova (eng. *Greenhouse gasses*, GHG), scenarije dijelimo na: RCP2.6, RCP4.5, RCP6.0 i RCP8.5 (eng. *Representative Concentration Pathway*, RCP). Broj uz oznaku RCP predstavlja iznos u W/m^2

za koje se povećava ravnotežno zračenje na vrhu atmosfere do kraja 21. stoljeća (Nakićenović i sur., 2000; Moss i sur., 2008; Van Vuuren i sur., 2008).

Početni prostorni mrežni korak CORDEX RCM-a je 0.44° . Za domene koja obuhvaćaju Europu (EURO-CORDEX) i Sredozemlje (MED-CORDEX) razvijaju se usklađene simulacije i projekcije s prostornim mrežnim korakom od 0.11° . Intenzivno se radi i na dodatnom profinjenju prostornog mrežnog koraka simulacija prema 0.02° (npr. CRM2 model iz rada Ban i sur., 2014; 2015; Prein i sur., 2015; Belušić i sur., 2018a). Smanjenje prostornog koraka mreže modela omogućuje isključivanje parametrizacije duboke konvekcije (Weismann i sur., 1997) u postavkama samog modela te se dopušta modelu da svojom dinamikom razluči proces duboke konvekcije.

Profinjenjem prostornog koraka simulacija, nameću se dva važna istraživačka pitanja vezana uz dodanu vrijednost (eng. *added value*) simulacija s manjim prostornim mrežnim korakom (Kotlarski i sur., 2014; Rummukainen, 2016). Prvo, još uvijek nije sasvim jasno nude li RCM-i točnije simulacije (u smislu smanjenja sustavnih pogrešaka i/ili realnijih simulacija ekstremnih događaja) od globalnih reanaliza (npr. ERA-Interim) ili GCM-a. Drugo je pitanje pružaju li simulacije s manjim prostornim korakom (npr. 0.11° i 0.02°) dodatne informacije u polju nekog prizemnog parametra koje simulacije s grubim prostornim korakom (0.44°) nisu uspjele vjerodostojno reproducirati.

Usporedbom dosadašnjih rezultata pokazano je da globalne reanalize nisu prikladan alat za proučavanje regionalnih i lokalnih meteoroloških elemenata zbog grubog prostornog mrežnog koraka (Sotillo i sur., 2005; Feser i sur., 2011; Herrmann i sur., 2011; Menendez i sur., 2014). Iako globalne reanalize (npr. NCEP/NCAR reanaliza s prostornim korakom oko 210 km ili ERA-Interim oko 80 km) i GCM-i mogu učinkovito reproducirati obilježja velike skale, često loše reproduciraju regionalne i lokalne klimatske aspekte, osobito u područjima pod izrazitim utjecajem orografije (Rummukainen, 2010). Dinamika velike prostorne i vremenske skale dobro je reproducirana i unutar GCM-a, pokazano na primjeru sezonskih srednjaka (Vautard i sur., 2013; Di Luca i sur., 2015).

Poboljšanja uvedena dinamičkom prilagodbom RCM-a ovise ponajprije o geografskim obilježjima područja za koje se provode simulacije, kao što su razvedenost obale i kompleksnost orografije. Sotillo i sur. (2005) usporedili su jedan RCM s NCEP/NCAR reanalizom za nekoliko prizemnih varijabli i pronašli su veća poboljšanja za Sredozemno more nego za Atlantski ocean i za obalne plutače nego za plutače na otvorenom moru. U radovima nekolicine autora (npr. Sotillo i sur., 2005; Winterfeldt i Weisse 2009; Herrmann i sur., 2011) u kojima su usporedili nekoliko RCM-a s reanalizama pokazano je da su nedostaci zbog grubog prostornog koraka reanalize ispravljani kroz RCM-e (smanjenje pristranosti (eng. *bias*) i korijena srednje kvadratne pogreške (RMSE)) nauštrb smanjenog vremenskog koeficijenta korelacije. Kao vjerojatan razlog manjeg vremenskog koeficijenta korelacije navode činjenicu da RCM-i ne asimiliraju mjerenja. Prednosti RCM-a nad reanalizama osobito se uočavaju za vjetar u obalnom području te kod ekstremnih brzina vjetra (Sotillo i sur., 2005; Belušić i sur., 2018a).

Uspoređujući rezultate za vjetar usrednjen za područje Sredozemlja iz RCM-a s različitim prostornim korakom (50 km i 10 km u radu Herrmann i sur., 2011), autori su pronašli zanemarive razlike ($< 1\%$). Takvim se pristupom izgladuje polje vjetra te se lokalno strujanje inducirano orografijom zanemaruje. Međutim, značajne su razlike uočene kod simulacija s manjim prostornim korakom mreže RCM-a, lokalno uz obale Sredozemnog mora u područjima velikih brzina vjetra (npr. Lionski zaljev, Jadransko i Egejsko more).

Dosadašnje klimatske studije koje se bave usporedbom RCM-a s različitim prostornim koracima na lokalnoj razini, pokazale su da RCM-i s manjim prostornim korakom uspijevaju dobro opisati prostornu strukturu, lokalni intenzitet te ekstreme nekog prizemnog parametra (npr. Branković i sur., 2013; Prein i sur., 2015; Mayer i sur., 2015; Torma i sur., 2015; Belušić i sur., 2018a). Profinjenjem prostornog koraka javljaju se detalji na lokalnoj razini koje RCM-i s grubljim korakom uopće nemaju mogućnosti razlučiti (Herrmann i sur., 2011; Giorgi i sur., 2016). Opis parametara na dnevnoj i manjoj vremenskoj skali koji ovise o međudjelovanju na dvije prostorne skale (između orografije i atmosferske cirkulacije na sinoptičkoj skali) pokazalo je vrijednost RCM-a s finijim prostornim mrežnim korakom. Pokazano je i da je dodana vrijednost u simulacijama s manjim prostornim korakom osobito izražena u obalnom (Vautard i

sur., 2013; Güttler i sur., 2015) i planinskom (Ban i sur., 2014; Prein i sur., 2016; Rummukainen, 2016) području.

Usrednjavanje rezultata simulacija s malim prostornim korakom na mrežu simulacija koji imaju grublji prostorni korak može dovesti do poboljšanja rezultata, odnosno ukazuje na dodanu vrijednost temeljenu na fizikalnim procesima simulacija s manjim prostornim korakom. Primjer takvog poboljšanja pronađen je za oborinu u Alpama (Torma i sur., 2015) usrednjavanjem rezultata simulacija s prostornim korakom 0.11° na mrežu s grubljim prostornim korakom (0.44°) (eng. *upscaling*). Suprotno, interpolacijom s grube na finu mrežu nije se dobilo poboljšanje prostornih obilježja oborine. To je dokaz dodane vrijednosti na fizikalnoj osnovi do koje je došlo zbog detaljnije strukture orografije sadržane unutar simulacijama s finijim prostornim korakom.

Dodatno profinjenje prema vrlo visokoj razlučivosti za temperaturu i oborinu proučavali su Ban i sur. (2014; 2015) uspoređujući COSMO simulacije s prostornim korakom 0.11° i 0.02° . Za razliku od rezultata temeljenih na dnevnim srednjacima koji nisu pokazali razlike između simulacija s različitim prostornim korakom, kod rezultata dobivenih pomoću satnih vrijednosti uočavaju se značajne razlike. Simulacija s korakom 0.11° podcjenjuje jaku i precjenjuje slabu oborinu, dok se simulacija s korakom 0.02° vrlo dobro slaže s mjerenim vrijednostima.

Polje vjetra nad Jadranskim područjem simulirano najnovijom generacijom RCM-a za sadašnju klimu još uvijek nije istraženo. Stoga najnovija generacija RCM-a otvara mogućnost klimatološke analize polja vjetra koristeći ansambl sastavljen od desetak klimatskih simulacija.

1.2.1 Klimatske projekcije u globalnim i regionalnim modelima

Nakon određivanja ograničenja sadašnje generacije klimatskih simulacija, usporedbom s mjerenjima, važno je također proučiti klimatske projekcije imajući na umu prednosti i mane pojedinog RCM-a. Osim toga, klimatske projekcije, pod utjecajem su nekoliko izvora nepouzdanosti za procjenu buduće klime, uključujući rubne i početne uvjete te scenarije emisije stakleničkih plinova (Giorgi i Bi, 2000; Wu i sur., 2005). Rasap između različitih klimatskih

realizacija unutar ansambla služi za određivanje nepouzdanosti klimatskih projekcija, a rezultati se najčešće prikazuju u smislu vjerojatnosti za ostvarivanje određenog događaja (u %).

Najšire istraženi parametri po pitanju klimatskih projekcija su temperatura, oborina i tlak. Tako je uočeno da će se ekstremne vrijednosti temperature i oborine iznad Europe intenzivirati u budućoj klimi. Pozitivni ekstremi temperature će se najvjerojatnije povećati za 2-4°C iznad sjeverne, te 4-6°C iznad južne Europe, dok će se negativni ekstremi ublažiti za 1-2°C iznad sjeverne Europe te 2-6°C iznad srednje i južne Europe (Nikulin i sur., 2011). U skladu s time bit će češći i toplinski valovi iznad Europe (Beniston i sur., 2007). Projekcije za promjene u ekstremnim količinama oborine pokazuju trend povećanja intenzivne oborine na sjeveru, a smanjenja na jugu Europe (Nikulin i sur., 2011). Dodatno, Beniston i sur. (2007) naglašavaju da će te promjene biti izraženije u toplijem dijelu godine, uz izražene sušne periode na Sredozemlju.

Dok je za temperaturu i oborinu rasap među različitim simulacijama uglavnom mali do umjeren, Rockel i Woth (2007) te Outten i Esau (2013) naglašavaju da RCM-i ne daju dosljedan signal za određenu lokaciju ili za predznak najistaknutije promjene u projekcijama za brzinu prizemnog vjetra. Štoviše, autori su pokazali da su promjene koje pokazuju simulacije za buduću klimu istog reda veličine, ili čak i manje od nepouzdanosti same procjene ekstremnih brzina. Usprkos tome, vrlo je važno odrediti buduće promjene u obilježjima polja vjetra i dokumentirati nepouzdanosti unutar sadašnje generacije RCM-a (npr. promjene u intenzitetu, trajanju i čestini), posebice za područja koja su vrlo često pod utjecajem olujnog vjetra kao što je slučaj Jadrana.

Tlak sveden na srednju morsku razinu (*MSLP*), parametar koji pokazuje utjecaj dinamike velike skale, usko je povezan s prizemnim vjetrom (npr. Hueging i sur., 2013; Cardoso i sur., 2016). Pokazano je da RCM-i zadržavaju gotovo sva obilježja velike skale koja primaju iz GCM-a, ali GCM-i također utječu na dio klimatskog signala koji dolazi s manje vremenske i prostorne skale (Räisänen i sur., 2004; Laprise i sur., 2008; Kjellström i sur., 2011). Nad područjem Sredozemlja do kraja 21. stoljeća mogao bi se smanjiti doprinos ciklona, a povećati anticiklonalni utjecaj (Kjellström i sur., 2011; Hueging i sur., 2013; Reyers i sur., 2015). Projekcije GCM-a pokazuju da bi se Islandski minimum i Azorski maksimum mogli pomaknuti sjeveroistočno (npr. Hu i Wu, 2004; Reyers i sur., 2015) te bi time došlo i do jačanja gradijenta tlaka iznad Europe

(Knippertz i sur., 2000; Hu i Wu, 2004). Nadalje, gustoća putanja ciklona koje prelaze južnim Sredozemljem također bi se mogla smanjiti (Zappa i sur., 2015). Dok su Grieger i sur. (2014) pokazali da simulacije predviđaju da će se najveće promjene dogoditi upravo u samim putanjama ciklona, Bengtsson i sur. (2009) su pokazali da je pomicanje putanja ciklona prema sjeveru najizraženije u toplom djelu godine. Nadalje, istraživanje temeljeno na mjerenjima (McCabe i sur., 2001) pokazalo je značajno smanjenje ciklonalne aktivnosti u sjevernim umjerenim geografskim širinama u posljednjih 40 godina (1959.-1998.).

S obzirom na to da su meteorološki uvjeti nad područjem Sredozemlja pod izrazitim utjecajem ciklona u hladnom dijelu godine, posljedično možemo očekivati smanjenje srednje brzine vjetra tijekom zime (Nissen i sur., 2010; Pinto i sur., 2012). Međutim, promjene u brzini prizemnog vjetra nisu samo posljedica dinamike velike skale, već su i posljedica eventualnih promjena u režimima lokalnog vjetra (npr. bura, jugo, mistral, tramontana), koji su mnogo bolje razlučeni u simulacijama RCM-a nego u simulacijama GCM-a. Navedeni lokalni tip strujanja često pripada vjetru koji doseže olujnu jakost, a uglavnom je generiran orografijom (Horvath i sur., 2008; Grisogono and Belušić, 2009; Obermann-Hellhund i sur., 2017; Belušić i sur., 2018a; 2018b).

Klimatske projekcije za brzinu vjetra tijekom 21. stoljeća pokazuju pozitivan signal (projekcije-referentno povijesno razdoblje) iznad sjeverne, a negativan signal iznad južne Europe. Sukladno tome istraživanja su pokazala da postoji mogućnost za povećanje energije vjetra u klimatskim projekcijama za sjevernu Europu u toplom dijelu godine u kontinentalnim područjima te u hladnom dijelu godine u obalnim područjima (Pryor i sur., 2005). Isti su autori pronašli razlike u budućim obilježjima smjera vjetra, koji pokazuje smanjenje relativne čestine istočnog vjetra i povećanje čestine JZ vjetra u usporedbi s referentnim povijesnim razdobljem. Međutim, buduće promjene u smjeru vjetra su često reda veličine pogreške RCM simulacija obzirom na mjerenja ili reda veličine rasapa između simulacija unutar promatranog ansambla (Merryfield i sur., 2009; Pryor i sur., 2012).

Istraživanja su također pokazala da će se povećati brzine ekstremnoga vjetra (iznad 75. percentila) nad Sjevernim morem i sjevernom Europom u drugoj polovici 21. stoljeća (Pryor i

Barthelmie, 2003; Pryor i sur., 2012). Nekolicina autora je istraživala ekstremne brzine vjetra iznad sjeverne Europe i Sredozemlja. Nikulin i sur. (2011) nije pronašao jednoznačan prostorni uzorak za promjene u 20-godišnjem povratnom razdoblju brzine vjetra unutar ansambla od šest simulacija dobivenih forsiranjem jednog RCM-a različitim GCM-ovima. Beniston i sur. (2007), Rockel i Woth (2007), Schwierz i sur. (2010) su istraživali simulacije PRUDENCE projekta (Christensen i sur., 2002), a Donat i sur. (2011) simulacije ENSEMBLES projekta (van der Linden i Mitchell, 2009). Navedene studije su također pokazale vrlo slične promjene ekstremnih brzina vjetra iznad 90. percentila za kraj 21. stoljeća; povećanje brzine ekstremnoga vjetra nad Sjevernim morem, sjevernom Europom i Velikom Britanijom zajedno sa smanjenjem brzine ekstremnoga vjetra nad Sredozemljem. Autori su pronašli najizraženije promjene nad morem. Posljedično, energija vjetra nad južnom Europom se smanjuje do 15% u jesen, te 5-10% na godišnjoj skali (Tobin i sur., 2016). Jedina je iznimka Egejsko more koje bi moglo u budućnosti imati povećanje potencijala energije vjetra u ljeto i jesen (Hueging i sur., 2013). Osim za vjetropotencijal, buduće promjene u brzini vjetra važne su i za industriju i šumarstvo (Pryor i Schoof, 2010).

Prilikom dosadašnjih istraživanja prizemnog vjetra u budućoj klimi iz RCM-a, autori su uglavnom analizirali rezultate za veća geografska područja te dalje od obalnog područja (npr. globalno za sjever ili jug Europe, Sredozemno more, Sjeverno more). Može se uočiti da nedostaju istraživanja lokalnog, često geografski specifičnog vjetra pomoću RCM-a. To se osobito odnosi za područje Sredozemlja gdje takav vjetar vrlo često po intenzitetu pripada olujnom vjetru. Zbog interakcije strujanja s orografijom koja može lokalno značajno modificirati strujanje, područje Sredozemlja predstavlja izazov za simuliranje polja prizemnog vjetra iz RCM-a.

Tek se noviji radovi temelje na analizi lokalnih fenomena iz RCM-a za područje zapadnog Sredozemlja (Obermann i sur., 2016; Obermann-Hellhund i sur., 2017). Autori su proveli istraživanje usmjereno na sadašnje i buduće pojavljivanje mistrala i tramontane, tipova vjetra u Lionskom zaljevu u zapadnom Sredozemlju. Pokazali su da analizirani RCM-i mogu dobro simulirati događaje mistrala i tramontane ako je cirkulacija velike skale dobro prikazana unutar modela koji predstavlja rubne i početne uvijete za RCM. Međutim, u simulacijama RCM-a, u

danima s mistralom i tramontanom, brzina vjetra je podcijenjena nad morem, a precijenjena nad kopnom. Smjer vjetra je uglavnom dobro simuliran, a odstupanja od izmjerenih vrijednosti su najveća u području gdje glavni mlaz mistrala i tramontane prelazi s kopna na more. Kod proučavanja klimatskih projekcija, autori su primijetili samo male promjene u čestini mistrala za RCP4.5 i RCP8.5 scenarije, ali značajan pad u čestini tramontane bez promjene u brzini vjetra tijekom tih događaja. Time su smanjenje u brzini 90. percentila brzine vjetra povezali s manjim brojem pojavljivanja tramontane. Nadalje, autori ukazuju na potrebu istraživanja utjecaja istog GCM-a na različite RCM-e koje oni nisu bili u mogućnosti provesti.

1.2.2 Klimatsko modeliranje nad Jadranom

Istraživanja dosadašnjih mjerenja i numeričko modeliranje vjetra na području Jadrana mogu se grupirati u nekoliko skupina: (i) mezoskalna meteorološka i oceanografska istraživanja (npr., Cavaleri i sur., 1996; Enger i Grisogono, 1998; Telišman Prtenjak i sur., 2010; Horvath i sur., 2011; Vilibić i sur., 2013, 2017; Međugorac i sur., 2015; 2018), (ii) statistička prilagodba reanaliza (npr. Heimann, 2001.), (iii) primjena GCM-a (Pasarić i Orlić, 2004.) i (iv) primjena RCM-a (npr. Bellafigliore i sur., 2012; Benetazzo i sur., 2012; Pašičko i sur., 2012).

Sukladno tome klimatske su projekcije vjetra za područje Jadrana analizirane u sklopu posljednje dvije grupe. Analizirajući jednu RCM simulaciju Pašičko i sur. (2012) su pokazali da postoji naznaka da će sredinom 21. stoljeća srednja brzina vjetra porasti u obalnom području. Bellafigliore i sur. (2012) su analizirali podatke vjetra i tlaka iz dvije RCM simulacije iznad Jadrana. Autori su pronašli različito ponašanje modela i predlažu korištenje većeg ansambla RCM-a kako bi prikazani klimatski signal bio robustan. Benetazzo i sur. (2012) su pomoću jedne RCM simulacije nad Jadranom pokazali da će se do kraja 21. stoljeća intenzitet morskih valova potencijalno smanjiti zbog promjena u buri i jugu. Naglašavaju da su potrebna daljnja istraživanja da bi se odvojio utjecaj pojedinog tipa vjetra. Klimatsko istraživanje koje su proveli Pasarić i Orlić (2004), s fokusom na buru i jugo, zasniva se na rezultatima GCM-a s grubim prostornim korakom (1.25°). Njihovi rezultati pokazuju da se krajem 21. stoljeća može očekivati smanjenje

broja događaja i intenziteta bure i juga, ali dulje trajanje epizoda juga. Međutim, prostorna razlučivost GCM-a je pregruba da se opišu fina prostorna obilježja vjetra (tipično za buru).

1.3 Motivacija i ciljevi istraživanja

Jadran je područje kompleksne orografije i stoga predstavlja izazov za realistično simuliranje polja vjetra iz RCM-a. Stoga ovo doktorsko istraživanje pridonosi poznavanju klimatologije vjetra iz nekoliko aspekata. Poželjno je provesti evaluaciju prizemnog vjetra iz CORDEX simulacija u kompleksnom obalnom području čime će se odrediti ograničenja i poboljšanja korištenja sadašnje generacije RCM-a. Istovremeno, analiza *ansambla* RCM-a visoke razlučivosti s izrazitim fokusom na lokalne fenomene kao što su bura i jugo predstavlja proširenje dosadašnjih istraživanja prizemnog vjetra za šire područje Jadrana.

Sve navedeno vodi prema glavnoj hipotezi ovog rada da će se uslijed promjene u polju tlaka na globalnoj razini kao rezultat promjene opće cirkulacije atmosfere promijeniti učestalost, intenzitet i prostorna raspodjela lokalnih tipova vjetra na Jadranu. Prilikom ispitivanja hipoteze postavljeni sljedeći ciljevi ovog rada:

- I. Istražiti i evaluirati klimatološka obilježja polja strujanja iz RCM-a u sadašnjoj klimi pomoću prizemnih mjerenja te mjerenja satelitom QuikSCAT nad morem. Pri tome se želi proučiti ima li manji prostorni korak mreže RCM-a za posljedicu manje pogreške u simuliranju vjetra na području Jadrana.
- II. Analizirati klimatske projekcije u polja tlaka i vjetra, odrediti utjecaj pojedine kombinacije GCM-ova/RCM-ova i emisijskog scenarija na promjene u prizemnom vjetru nad Jadranom i otkriti koje su promjene robusne unutar ansambla CORDEX simulacija.
- III. Povezati buduće promjene u buri i jugu s promjenama u osnovnim sinoptičkim sustavima (ciklone, anticiklone) kroz određivanje tipova vremena na sinoptičkoj skali iz simuliranih polja vjetra, tlaka i geopotencijala u sadašnjoj i budućoj klimi.

Ciljevi istraživanja ovog rada proširit će naše spoznaje o promjenama prizemnog strujanja nad širim područjem Jadrana uslijed klimatskih promjena.

2 PODACI

2.1 Prizemna mjerenja vjetra

Prizemna mjerenja brzine i smjera vjetra na 10 m visine sa sinoptičkih postaja korištena su za područje Hrvatske, Slovenije, Bosne i Hercegovine, Crne Gore i dijela Italije (Sl. 1 i 2). Prekrivenost domene od interesa mjerenjima je vrlo nehomogena, s obzirom na to da ne postoje mjerenja vjetra interpolirana na pravilnu mrežu. Mjerenja vjetra na 10 m iznad tla za period od 1996./2001. (ovisno o postaji) do 2008. preuzeta su u SYNOP formatu iz nekoliko izvora: (i) NCDC/NOAA baze podataka (Smith i sur., 2011), (ii) baze podataka Državnog hidrometeorološkog zavoda (DHMZ) te (iii) baze podataka Hrvatske kontrole zračne plovidbe (HKZP).

Kontrola kvalitete NCDC/NOAA podataka (<https://www.ncdc.noaa.gov/isd>) vrši se prije objave samih podataka na mrežnim stanicama baze, dok su mjerenja preuzeta s hrvatskih institucija lokalno kontrolirana na pripadnim institucijama. Zbog prethodnih provjera je, nakon preuzimanja mjerenih podataka, odrađena jednostavna dodatna vizualna kontrola podataka na izračunatim dnevnim srednjacima.

Dnevni srednjaci računati su ako je barem 5 od 8 SYNOP podataka bilo dostupno za pripadni dan, u suprotnom je dnevni srednjak za taj dan proglašen nedefiniranom vrijednosti. Nakon toga su korišteni podaci samo za one postaje koje imaju dostupno više od 70% dnevnih srednjaka u promatranom periodu. Male promjene u navedenim kriterijima ne utječu na strukturu krajnje izdvojenih postaja. Na kraju su bila dostupna mjerenja s 43 postaje koje zadovoljavaju navedene kriterije za smjer i brzinu vjetra.


Dodatno su u ovom istraživanju, zbog raznolikosti orografije, kopnene postaje razvrstane u tri kategorije; one u unutrašnjosti (njih 22), one koje se nalaze u kompleksnom obalnom području (njih 10) i postaje u ravničarskom obalnom području (njih 11). Kriterij da se postaja

proglasi obalnom određen je zračnom udaljenosti postaje od mora. Ona je zadana na manje od 20 km.


2.2 Mjerenja vjetra QuikSCAT satelitom

Mjerenja vjetra nad morem također su uključena u analizu. Podaci sa satelita dobiveni su mjerenjem *SeaWinds* instrumenta QuikSCAT satelita (QuikSCAT) na horizontalnoj mreži razlučivosti 25 km (Perry, 2001; Ruti i sur., 2008). Razdoblje unutar kojeg postoje satelitski podaci je od 2001. do 2008., ali je dostupnost podataka za određeni dan ovisna o pokrivenosti oblacima i brojem preleta satelita preko Jadrana. Time je dnevni srednjak QuikSCAT mjerenja izračunat iz maksimalno dvije vrijednosti tijekom dana.

Dosadašnja istraživanja su pokazala da QuikSCAT blago podcjenjuje male brzine vjetra, a precjenjuje velike brzine vjetra tijekom dana u odnosu na mjerenja s plutača (Herrmann i sur., 2011). Nadalje, QuikSCAT mjerenja su manje točna za male brzine vjetra (< 3 m/s) i u blizini obala (Tang i sur., 2004; Telišman Prtenjak i sur., 2010). Usprkos tome, QuikSCAT podaci vjerno opisuju dnevne srednjake brzine vjetra za područje otvorenog mora (Accadia i sur., 2007). Radi usporedbe s RCM-ima, odabrane su četiri točke nad otvorenim more s najpotpunijim nizom QuikSCAT mjerenih podataka u periodu od interesa (Sl. 2)



Slika 1. Orografija i batimetrija Sredozemlja. Crni pravokutnik označava odabrano šire područje Jadrana (12° E – 20° E i 40° N – 46° N).



Slika 2. Prostorna raspodjela 47 lokacija dostupnih za ovo istraživanje uključujući nacionalne postaje dostupne preko NCDC/NOAA baze podataka, DHMZ postaje te HKZP postaje. Postaje su odabrane na način da budu reprezentativne na dnevnoj skali (5 od 8 SYNOP mjerenja mora postojati za određeni dan) i reprezentativne za razdoblje 1996./2001. – 2008. (najmanje 70% dnevnih podataka mora postojati). Postaje koje pokrivaju vremenski niz 1996.-2008. označene su crnim x simbolom, 2001.-2008. označene su crvenim o simbolom, a QuikSCAT podaci koji pokrivaju razdoblje 2000.-2008. označeni su plavim + simbolom na slici. Ako se za određenu lokaciju pojavljuju dva simbola, tada su za tu lokaciju dostupna dva vremenska niza iz dva izvora. Imena na slici se javljaju uz postaje koje će biti diskutirane u tekstu.

2.3 ERA-Interim reanaliza

Za usporedbu rezultata RCM-a s globalnom reanalizom koriste se dva različita ERA-Interim vremenska niza s prostornim korakom 0.75° : (i) analiza (dalje u tekstu ERA-Interim) i (ii) 6-h prognoza (dalje u tekstu ERA-Interim6). Za određeni dan, brzina vjetera u 6:00 UTC je u slučaju (i) produkt analize polja u 6:00 UTC, dok je u slučaju (ii) rezultat prognoze 6 h unaprijed simulacije koja je započela u 00:00 UTC. Drugim riječima, ERA-Interim6 rezultat je 6-h i 12-h prognoze inicijalizirane u 00:00 i 12:00 UTC. Takav nam pristup omogućava testiranje robusnosti ERA-Interim rezultata i određivanje utjecaja početnih uvjeta korištenih u ERA-Interim reanalizi.

Za daljnju analizu i interpretaciju rezultata važno je napomenuti da ERA-Interim ne

asimilira mjerene podatke vjetra na 10 m nad kopnom, ali asimilira QuikSCAT podatke nad morem (počevši od 2000., Dee i sur., 2011).

2.4 Regionalni klimatski modeli (RCM)

Sedam EURO-CORDEX (Jacob i sur., 2013), tri MED-CORDEX (Somot i sur. 2011; Ruti i sur. 2016) te dvije dodatne nehidrostatske simulacije ETH instituta iz Züricha (ETHZ) su analizirane za potrebe evaluacijskog dijela istraživanja. Svi CORDEX modeli su hidrostatski, jedino je CLMcom-CCLM4 nehidrostatski. Iz EURO-CORDEX simulacija preuzeti su podaci za obje komponente vjetra (u , v) te brzina vjetra na 10 m. U MED-CORDEX bazi, u trenutku provođenja istraživanja, bila je dostupna samo brzina vjetra na 10 m. Svi preuzeti podaci CORDEX baze odnose se na dnevne srednjake. Dodatno, SMHI-RCA4 i DHMZ-RegCM42 imaju dostupne 3-h podatke za period evaluacije.

Ovisno o odabranoj CORDEX simulaciji, duljina dostupnog vremenskog niza za evaluaciju varira između 20 do 30 godina, ali sve završavaju 2008. godine. Simulacije su dostupne s prostornim korakom 0.11° s pripadnim parom koji se računao na grubljoj mreži s prostornim korakom 0.44° . ERA-Interim reanaliza korištena je za početne i lateralne rubne uvjete te površinsku temperaturu mora (Dee i sur., 2011), obzirom da se njeni podaci smatraju kvalitetnima u umjerenim širinama (Brands i sur., 2013).

ETHZ simulacije dodane su zbog mogućnosti usporedbe rezultata na vrlo finoj rezoluciji. Time su ukupnom ansamblu koji je korišten za evaluaciju dodane dvije simulacije sa satnim podacima: ETHZ-CCLM-11 na 0.11° (tzv. *COSMO convection-parametrizing model*) te ETHZ-CCLM-02 na 0.02° (tzv. *COSMO convection-resolving model* ili *convection-permitting model*). Te su simulacije dostupne jedino za evaluacijsko razdoblje i duge su 10 godina, od 1999. do 2008. godine. Postupak dobivanja simulacije s prostornim korakom 0.02° provodi se u dva koraka korištenjem ugnježdene mreže i rubnih uvjeta koji dozvoljavaju jednosmjernu komunikaciju između mreža tijekom dinamičke prilagodbe. U prvom koraku se podaci ERA-Interim reanalize prilagođavaju na mrežu s korakom 0.11° . Potom se jednosmjernim

ugnježdivanjem dinamički prilagođavaju polja s 0.11° na 0.02° . Konačno, za analizu uspješnosti u simuliranju sadašnje klime na raspolaganju stoji ukupno 12 simulacija (Tab. 1).

Za analizu klimatskih projekcija korišteni su podaci sedam EURO-CORDEX RCM-a uz dodatne varijable prizemni tlak i geopotencijalnu visinu 500-hPa plohe. U ovom se dijelu koriste samo simulacije s 0.11° prostornim korakom. Dnevni srednjaci simulacija dostupni su sveukupno od 1971. do 2099. godine, uz iznimku DHMZ-RegCM42 simulacija koje pokrivaju razdoblje od 1971. do 2070. godine. Dodatno, SMHI-RCA4 i DHMZ-RegCM42 imaju dostupne 6-h podatke.

Pet različitih GCM-a koristi se za rubne i početne uvjete za RCM-e kako bi se odredio utjecaj izbora rubnih (GCM) uvjeta. Odabrani GCM-i su dio CMIP5 projekta (Williams i sur., 2011) i pokazali se se dobrima u simuliranju prizemnih parametara za područje Europe (Jury i sur., 2015) te se time smatraju i kvalitetnim rubnim i početnim uvjetima za RCM-e. Korištene GCM simulacije imaju isti fizikalnu verziju (p1) i metodu inicijalizacije (i1), ali se razlikuju u početnom stanju (r1, r12, r2, r3 ili r8). Time se analiza projekcija vrši pomoću ansambla od ukupno 19 simulacija za pojedini klimatski scenariji. Za potrebe ovog doktorskog istraživanja korištena su dva scenarija koncentracije stakleničkih plinova, RCP4.5 i RCP8.5.

Sve navedene simulacije, i za potrebe evaluacije i za klimatske projekcije, imaju samo atmosfersku komponentu i ne uvažavaju međudjelovanje atmosfera-more te u potpunosti pokrivaju odabrano šire područje Jadrana (Sl. 2). Pojedine simulacije će se skraćeno definirati imenom GCM-a (kod analize klimatskih projekcija, inače bez), zajedno s imenom institucije koja provodi simulacije te imenom RCM-a. U evaluacijskom dijelu uz sve navedeno dodana je i informacija o horizontalnom koraku mreže (02 za 0.02° , 11 za 0.11° te 44 za 0.44°).

Tablica 1. Popis analiziranih simulacija. Brojevi u 3. i 5. stupcu označavaju pojedinu simulaciju radi lakšeg praćenja slika. Sve CORDEX simulacije su dostupne s oba prostorna koraka mreže, 0.11° i 0.44°, dok su ETHZ simulacije dostupne s prostornim korakom mreže 0.02° i 0.11°.

RCM	Institucija (Kratica)	Evaluacija	Klimatske projekcije	
		ERA-Interim	GCM	Član ansambla
EURO-CORDEX				
CCLM4 ^a	Climate Limited-area Modelling Community (CLMcom)	Da (1)	ICHEC-EC-EARTH ⁱ MOHC-HadGEM2-ES ^j CNRM-CERFACS-CNRM-CM5 ^h MPI-M-MPI-ESM-LR ^k	r12i1p1 (1) r1i1p1 (2) r1i1p1 (3) r1i1p1 (4)
HIRHAM5 ^b	Danish Meteorological Institute (DMI)	Da (2)	ICHEC-EC-EARTH	r3i1p1 (5)
RACMO22E ^c	Royal Netherlands Met. Institute (KNMI)	Da (3)	ICHEC-EC-EARTH MOHC-HadGEM2-ES	r1i1p1 (6) r1i1p1 (7)
RCA4 ^d	Swedish Meteorological and Hydrological Institute (SMHI)	Da (4)	ICHEC-EC-EARTH MOHC-HadGEM2-ES CNRM-CERFACS-CNRM-CM5 MPI-M-MPI-ESM-LR IPSL-IPSL-CM5A-MR ^l	r12i1p1 (8) r1i1p1 (9) r1i1p1 (10) r1i1p1 (11) r1i1p1 (12)
ALADIN53 ^e	Centre National de Recherches Met. (CNRM)	Da (5)	CNRM-CERFACS-CNRM-CM5	r1i1p1 (13)
RegCM42 ^f	Meteorological and Hydrological Service of Croatia (DHMZ)	Da (6)	MOHC-HadGEM2-ES ICHEC-EC-EARTH CNRM-CERFACS-CNRM-CM5 MPI-M-MPI-ESM-MR	r1i1p1 (14) r12i1p1 (15) r1i1p1 (16) r1i1p1 (17)
WRF331F ^m	Institut Pierre Simon Laplace (IPSL)	Da (7)		
REMO ^g	Max Planck Institute for Met. (MPI-M)		MPI-M-MPI-ESM-LR	r1i1p1 (18) r2i1p1 (19)
MED-CORDEX				
ALADIN52 ^e	Centre National de Recherches Met. (CNRM)	Da (8)		
RegCM42 ^f	International Centre for Theoretical Physics (ICTP)	Da (9)		
PROMES1	Universidad de Castilla La Mancha (UCLM)	Da (10)		
ETHZ				
CCLM4 ^a	Eidgenössische Technische Hochschule Zürich (ETHZ)	Da (11 i 12)		

^a Rockel i sur. (2008), ^b Christensen i sur. (2006), ^c Van Meijgaard i sur. (2008), ^d Samuelsson i sur. (2011), ^e Colin i sur. (2010), ^f Giorgi i sur. (2012), ^g Teichmann i sur. (2013), ^h Voldoire i sur. (2013), ⁱ Hazeleger i sur., (2012), ^j Martin i sur. (2011), ^k Giorgetta i sur. (2013), ^l Dufresne i sur., (2013), ^m Katragkou i sur. (2015).

3 METODOLOGIJA

Za potrebe evaluacije RCM-a po lokacijama potrebno je odabrati metodu pomoću koje se točka unutar modela povezuje sa stvarnom lokacijom mjerne postaje. Postoje mnoge prostorne interpolacijske metode, a u ovom radu su testirane dvije (slično kao Di Luca i sur., 2015); (i) metoda najbližeg susjeda (NN) u kojoj se uzima točka modela koja je po geografskim koordinatama najbliža mjernoj lokaciji uzimajući u obzir masku kopna i mora te (ii) bilinearna interpolacija (BI) gdje se računa težinski srednjak pomoću četiri točke najbliže mjernoj lokaciji. Prednost korištenja dvije metode prostorne interpolacije je u mogućnosti određivanja robusnosti dobivenih rezultata.

Usporedba rezultata dobivenih iz simulacija s različitim prostornim korakom napravljena je kao u radu Pryor i sur. (2012), reskaliranjem (eng. *upscaling*) rezultata koji koristi 16 okolnih točaka na mreži s korakom 0.11° za dobivanje rezultata na mreži s korakom 0.44° . Takvim pristupom se osigurava da u slučaju uočavanja dodane vrijednosti u reskaliranim rezultatima, ona bude povezana s boljom prezentacijom fizikalnih procesa unutar modela (Torma i sur., 2015). Reskalirane simulacije označene su skraćenicom *UPS*.

3.1 Statistički parametri

Sve simulacije dostupne u evaluacijskom periodu uspoređene su s mjerenjima i izračunato je nekoliko osnovnih statističkih mjera kao što su pristranost (simulacije-mjerenja), standardna devijacija, korijen srednjeg kvadratnog odstupanja (*RMSD*) i vremenski koeficijent korelacije, odnosno nekoliko izvedenih mjera kao što su stalnost vjetra, empirijska funkcija gustoće vjerojatnosti (*ePDF*) i mjere uspješnosti (*Brier skill score (BSS)*, *Perkins skill score (PSS)*). Također su se koristile i napredne statističke metode kao što su EOF analiza i spektralna analiza. Evaluacija RCM-a u sadašnjoj klimi provedena je na dnevnim podacima, samo se spektralna

analiza temeljila na 6-h podacima, no u tom je slučaju broj članova ansambla smanjen i sastojao se od samo četiri modela.

Pretpostavka je da se simulacija smatra uspješnom ako vrijedi: (i) da je *RMSD* manji od standardne devijacije mjerenja i (ii) da su standardna devijacija dobivena iz mjerenja i one dobivene iz simulacija usporedive (Pielke, 2002). Kako bi se bolje uočilo koje su simulacije uspješne, informacija o *RMSD*-u (1), standardnoj devijaciji i koeficijentu korelacije prikazana je pomoću Taylorovog dijagrama (Taylor, 2001).

$$RMSD = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i - \bar{x} + \bar{y})^2} , \quad (1)$$

gdje je N broj podataka, x su modelirane, a y mjerene vrijednosti.

Stalnost vjetra je bezdimenzionalni parametar definiran kao nelinearizirani omjer srednjeg vektora vjetra i skalarne brzine vjetra (Halpren, 1979; Powell i sur., 1995; Dunion i sur., 2003):

$$P = \frac{\bar{v}}{\bar{V}} * 100 . \quad (2)$$

U takvoj definiciji stalnosti vjetra, veličina varira od 0 (niska stalnost) do 100% (potpuno stalan vjetar na određenoj lokaciji). Stalnost vjetra omogućava prepoznavanje prevladavajućeg smjera vjetra.

Izračunate su i prikazane dvije mjere uspješnosti; *Brier skill score* (*BSS*) temeljena na dan-za-dan korelaciji te *Perkins skill score* (*PSS*) temeljena na usporedbi raspodjele percentila. *BSS* kazuje daju li RCM-i bolje rezultate od ERA-Interim reanalize u usporedbi s mjerenjima. U radu se koristi modificirani *BSS* preuzet iz Winterfeldt i sur. (2011) i Menendez i sur. (2014):

$$BSS = \begin{cases} 1 - \frac{\sigma_D^2}{\sigma_R^2} & \text{ako } \sigma_D^2 \leq \sigma_R^2 \\ \frac{\sigma_R^2}{\sigma_D^2} - 1 & \text{ako } \sigma_D^2 > \sigma_R^2, \end{cases} \quad (3)$$

gdje su σ_D^2 i σ_R^2 korijeni srednje kvadratne pogreške RCM-a (D stoji za dinamičku prilagodbu, a R za ERA-interim reanalizu) izračunati u odnosu na mjerenja. Takvom definicijom *BSS* varira između -1 (reanaliza jednaka mjerenjima) i 1 (simulacija RCM-a jednaka mjerenjima).

Općenito, negativne vrijednosti ukazuju da je reanaliza uspješnija od RCM-a u simuliranju mjerenja, dok pozitivne vrijednosti ukazuju na bolju uspješnost RCM-a.

PSS je mjera definirana u Perkins i sur. (2007) i označava preklapanje dva PDE-a. Računa se kumulativna minimalna vrijednost u svakom razredu dviju raspodjela. Centri razreda određuju se iz mjerenja. Ako je preklapanje dviju raspodjela potpuno (simulacija sasvim opisuje izmjerene vrijednosti) PSS iznosi 1, što je ukupna suma po svim razredima unutar danog PDE-a. Time relacija za izračun PSS-a glasi:

$$PSS = \sum_{i=1}^N \min(Z_D, Z_0), \quad (4)$$

gdje je N broj razreda iz kojih se računa PDE, Z_D je čestina u pojedinom razredu iz raspodjele dobivene simulacijom, a Z_0 je čestina u odgovarajućem razredu dobivena pomoću mjerenja.

Od naprednih statističkih metoda evaluacije koriste se *EOF* analiza (npr. Ludwig i sur., 2004) i spektralna analiza (npr. Žagar i sur., 2006; Horvath i sur., 2011). Spektralna analiza provedena je na reduciranom ansamblu za one simulacije koje imaju dostupne 3-h podatke i za postaje za koje nedostaje manje od 10% SYNOP podataka u razdoblju 2001.-2008. Nakon uvažavanja navedenih kriterija preostalo je šest od ukupno 47 lokacija za spektralnu analizu. Nedostajući podaci u nizovima podataka s odabranih postaja popunile su se linearnom interpolacijom. Provjeren je i da su popunjene praznine sporadične te se ne javljaju u grupama čime interpolacija ne utječe na krajnje rezultate. Nakon uklanjanja linearnog trenda, spektralna gustoća je procijenjena iz brzine vjetrova pomoću modificirane metode Welch-ovog periodograma (Welch, 1967). Vremenski niz podijeljen je na preklapajuće podnizove duljine 256 mjernih točaka (tj. 256 3-h podataka) te je na svaki podniz primijenjen Hamming-ov prozor. Spektri su izračunati za svaki podniz te nakon toga usrednjeni i prikazani grafički (Belušić i Güttler, 2010; Večenaj i sur., 2010).

Vjerodostojnost povijesnih simulacija u statističkom smislu provjerava se usporedbom izmjerenih podataka i povijesnih simulacija za preklapajući period od 1996./2001. do 2005. godine te implementacijom ANOVA statističkog pristupa dekompozicije varijance (Déqué i sur., 2007; 2012). Ukupna varijanca (V) se tada može razdvojiti na doprinos od RCM-a (R), GCM-a

(G) i njihove kombinacije (GR, $V = R + G + GR$). R je varijanca sumirana za sve RCM-e kada su usrednjeni utjecaji svih GCM-a za pojedini RCM. G je varijanca sumirana za sve GCM-e kada su usrednjeni utjecaji svih RCM-a za pojedini GCM. GR predstavlja član interakcije RCM-a s određenim GCM-om te on predstavlja varijancu usrednjenu po svim kombinacijama GCM-a i RCM-a.

Analiza klimatskih projekcija provedena je za tri buduća razdoblja: *P1* (2011.-2040.), *P2* (2041.-2070.) i *P3* (2071.-2099.) u usporedbi s referentnim razdobljem koji predstavlja donedavnu klimu: *P0* (1971.-2000.), uglavnom samo za zimsku (DJF) i ljetnu (JJA) sezonu. Za buduću klimu se, osim podataka o prizemnom vjetru, analiziraju i polje tlaka te polje geopotencijala. U tu se svrhu polje tlaka i geopotencijala prebacuje iz CORDEX koordinatnog sustava (detalji o CORDEX koordinatnom sustavu i mreži mogu se naći na http://cordex.org/wp-content/uploads/2012/11/CORDEX-domain-description_231015.pdf) u sjever-jug geografski koordinatni sustav koristeći Haversinu relaciju (van Brummelen, 2013) koja uvažava nejednaku udaljenost u km s obzirom na geografsku širinu u svrhu dobivanja gradijenta tlaka u smjeru sjever-jug i lakše interpretacije rezultata.

Analiziraju se i buduće promjene na tri vremenske skale: sezonskoj, dnevnoj i 6-h skali. Na sezonskoj skali od interesa su promjene u iznosu prizemnog tlaka te u iznosu promjene gradijenta prizemnog tlaka ($|\nabla MSLP|_{p_X} - |\nabla MSLP|_{p_0}$, gdje je $X = 1, 2, 3$) iz RCM-a i GCM-a sukladno Hueging i sur. (2013), oduzimajući odgovarajuće susjedne točke modela. Radi usporedbe s Hueging i sur. (2013) dobiveni rezultati su skalirane u mjerene jedinice hPa/4.4°.

Dobiveni rezultati povezani su s pripadnim promjenama u geostrofičkom ($\vec{v}_g = \frac{1}{f\rho} \vec{k} \times \nabla MSLP$, gdje je f Coriolisov parametar, a ρ gustoća zraka) i prizemnom vjetru. Promjene su prikazane samo nad morem s obzirom na to da se pogreške redukcije tlaka na srednju morsku razinu nad orografijom većom od 1 km (npr. Bluestein, 1992; Pandžić, 2002) amplificiraju kada promatramo gradijent tlaka.

Uveden je novi *PCC* (eng. *PDF-based Climate Change*) parametar pomoću kojeg se iz razlike dviju raspodjela određuje stupanj klimatske promjene za određenu postaju. *PCC* je

izveden iz PSS -a kao $PCC = 1 - PSS$. Time PCC varira između 0 (potpuno preklapanje dvije razdiobe; tj. nema klimatske promjene) do 1 (nema preklapanja između dvije raspodjele; tj. signal koji upućuje na znatnu klimatsku promjenu). Definirana su tri PCC razreda kako bi se bolje uočio signal koji upućuje na klimatske promjene: $0 < PCC \leq 0.1$, $0.1 < PCC \leq 0.3$, $0.3 < PCC \leq 1$.

Za mjeru ekstremnog vjetra uzima se promjena u 99. percentilu brzine vjetra. Ovaj postupak prati određivanje nepouzdanosti pomoću interkvartilnog raspona (IQR) kako bi se eventualni signal klimatske promjene izdvojio od nepouzdanosti zbog odabira klimatske simulacije. S obzirom na ciljeve ovog rada, analiziraju se bura i jugo kojima se pridjeljuju sljedeći rasponi smjerova vjetra; dok je za buru interval smjerova SSI (22.5°) - ISI (67.5°), za jugo se koristi IJI (112.5°) - JJI (157.5°).

Obilježja bure i juga istražuju se na 6-h vremenskoj skali samo za dva RCM-a (SMHI-RCA i DHMZ-RegCM). Time je ansambl reduciran na ukupno devet članova kojima razdoblje preklapanja završava 2070. godine (do kraja $P2$ perioda). Događaj bure/juga definiran je kada 6-h vrijednost brzine vjetra prelazi zadani prag (testirana su tri praga: 3 m/s, 5 m/s i 7 m/s), a smjer vjetra dolazi iz kvadranta koji je ranije spomenut. Rezultati analize prikazuju se pomoću promjene u broju pojedinih događaja, u srednjoj brzini vjetra i u 99. percentilu brzine vjetra unutar svakog 30-godišnjeg intervala pomoću medijana ansambla od devet simulacija.

3.2 Definicija tipova vremena

Naposljetku, prikazane promjene u buri i jugu pokušat će se povezati s promjenama u tipovima vremena, odnosno baričkim formacijama u polju tlaka. Klasifikacija vremenskih sustava tema je od 1950-ih godina (npr. Lamb, 1950; Poje, 1965) te postoji više pristupa u nizu studija sinoptičke klimatologije (npr. Yarnal i sur., 2001; Philipp i sur., 2010). Metode klasifikacije obično su podijeljene u dvije glavne skupine: kao ručna i automatska klasifikacija, ili alternativno kao subjektivna i objektivna klasifikacija tipova vremena (Philipp i sur., 2010). Subjektivna metoda se bazira na iskustvu prognostičara, a objektivna metoda može koristiti analize temeljene na korelaciji, analizi glavnih komponenata, EOF-u, klimatskim indeksima i sl. Svaki pristup ima

svoje prednosti i ograničenja te je važno napomenuti da automatizirane metode, koje se često smatraju objektivnim, uvijek sadrže subjektivne odluke.

Prvu i još uvijek naveliko korištenu klasifikaciju vremenskih sustava za Hrvatsku predložio je Poje (1965) u obliku 29 tipova vremena. Klasifikacija je subjektivna te se provodi pomoću prizemnih i visinskih karata standardnih izobarnih ploha i dominantnog smjera vjetra. Kako je iz CORDEX RCM-ova moguće dobiti informacije samo s dva relevantna nivoa (prizemnog i s 500-hPa plohe) u donjem dijelu atmosfere, metoda ovdje nije u potpunosti primjenjiva.

S obzirom na dostupna polja iz RCM simulacija ovdje je tipizacija vremena uzela u obzir elemente subjektivnog pristupa kojeg je predložio Poje (1965) te objektivne klasifikacije iz Bissolli i Dittmann (2001). U tu svrhu izrađen je novi algoritam koji iz podataka o prizemnom tlaku i geopotencijalnoj visini 500-hPa plohe svakom danu pridružuje jedan vremenski tip koji određuje strujanje nad Jadranom. Algoritam je definiran za domenu u rasponu od 5° E do 21° E te od 35° N do 50° N kako bi se obuhvatili veliki barički sustavi koji utječu na strujanje nad Jadranom. Unutar ove domene nalazi se i manja domena (11 °E – 20 °E i 40 °N – 48 °N) koja u izračunu nosi težinu 2, dok preostale točke u vanjskom rubu nose težinu 1. Unutarnja domena je izabrana na način da veću težinu daje ulaznom strujanju u jadransku domenu zbog zonalnog strujanja i dominantnog dolaska ciklonalnih struktura iz zapadnih smjerova (van Bebbber, 1891). Izračunati su težinski srednjaci Laplasijana tlaka i geopotencijala ($\nabla^2 p$, $\nabla^2 \phi_{500}$) koji nam daju informaciju o vrtložnosti unutar domene. Ukoliko su navedeni Laplasijani pozitivni/negativni, a istovremeno je minimum/maksimum tlaka u domeni manji/veći od 1013.25 hPa, tada su prizemna i visinska vrtložnost iznad domene ciklonalne/anticiklonalne (Bissolli i Dittmann, 2001). Uzimajući navedeno u obzir i koristeći dodatne uvjete obzirom na položaj minimuma/maksimuma (minimum se traži ako je prizemna vrtložnost ciklonalna, a maksimum ako je prizemna vrtložnost anticiklonalna) prizemnog tlaka unutar domene definirano je 16 tipova vremena opisanih u Tablici 2. Važno je napomenuti da se položaj centra ciklone ili centra anticiklone ne mora nužno nalaziti u domeni, što osobito vrijedi za anticiklone. Tada detektiramo tlak izobarne linije koja je najbliža centru, a ulazi u našu domenu od interesa. Detalji vezani uz

postupak određivanja tipa vremena za određeni dan nalaze se u Dodatku A. Svakom danu pridružen je jedan vremenski tip koji vrijedi za sve točke unutar jadranske domene.

Tablica 2. Opis vremenskih tipova

Tip vremena	Opis
C1C	Ciklonalna vrtložnost prizemno i na 500 hPa. Minimum <i>MSLP</i> -a unutar domene nalazi se između 41° N i 47° N te 5° E i 16° E. Ciklona se sa zapada približava jadranskoj domeni.
C1A	Ciklonalna vrtložnost prizemno, anticiklonalna vrtložnost na 500 hPa. Ostalo kao tip C1C.
C2C	Ciklonalna vrtložnost prizemno i na 500 hPa. Minimum <i>MSLP</i> -a unutar domene nalazi se ispod 41° N. Ciklona na jadransku domenu utječe svojom gornjom stranom.
C2A	Ciklonalna vrtložnost prizemno, anticiklonalna vrtložnost na 500 hPa. Ostalo kao tip C2C.
C3C	Ciklonalna vrtložnost prizemno i na 500 hPa. Minimum <i>MSLP</i> -a unutar domene nalazi se između 41° N i 47° N te 16° E i 21° E. Ciklona se udaljava od jadranske domene.
C3A	Ciklonalna vrtložnost prizemno, anticiklonalna vrtložnost na 500 hPa. Ostalo kao tip C3C.
C4C	Ciklonalna vrtložnost prizemno i na 500 hPa. Minimum <i>MSLP</i> -a unutar domene nalazi se iznad 47° N. Ciklona na jadransku domenu utječe svojom donjom stranom.
C4A	Ciklonalna vrtložnost prizemno, anticiklonalna vrtložnost na 500 hPa. Ostalo kao tip C4C.
A1C	Anticiklonalna vrtložnost prizemno, ciklonalna vrtložnost na 500 hPa. Maksimum <i>MSLP</i> -a unutar domene nalazi se između 41° N i 47° N te 5° E i 16° E. Anticiklona se sa zapada približava jadranskoj domeni.
A1A	Anticiklonalna vrtložnost prizemno i na 500 hPa. Ostalo kao tip A1C.
A2C	Anticiklonalna vrtložnost prizemno, ciklonalna vrtložnost na 500 hPa. Maksimum <i>MSLP</i> -a unutar domene nalazi se ispod 41° N. Anticiklona na jadransku domenu utječe svojom gornjom stranom.
A2A	Anticiklonalna vrtložnost prizemno i na 500 hPa. Ostalo kao tip A2C.
A3C	Anticiklonalna vrtložnost prizemno, ciklonalna vrtložnost na 500 hPa. Maksimum <i>MSLP</i> -a unutar domene nalazi se između 41° N i 47° N te 16° E i 21° E. Anticiklona se udaljava od jadranske domene.
A3A	Anticiklonalna vrtložnost prizemno i na 500 hPa. Ostalo kao tip A3C.
A4C	Anticiklonalna vrtložnost prizemno, ciklonalna vrtložnost na 500 hPa. Maksimum <i>MSLP</i> -a unutar domene nalazi se iznad 47° N. Anticiklona na jadransku domenu utječe svojom donjom stranom.
A4A	Anticiklonalna vrtložnost prizemno i na 500 hPa. Ostalo kao tip A4C.

Povezivanje tipova vremena i događaja bure i juga čija 6-h brzina prelazi 5 m/s provedeno je na način da su za svaku točku modela izdvojeni posebno dani s burom i oni s jugom. Ti su dani

dobili oznaku 1, a svi ostali 0. Poznato je koji vremenski tip odgovara danima s oznakom 1. Time je za svaku točku modela za dane kada u toj točki puše bura (ili jugo) poznata raspodjela vremenskih tipova. Rezultati su prikazani kao medijan od devet simulacija za broj događaja bure (i juga) za svaku točku mreže.

4 REZULTATI I DISKUSIJA

4.1 Evaluacija simulacija u sadašnjoj klimi

4.1.1 Prostorna obilježja vjetra

Prizemni vjetar je prostorno vrlo varijabilan po smjeru i iznosu. Stoga je prije same analize rezultata važno pogledati prostorna obilježja vjetra u različitim simulacijama. Slika 3 prikazuje godišnje srednjake skalarne brzine vjetra za predstavnike simulacija svih korištenih prostornih koraka (redom 0.02°, 0.75°, 0.11° i 0.44°). Dodana vrijednost uslijed dinamičke prilagodbe modela i smanjenja prostornog koraka mreže vrlo se dobro uočava na Slici 3 u prostornim detaljima te kroz veće brzine vjetra koje donosi simulacija s manjim prostornim korakom. Za jadransku domenu u kojoj su glavni tipovi lokalnog vjetra (ovdje dominantno bura) poznati po svojoj prostornoj varijabilnosti, prikaz finih prostornih struktura je izrazito važno.

Slike 4 i 5 prikazuju sezonske zimske (DJF, prosinac-siječanj-veljača) i ljetne (JJA, lipanj-srpanj-kolovoz) vektorske srednjake vjetra, skalarnu brzinu prizemnog vjetra te stalnost vjetra iznad jadranske domene za dva izvora. U prvom ETHZ-CCLM-02 simulacija (simulacija s najmanjim prostornim korakom mreže), a u drugom stupcu prikazana je ERA-Interim reanaliza (simulacija s najvećim prostornim korakom mreže).

U zimskoj sezoni nad kopnenim djelom Hrvatske uočava se relativno slabo sjeverozapadno (SZ) strujanje simulirano ERA-Interim reanalizom (Sl. 4b) koje je vidljivo i u rezultatima ETHZ-CCLM-02 simulacije (Sl. 4a). Poboljšanja uočena prelaskom na manji prostorni korak odnose se na smjer, intenzitet i stalnost vjetra u okolini izoliranih planinskih vrhova nizinske Hrvatske. U obalnom području, neovisno o prostornom koraku (Sl. 4), dominira sjeveroistočno strujanje (SI) većeg intenziteta i stalnosti (> 40%) u zimskoj sezoni. Međutim, za razliku od relativno uniformnog SI vjetra unutar ERA-Interim reanalize, ETHZ-CCLM-02 pokazuje kompleksnije prostorne strukture vjetra. Područja SI vjetra većih brzina (Sl. 4a)


preklapaju se s područjem veće stalnosti vjetra (preko 60%) duž Jadrana (Sl. 4c). Zaključujemo, dakle, da ETHZ-CCLM-02 simulacija vjerodostojno, po pitanju relativnog intenziteta i položaja, simulira tzv. mlazove bure. Mlazovi bure povezani su s obalnim planinskim prijevojima te su uočeni u mjerenjima kao i u simulacijama (Grisogono i Belušić, 2009; Stiperski i sur., 2012; Prtenjak i sur., 2015; Kuzmić i sur., 2015). S druge strane, jugo se ne uočava lako u sezonskoj klimatologiji prizemnog vjetra zbog niske stalnosti. Indikacije za postojanja juga vide se kroz nisku stalnost vjetra iznad otvorenog mora, osobito na krajnjem jugu domene.

U ljetnoj sezoni (Sl. 5a i b), u kojoj prevladavaju niže brzine vjetra nego u zimskoj sezoni, postoje manje razlike u intenzitetu vjetra između kontinentalnog i obalnog područja. Međutim, brzina vjetra nad otvorenim morem je nešto veća i otkriva dva glavna vjetrovna režima. SI-I strujanje u sjevernom dijelu domene i SZ strujanje (etezije sa stalnošću > 60%) u južnom dijelu domene koje dodatno jača pomičući se prema jugu. ETHZ-CCLM-02 simulacije pokazuje veću varijabilnost u smjeru vjetra duž obale (Sl. 5a) i uglavnom nisku stalnost (< 30%; Sl. 5c) što se može povezati sa prisustvom termički induciranog strujanja (smorac, kopnenjak, vjetar obronka, vjetar doline) čije je obilježje da mijenja smjer unutar 24 h.

Sezonska klimatologija, osobito ona izračunata pomoću ETHZ-CCLM-02 simulacije, se vrlo dobro slaže s klimatologijom prizemnog vjetra dobivenu dinamičkom prilagodbom prognostičkog modela ALADIN s prostornim korakom od 2 km (Horvath i sur., 2011, vidi njihovu Sl. 2) i QuikSCAT analizom u Accadia i sur. (2007, vidi njihovu Sl. 3).


4.1.2 Osnovne statističke mjere u vremenu i prostoru

Kroz ovo istraživanje se pokušalo različitim statističkim metodama kvantificirati dodanu vrijednost simulacija s manjim prostornim korakom prethodno uočene na Slikama 3-5. Detaljna evaluacija prizemnog vjetra pomoću mjerenja provedena je u vremenu i prostoru. Prvo je napravljena analiza osnovnih statističkih obilježja svih raspoloživih lokacija (ukupno njih 47). Obzirom da npr. Herrmann i sur. (2011) te Menendez i sur. (2014) naglašavaju da je varijabilnost prizemnog vjetra direktno povezana s orografskim obilježjima područja koje promatramo, a polje




Slika 3. Godišnji srednjaci srednjaci skalarne brzine vjetra, a) ETHZ-CCLM-02, b) ERA-INTERIM, c) CLM-CCLM-11 I d) CLM-CCLM-44. Crne točke predstavljaju postaje koje su detaljno diskutirane u tekstu.

vjetra iznad otvorenog mora je više pod utjecajem gibanja sinoptičke skale, postaje su podijeljene u četiri osnovne grupe (vidi poglavlje 2.2). Polje vjetra u širem jadranskom području pod utjecajem je raznolike podloge; od otvorenog mora iznad kojeg je vjetar manje varijabilan preko obalnog područja gdje orografija značajno oblikuje polje strujanja pa sve do nizinskog područja u unutrašnjosti nad kojim je vjetar ponovo manje varijabilan (vidi Sl. 3-5).




Slika 4. Zimski (DJF) sezonski vektorski srednjaci (označeno vektorima; a, b), srednjaci brzine (označeno bojama; a, b) i stalnosti vjetra (označeno bojama; c, d) nad širim jadranskim područjem iz ERA-Interim reanalize (desno) i ETHZ-CCLM-02 simulacije (lijevo). Vektori vjetra su normalizirani brzinom vjetra i daju informaciju samo o smjeru vjetra. Bijeli simboli predstavljaju postaje koje su detaljno diskutirane u tekstu.

Pristranost nad otvorenim morem (Sl. 6a) je uglavnom negativna, a vrijednosti variraju u rasponu od -2.5 m/s do 2 m/s ovisno o lokaciji. To znači da simulacije podcjenjuju vrijednosti izmjerene QuikSCAT satelitom. Suprotno, pristranost za postaje u unutrašnjosti je oko nule ili blago pozitivna (Sl. 6b, ukupan raspon od -3 m/s do 4 m/s ovisno o postaji). To ukazuje da simulacije u tom području precjenjuju izmjerenu brzinu vjetra. Pristranost je u obalnom području



Slika 5. Kao Slika 4 samo za ljetne (JJA) srednjake.

u ravničarskom terenu vrlo slična kao za postaje u unutrašnjosti (Sl. 6c). Nasuprot tome, maksimalna pristranost za postaje grupirane unutar kompleksnog obalnog područja (Sl. 6d) je dva puta veća od maksimalne pristranosti za ostale grupe postaja. U kompleksnom obalnom području vrijednosti pristranosti variraju između 2 m/s i 8 m/s, što ukazuje i na veliko raspršenje među postajama unutar same grupe. Navedeni rezultati slažu se s rezultatima prikazanim u članku Obermann i sur. (2016) (vidi njihovu Sl. 9), gdje pristranost varira između -3 m/s i 2 m/s za lokacije nad otvorenim morem i između -1 m/s i 5 m/s za kopнено područje. Takvo ponašanje je još jedna potvrda da je u području gdje prevladava kompleksna orografija izrazito važno koristiti



Slika 6. Pristranost (crveno), *RMSD* (zeleno) i koeficijent korelacije (plavo) brzine vjetra za 47 analiziranih lokacija svrstanih u odgovarajuće kategorije. Svaki dijagram s pravokutnikom predstavlja raspodjelu za odgovarajuću simulaciju unutar koje su grupirane sve postaje od interesa. Rezultati su grupirani u četiri područja i to redom: a) lokacije nad otvorenim morem (QuikSCAT mjerenja), b) postaje u unutrašnjosti, c) postaje u ravničarskom obalnom području i d) postaje u kompleksnom obalnom području. Brojevi 1-11 predstavljaju NN simulacije s prostornim korakom 0.11° , broj 12 predstavlja NN 0.02° ETHZ simulaciju, dok su brojevi 13 i 14 pridruženi ERA-Interim simulacijama kao što je naznačeno u Tablici 1 u 3. stupcu.

simulacije s čim manjim prostornim korakom mreže kako bi vjerno opisali obilježja male skale i zaobišli ograničenja koja imaju simulacije s nedovoljno malim prostornim korakom (tj. nerazlučena orografija i maska kopno-more, parametrizacije).


RMSD vrijednosti su veće nad morem i duž kompleksnog obalnog područja (~ 2-3 m/s), gdje je i veća brzina vjetra, a manje u ravničarskom području (1.5-2 m/s) (Sl. 3-5). Vremenski koeficijent korelacije također pokazuje najveće vrijednost za područje otvorenog mora i kompleksno obalno područje. Takvo ponašanje se može povezati s većom brzinom i stalnošću vjetra u određenom dijelu godine.

Uspoređujući samo modele, pristranost i rasap u pristranosti su najmanji za ETHZ simulacije i CNRM-ALADIN52, a najveći su za DHMZ-RegCM42 i ICTP-RegCM43 za sve lokacije. Najveće vrijednosti vremenskog koeficijenta korelacije nalaze se za ETHZ simulacije i ERA-Interim reanalizu, a najmanje za RegCM simulacije. ERA-Interim i ERA-Interim6 pokazuju slično ponašanje. Sami rezultati podupiru korištenje ERA-Interim simulacije zbog manjih pogrešaka i manje pristranosti. Iako razlike između rezultata koji su dobiveni dvjema različitim metodama interpolacije (NN i BI) mogu biti značajne kada se analizira specifičan događaj, na klimatološkoj skali su one zanemarive.

U sljedećim poglavljima koji se odnose na evaluacijske rezultate bit će prikazane samo postaje reprezentativne za pojedine grupe: lokacija Srednji Jadran - Južna Dalmacija (lokacija nad otvorenim morem), zračna luka Zagreb (postaja u unutrašnjosti), zračna luka Zadar (postaja u ravničarskom obalnom području) i Senj (postaja u kompleksnom obalnom području). Zadar i Senj su odabrani kao lokacije vezane uz buru; Zadar je poznat kao područje zatišja bure (npr. Stiperski i sur., 2012), dok je Senj područje izrazito jake i olujne bure (npr. Horvath i sur., 2011; Kuzmić i sur. 2013; Telišman Prtenjak i sur., 2015). Glavni kriterij za odabir druge dvije postaje je lokacija i dostupnost podataka.

Taylorov dijagram brzine vjetra na Slici 7 prikazuje sve dostupne simulacije s prostornim korakom 0.11° i 0.44° za četiri odabrane lokacije (Sl. 7a za lokaciju nad otvorenim morem, Sl. 7b postaja u unutrašnjosti, Sl. 7c postaja u ravničarskom obalnom području, Sl. 7d postaja u kompleksnom obalnom području). Reskalirane simulacije u ovom slučaju ne vode na nove

zaključke stoga su one izostavljene. Idealna, najbolja slaganja simulacija s mjerenjima nalaze se u okolini zvjezdice na x- osi dijagrama koja predstavlja mjerenja.



Slika 7. Normalizirani Taylorov dijagram brzine vjetra prikazuje uspješnost simulacija obzirom na mjerene vrijednosti za: a) lokaciju nad otvorenim morem (Srednji Jadran - Južna Dalmacija, 2001.-2008.), b) postaju u unutrašnjosti (zračna luka Zagreb, 1996.-2008.), c) obalnu postaju u ravničarskom terenu (zračna luka Zadar, 2001.-2008.) i d) obalnu postaju u kompleksnom terenu (Senj, 1996.-2008.). Prazni simboli označavaju NN metodu interpolacije, a puni simboli BI metodu interpolacije, crni simboli označavaju EURO-CORDEX-11 simulacije, plavi MED-CORDEX simulacije, crveni ETHZ simulacije, zvjezdice označavaju ERA-Interim simulacije, sivi simboli CORDEX-44 simulacije. Crna zvjezdica na x-osi predstavlja mjerenja.

Najveće vrijednosti *RMSD*-a uočene su za postaje zračna luka Zadar i Senj koje se nalaze u obalnom području, dok su najmanje vrijednosti za postaju zračna luka Zagreb smještenu u unutrašnjosti. Simulacije s manjim prostornim korakom pokazuju manje pogreške u usporedbi s pripadnom simulacijom s većim prostornim korakom. Manje pogreške u simulacijama s manjim prostornim korakom pronađene su i za područje otvorenog mora u radu Herrmann i sur. (2011) i Obermann-Hellhund i sur. (2016).

Uspoređujući RCM-e unutar CORDEX ansambla, CNRM-ALADIN53 se najbolje slaže s mjerenjima s obzirom na to da se za većinu postaja na Taylorovom dijagramu nalazi najbliži liniji koja označava normaliziranu standardnu devijaciju jednaku 1 te istovremeno ima najveći vremenski koeficijent korelacije. Uočava se da neke simulacije lokalno smanjuju *RMSD* u usporedbi s ERA-Interim reanalizom kao za slučaj postaje zračna luka Zadar gdje je polje vjetera izrazito varijabilno tijekom godine (vidi i Sl. 15). Međutim, sve CORDEX simulacije imaju niži vremenski koeficijent korelacije od ERA-Interim reanalize. ETHZ-CCLM-11 i -02 vrlo su bliski ERA-Interim reanalizi na Taylorovom dijagramu, što povlači da vrlo dobro simuliraju mjerenja. Razlike između NN i BI metoda interpolacije za RCM simulacije su zanemarive. To vodi do zaključka da odabir određenog RCM-a više utječe na rezultate nego odabir metode interpolacije.

DHMZ-RegCM42 simulacija ima najniži vremenski koeficijent korelacije za sve analizirane postaje (kao na Sl. 6), ali *RMSD* ne odskaka od CORDEX ansambla. Zanimljivo je primijetiti da je takvo ponašanje RegCM modela pronađeno i u drugim istraživanjima (npr. Turuncoglu i Sannino, 2016 za područje nad Sredozemnim morem). Turuncoglu i Sannino analizirali su RegCM42 s prostornim korakom 0.44° koji je bio združen s oceanografskim ROMS (*Regional Ocean Modeling System*, Shchepetkin i McWilliams, 2003) modelom (združeni model poznat je pod nazivom REGESM). Autori su pokazali da atmosferski modeli RegCM i REGESM dobro opisuju strujanje usrednjeno za područje Sredozemnog mora, ali se veća odstupanja javljaju kada se pojedini model uspoređuje s plutačama na otvorenom moru. Takvo su ponašanje objasnili grubim razlučivanjem modela, ali rezultati u ovom radu pokazuju da ni RegCM simulacije s korakom mreže 0.11° ne pokazuju poboljšanja. Preliminarni rezultati testova osjetljivosti provedenih u sklopu ovog doktorskog rada pokazali su da su rezultati koji se odnose


na vremenski koeficijent korelacije ovisni o shemama parametrizacije atmosferskog graničnog sloja te duboke konvekcije (slično je pokazano u Gómez-Navarro i sur., 2015). U svrhu potvrde ovih rezultata potrebno je napraviti dodatne detaljne testove osjetljivosti modela RegCM.

ERA-Interim reanaliza ima najveće vrijednosti vremenskog koeficijenta korelacije na svim analiziranim postajama, ali uglavnom precjenjuje izmjerenu standardnu devijaciju. Nadalje, četiri ERA-Interim vremenska niza (ERA-Interim NN, ERA-Interim BI, ERA-Interim6 NN, ERA-Interim6 BI) pokazuju slično ponašanje u usporedbi s mjerenjima. Ipak, uočava se da metoda interpolacije, u ovakvoj klimatološkoj analizi, ima veći utjecaj nego odabir vremenskog niza prognoze ili analize (vidi poglavlje 2.3).

Međusoban odnos CORDEX ansambla, ETHZ simulacija i ERA-Interim reanalize na Taylorovom dijagramu koji uvažava vremenski slijed događaja posljedica je nekoliko činjenica. Prvo, niži koeficijenti korelacije kod CORDEX ansambla nego kod ERA-Interim reanalize (osobito za Zagreb aerodrom i Senj) djelomično dolazi zbog ne korištenja spektralne prinude (eng. *spectral nudging*), čime se dopušta da RCM simulacije slobodno razvijaju gibanja na maloj skali. No, korištenje spektralne prinude smanjilo bi varijabilnost (von Storch i sur., 2000). Istovremeno, smanjenje koraka mreže ne dovodi do linearnih poboljšanja u statističkim parametrima (primjećeno osobito za smanjenje s 0.44° na 0.11° ; Ranjha i sur., 2016), dok ETHZ-02 simulacija vrlo vjerno opisuje vremenski slijed strujanja male skale na pojedinoj postaji. S druge strane, ERA-Interim ima vrlo grubi prostorni korak što joj ne omogućava razlučivanje male skale, ali asimilira mjerene podatke (uočeni *RMSD* je usporediv s CORDEX simulacijama, a koeficijent korelacije je veći).


Taylorov dijagram za sezone, zimsku (DJF) i ljetnu (JJA) nalaze se na Slici 8 za zračnu luku Zadar samo za simulacije s prostornim korakom 0.11° interpolirane NN metodom. Slično sezonsko ponašanje pokazuju i ostala tri predstavnika grupa. Precjenjivanje izmjerene standardne devijacije je veće, a vremenski koeficijent korelacije je manji u ljetnoj (JJA) sezoni (Sl. 8b) nego u zimskoj (DJF) sezoni (Sl. 8a), iako je brzina vjetera veća u DJF sezoni nego u JJA sezoni (Sl. 4 i 5). Takvo ponašanje može se pripisati skoro stalnom strujanju velike skale u zimskoj sezoni te konvektivnim događajima i većoj varijabilnost zbog utjecaja manje skale u JJA sezoni. Obilježja

ljetnog strujanja mnogo je teže simulirati RCM-ima, a ERA-Interim reanaliza ih ne može simulirati. Dosadašnja istraživanja također podupiru takav zaključak, gdje je pokazano da mezoskalni modeli strujanje slabije od 1.5 m/s obično reproduciraju loše, osobito u kompleksnom obalnom području (Baklanov i Grisogono, 2007; Telišman Prtenjak i sur., 2010b).




Slika 8. Sezonski normalizirani Taylorov dijagram brzine vjetra za postaju zračna luka Zadar (obalna postaja u ravničarskom terenu). a) zimska sezona (DJF), b) ljetna sezona (JJA). Opis simbola isti je kao za Sliku 7.

Dok su dijagrami s pravokutnikom brzine vjetra za simulacije s prostornim korakom 0.44° i UPS simulacije prikazani na Slici 9, QQ dijagrami za simulacije s prostornim korakom 0.11° , UPS i 0.44° vidljivi su na Slici 10. Obje slike pokazuju kako se obilježja raspodjele vjerojatnosti vjetra mijenjaju s udaljavanjem od obale. Općenito su razlike između kontinentalnog i obalnog dijela dobro simulirane modelima. Maksimalna brzina vjetra veća je u obalnom području i opada prema unutrašnjosti. Najveći rasap između simulacija unutar ansambla je za obalne postaje (kao na Sl. 6), dok je rasap iznad otvorenog mora sličan onom za postaje u unutrašnjosti. Razlika između posljednje dvije grupe je u tome da je iznos maksimalne brzine vjetra za postaje u unutrašnjosti oko 10 m/s, dok je za lokacije nad otvorenim moram taj iznos oko 25 m/s.



Slika 9. Dijagrami s pravokutnikom brzine vjetra za simulacije s prostornim korakom 0.44° i UPS simulacije koristeći NN interpolaciju. a) Lokacije nad otvorenim morem (Srednji Jadran - Južna Dalmacija), b) postaja u unutrašnjosti (zračna luka Zagreb), c) obalna postaja u ravničarskom terenu (zračna luka Zadar) i d) obalna postaja u kompleksnom terenu (Senj). Pravokutnik obuhvaća vrijednosti od 25. (P25) do 75. (P75) percentila, crvena linija označava medijan, a crveni križići vrijednosti veće od $P75+1.5*(P75-P25)$ ili manje od $P25-1.5*(P75-P25)$.



Slika 10. QQ dijagrami brzine vjetra za a) - c) lokaciju nad otvorenim morem, d) - f) postaju u unutrašnjosti, g) - i) obalnu postaju u ravničarskom terenu, j) - l) obalnu postaju u kompleksnom terenu. Prvi stupac: 0.11° NN simulacije, drugi stupac: UPS NN simulacije i treći stupac: 0.44° NN simulacije. EURO-CORDEX simulacije označene su crno, MED-CORDEX plavo, ETHZ crveno, a ERA-Interim plavo crtkano. Na vrhu svake linije stoji simbol, istovjetan Slici 7 koji dodatno označava pojedine simulacije. Linije QQ dijagrama crtaju se pomoću svakog 10. percentila za vrijednosti manje od medijana i svakog 5. percentila za vrijednosti veće od medijana

Korist prikaza na Slici 9 je i u uočavanju dodane vrijednosti na fizikalnoj osnovi simulacija s manjim prostornim korakom mreže modela. Uspoređujući obje simulacije istog modela (0.44° i UPS), vidi se da se medijan bolje slaže s mjerenjima za UPS simulacije pomičući cijelu raspodjelu također bliže mjerenjima.

Slika 10 otkriva, kao i ranije, da lokacije nad otvorenim morem i postaje u unutrašnjosti pokazuju manji rasap među simulacijama, ali simulacije sustavno podcjenjuju male brzine vjetra za lokacije nad otvorenim morem (kao u Herrmann i sur., 2011) i precjenjuju male brzine u kopnenom području u unutrašnjosti. Za obalne postaje u ravničarskom terenu vidljivo je precjenjivanje za sve brzine vjetra. Jedino se za Senj ne uočava grupiranje simulacije unutar ansambla iznad ili ispod teorijske 1-1 linije.

Dodatno Slika 10 ukazuje na poboljšanja uvedena dinamičkom prilagodbom. Rezultati su prikazani samo za NN interpolaciju, a isti zaključci se izvode i za BI interpolaciju. Najveća odstupanja primjećuju se za simulacije s velikim prostornim korakom u obalnom području za ekstremne brzine vjetra (uglavnom povezane s burom i jugom). Općenito, uočava se da reskaliranje s 0.11° na 0.44° (drugi stupac) unosi poboljšanja usporedno s 0.44° simulacijama (treći stupac). Osim u obalnom kompleksnom području, dodana vrijednost se primjećuje i za ekstremne brzine vjetra u ostalim područjima (isto pronađeno u radovima Sotillo i sur., 2005; Hermann i sur., 2011).

Za postaje u unutrašnjosti i lokacije nad otvorenim morem već ERA-Interim reanaliza (označena plavo crtkano i plavom zvjezdicom) pokazuje dobro slaganje s mjerenjima te su u tim područjima poboljšanja uvedena dinamičkom prilagodbom manje vidljiva kroz ovakav statistički prikaz. Ukupno, ETHZ simulacije (označene crveno) su najbliže dijagonalnoj liniji koja predstavlja savršeno slaganje.


4.1.3 Mjere uspješnosti

Kvantifikacija dodane vrijednosti RCM-a u odnosu na ERA-Interim reanalizu se može izraziti pomoću modificiranog BSS-a. Obzirom da Taylorovi dijagrami na Slici 7 pokazuju da za ERA-

Interim reanalizu vrijedi da su rezultati ovisni o metodi interpolacije više nego o odabiru vremenskog niza analize ili prognoze, na Slikama 11 i 12 prikazani su rezultati za obje metode interpolacije. Tako se na primjer na Slici 11c za ETHZ-CCLM-11 i -02 može uočiti da je za NN interpolaciju *BSS* za oko 30% veći nego za BI interpolaciju. Usporedba UPS i 0.44° simulacija u ovom slučaju ne daje konzistentne rezultate za sve simulacije i postaje.


Iznad otvorenog mora (Sl. 11a) i za postaje u unutrašnjosti (Sl. 11b), gdje već ERA-Interim reanaliza može dobro opisati masku kopno-more i orografiju, većina RCM-a pokazuje negativan *BSS* (ERA-interim reanaliza je bolja u smislu *BSS*-a). Modificirani *BSS* je za to područje izrazito negativan što se slaže s radom Menendez i sur. (2014). Iznad otvorenog mora (Sl. 11a), jedino CNRM-ALADIN53 i ETHZ simulacije pokazuju pozitivne vrijednosti modificiranog *BSS*-a. Winterfeldt i Weisse (2009) su također pokazali da RCM-i nemaju poboljšanja u odnosu na reanalizu za područje otvorenog mora. Naglasili su da modificirani *BSS* nad otvorenim morem nije ovisan o asimilaciji prizemnih mjerenja vjetra QuikSCAT satelitom (Feser i sur., 2011).

Dvije obalne postaje (zračna luka Zadar i Senj) ne pokazuju konzistentne rezultate za sve simulacije. Iako je modificirani *BSS* pozitivan za nekolicinu RCM-a s manjim prostornim korakom za zračnu luku Zadar, negativne vrijednosti dominiraju za Senj. Nekoliko je čimbenika koji mogu utjecati na takvo ponašanje. Prvo, za Senj, pripadna najbliža točka u ERA-Interim reanalizi je kopnena točka dok je za Zadar to točka modela koje je označena kao more. Takvo pogrešno predstavljanje vodi k brzinama vjetra većim od očekivanoga u ERA-Interim reanalizi (Sl. 10c). Dodatno, SI vjetar (bura) u Senju je vrlo perzistentan tijekom cijele godine (Sl. 4 i 5 u ovom radu i Sl. 3 u Poje, 1992). S druge strane, na nastanak bure utječe nekoliko čimbenika, uključujući i lokaciju sinoptičkih struktura tlaka i visinu okolne orografije. Obzirom da ERA-Interim reanaliza može vrlo dobro opisati sinoptička gibanja, perzistentan SI vjetar je također dobro opisan u modelu (vidi i Sl. 16). Time nema prostora da RCM nadvlada uspješnost ERA-Interim reanalize. Suprotno od Senja, za zračnu luku Zadar polje vjetra je izrazito varijabilno tijekom godine (vidi i Sl. 15) pa je dodana vrijednost RCM-a kroz *BSS* naglašena.



Slika 11. Modificirani BSS brzine vjetra (na y- osi) za: a) lokaciju nad otvorenim morem (Srednji Jadran - Južna Dalmacija), b) postaju u unutrašnjosti (zračna luka Zagreb), c) obalnu postaju u ravničarskom terenu (zračna luka Zadar) i d) obalnu postaju u kompleksnom terenu (Senj). Prikazani BSS izračunat je koristeći ERA-Interim simulaciju. Svaki broj na x- osi ima pridruženo tri stupca različitih boja i predstavlja jedan model s prostornim korakom naznačenim na legendi. Prvi stupac (crveno): 0.11° ili 0.02° , drugi stupac (zeleno): 0.44° i treći stupac (plavo): UPS. Modeli su posloženi redom kao u Tablici 1, osim što ovdje svakom modelu pripadaju dva uzastopna broja zbog NN i BI metode interpolacije.


Modificirani *BSS* za brzinu vjetra ima izrazitu sezonsku ovisnost, kao što je prikazano na Slici 12 za NN interpolaciju simulacija s korakom 0.11° . Veće se vrijednosti javljaju zimi nego ljeti za sve četiri reprezentativne postaje što potvrđuje da RCM-i imaju problema s reproduciranjem malih i varijabilnih brzina vjetra.




Slika 12. Modificirani *BSS* brzine vjetra (na y- osi) izračunat je koristeći ERA-Interim simulaciju za zimsku (DJF) i ljetnu (JJA) sezonu za 0.11° i 0.02° NN simulacije. Prikaz za obalnu postaju u ravničarskom terenu (zračna luka Zadar). Svaki broj na x- predstavlja jedan model naznačen u Tablici 1.

Mnogo jasnije i konzistentnije rezultate od onih prikazanih *BSS*-om daje mjera uspješnosti *PSS* (Sl. 14 za NN metodu interpolacije simulacija s korakom 0.11° i 0.02°) koja uspoređuje dvije raspodjele čestina (Sl. 13). Rezultati pokazuju da sve simulacije s malim prostornim korakom dobro opisuju izmjerenu razdiobu čestina. Nisu uočene značajne razlike između postaja u unutrašnjosti i obalnih postaja. Zanimljivo je da *PSS* rezultati za ETHZ simulacije ne pokazuju značajno bolje rezultate od ostalih simulacija CORDEX ansambla, ali sve RCM simulacije imaju veće vrijednosti *PSS* parametra od ERA-Interim reanalize (ERA-Interim NN i ERA-Interim6 NN). Konzistentno s dosadašnjim rezultatima, ICTP-RegCM43 i DHMZ-RegCM42 simulacije imaju najlošije rezultate, odnosno najniže *PSS* vrijednosti za sve analizirane lokacije.

Općenito, *PSS* je najveći, a rasap *PSS*-a je najmanji za lokacije nad otvorenim morem. To povlači zaključak da je raspodjelu strujanja nad otvorenim morem najlakše simulirati. Takvo ponašanje je i očekivano jer je strujanje nad tim područje uglavnom pod utjecajem gibanja velike skale (npr. Winterfeldt i Weisse, 2009). S druge strane, iznenađujuće je to da su takvi rezultati dobiveni i za područje Jadranskog mora koje je uski, polu-otvoreni bazen pod izrazitim utjecajem okolne orografije.




Slika 13. Empirijske funkcije gustoće vjerojatnosti za mjerenja, ETHZ-CCLM-02, CLM-CCLM-11, CLM-CCLM-44 i ERA-Interim reanalizu na reprezentativnim postajama. a) lokacija nad otvorenim morem, b) postaja u unutrašnjosti, c) obalna postaja u ravničarskom terenu i d) obalna postaja u kompleksnom terenu.



Slika 14. PSS za brzinu vjetra izračunat iz NN simulacija s prostornim korakom 0.11° i 0.02° za a) lokaciju nad otvorenim morem, b) postaju u unutrašnjosti, c) obalnu postaju u ravničarskom terenu i d) obalnu postaju u kompleksnom terenu. Svaki broj označava jednu simulaciju kao u Tablici 1 (3. stupac). Detalji isti kao na Slici 11.

4.1.4 Ruža vjetra i EOF analiza

Ruža vjetra prikazuje na istom grafu odnos čestine i raspodjele kutova polja vjetra za određenu lokaciju. Za obalne postaje uz jadransku obalu takvi su prikazi osobito korisni jer je to područje pod utjecajem snažnog i perzistentnog vjetra (bura i jugo). Slika 15 pokazuje ružu vjetra za NN




Slika 15. Ruža vjetra za postaju zračna luka Zadar (2001.-2008.) dobivena iz a) mjerenja, b) ETHZ-CCLM-02 NN simulacije, c) ETHZ-CCLM-11 NN simulacije, d) CLM-CCLM4-11 NN simulacije, e) ERA-Interim NN simulacije, f) CLM-CCLM4-UPS NN simulacije, g) CLM-CCLM4-44 NN simulacije.

interpolaciju za zračnu luku Zadar iz nekoliko odabranih simulacija: CLM-CCLM-11 (predstavnik CORDEX simulacija) s korakom 0.11° (Sl. 15d), CLM-CCLM-44 s korakom 0.44° (Sl. 15g), pripadna UPS simulacija (Sl. 15f), ETHZ-CCLM4 simulacija s korakom 0.11° (Sl. 15c) i ETHZ-CCLM4 simulacija s korakom 0.02° (Sl. 15b), te ERA-Interim reanaliza (Sl. 15e). Na toj je postaji vjetar iz svih smjerova jednako zastupljen, a brzine vjetra bure su tipično male.

ETHZ-CCLM-02 simulacija se najbolje slaže s izmjerenom ružom vjetra za zračnu luku Zadar (Sl. 15a). Iako precjenjuje brzinu vjetra, smjer bure (SI) i juga (JI) su dobro simulirani. Pripadna simulacija s korakom mreže 0.11° također dobro simulira buru precjenjujući međutim čestinu događaja. CLM-CCLM-11 CORDEX simulacija precjenjuje čestinu događaja bure i ne simulira dobro sjeverozapadno strujanje (SZ, etezije). UPS simulacija i simulacija s korakom 0.44° simuliraju buru uz precjenjivanje broja događaja, međutim reskaliranjem postignuta je veća maksimalna brzina vjetra. ERA-Interim reanaliza ne može simulirati izmjerenu varijabilnost vjetra tijekom godine (vidljivo i na Sl. 7c) i pokazuje slične rezultate kao CORDEX simulacija s korakom mreže 0.44° .

Za postaje u unutrašnjosti, za koje je izmjerena mnogo manja maksimalna brzina vjetra i vjetar je ravnomjernije zastupljen po smjerovima nego za obalne postaje, simulacije mnogo bolje (u smislu intenziteta i smjera) opisuju pripadne ruže vjetra. Ovdje nije prikazano, međutim, za ostale lokacije koje učestalo mjere buru (npr. Trst, Split, Dubrovnik vidljivo i na Sl. 3 i 4; Telišman Prtenjak i sur., 2010a; Horvath i sur., 2011), simulacije uglavnom vrlo dobro reproduciraju buru kao najčešći i najintenzivniji vjetar.

Najjača izmjerena bura duž istočne jadranske obale je na području Senja u zimskom periodu (DJF). RCM simulacije (CLM-CCLM4-11 primjer simulacija s korakom 0.11° (Sl. 16b), CLM-CCLM4-44 primjer simulacija s korakom 0.44° (Sl. 16d), pripadna UPS simulacija (Sl. 16c)) se dobro slažu s mjerenjima po relativnom odnosu čestina za pojedine smjerove. Međutim simulacija s korakom mreže 0.11° pokazuje i sekundarni maksimum JI smjera koji nije vidljiv u mjerenjima, UPS simulacija i simulacija s korakom 0.44° podcjenjuju brzinu vjetra i ukupan broj događaja maksimalnih brzina bure. Reskaliranjem je postignut bolji odnos kuta i čestina bure



Slika 16. Ruža vjetra za DJF sezonu za Senj za razdoblje 1996.-2008. za a) mjerenja, b) CLM-CCLM-411, c) CLM-CCLM4-UPS, d) CLM-CCLM4-44 i e) ERA-Interim reanaliza te za razdoblje 2001.-2008. za f) ETHZ-CCLM4-02 i g) ETHZ-CCLM4-11 simulacije.

uspoređujući s mjerenjima. ERA-Interim reanaliza (Sl. 16e) se vrlo dobro slaže s mjerenjima po raspodjeli brzine vjetra, dok je broj događaja blago podcijenjen. Razlog dobrog slaganja vjerojatno leži, kao što je već i spomenuto, u gotovo stalnom i intenzivnom strujanju na toj lokaciji generirano uglavnom sinoptičkim gibanjima i specifičnom orografijom.

Dok se za zračnu luku Zadar ETHZ-CCLM4-02 simulacija gotovo savršeno poklapa s mjerenim podacima u smislu razdiobe čestina po kutovima, za Senj u DJF sezoni to nije slučaj. Prikaz bure zimi u Senju iz ETHZ-CCLM4-02 (Sl. 16g) simulacije raspršen je u rasponu kutova od 34° do 79°. U ovom slučaju se ETHZ-CCLM4-11 (Sl. 16f) simulacija mnogo bolje slaže s mjerenjima u smislu čestine po kutovima i simuliranih brzina vjetra.


U svrhu rezimiranja rezultata prikazanim ružama vjetra provedena je EOF analiza koja bi trebala pokazati mogu li RCM-i razumno reproducirati klimatologiju smjera vjetra. Na Slici 17 prikazan je omjer varijance glavnih osi (pokazuju smjer najvarijabilnije brzine vjetra) i razlika kuta glavnih osi simulacija i mjerenja. Simulacija se u ovom slučaju smatra uspješnom ako omjer glavnih osi simulacije i mjerenja približno jednak 1, a razlika kutova glavnih osi čim manja.

Za područje otvorenog mora (Sl. 17a) glavna os dobivena iz mjerenja nagnuta je za 158° i označava da je SZ-JI os najvarijabilnija. Rezultat se može s povezati s činjenicom da se u tom području uglavnom izmjenjuju etezije (SZ) i jugo (JI). Kut se mijenja ovisno o dijelu Jadrana koji promatramo. Tako je za postaje na sjevernom Jadranu kut glavne osi u SI kvadrantu (za Senj je to 65°) što odgovara smjeru puhanja bure. Simulacije vrlo dobro prate pomak u kutu glavne osi unutar odgovarajućem kvadranta obzirom u kojem dijelu Jadrana se nalaze. Međutim, odstupanja unutar kvadranta ipak postoje. Odstupanja simulacija od mjerenja najveća su za zračnu luku Zadar (Sl. 17c), s obzirom na to da je na toj postoji, zbog varijabilnost po smjeru, vjetar najteže simulirati.


4.1.5 Spektralna analiza

Uz sve do sada navedeno, uspješna simulacija mora dobro opisivati i mjerenu spektralnu gustoću. Potrebni su 3-h podaci za spektralnu analizu kako bi se ta bitna informacija dobila. Spektralna

analiza provedena je za četiri simulacije koje imaju dostupne 3-h podatke: SMHI-RCA4, DHMZ-RegCM42, ETHZ-CCLM-11 i ETHZ-CCLM-02. Analizom nisu uočene bitne razlike između NN i BI interpolacije stoga su prikazani rezultati samo za NN metodu. Do sada prikazane postaje nisu uglavnom mogle zadovoljiti nužan uvjet o barem 90% dostupnosti SYNOP podataka (vidi poglavlje 3) pa se za potrebe spektralne analize prikazuje ukupno šest postaja koja su zadovoljile ovaj strogi kriterij. Odabrani set postaja čine: Daruvar (Sl. 18a), Gospić (Sl. 18b), Varaždin (Sl. 18c), zračna luka Zadar (Sl. 18d), zračna luka Cervia (Sl. 18e) i Zagreb Maksimir (Sl. 18f).



Slika 17. Rezultati za glavne osi EOF analize za simulacije s prostornim korakom 0.11° . Omjer varijance glavnih osi simulacija i mjerenja (lijevo) i razlika kutova glavnih osi simulacija i mjerenja (desno). Brojevi na x- osi se odnose na pojedine NN simulacije. a) Srednji Jadran - Južna Dalmacija (lokacija nad otvorenim morem), b) zračna luka Zagreb (postaja u unutrašnjosti), c) zračna luka Zadar (postaja u obalnom ravničarskom terenu), d) Senj (postaja u obalnom kompleksnom terenu).




Slika 18. Mjereni i simulirani spektar gustoće energije brzine vjetra u razdoblju 2001.-2008. za: a) Daruvar, b) Gospić, c) Varaždin, d) zračnu luku Zadar, e) zračnu luku Cervia (Italija) i f) Zagreb Maksimir. Točne lokacije postaja vidljive su na Slici 1. DHMZ-RegCM42-11 označen crvenom, SMHI-RCA4-11 zelenom, ETHZ-CCLM-11 plavom i ETHZ-CCLM-02 označen ljubičastom bojom.

Spektralna analiza primijenjena na simulirane podatke otkriva tri izražena maksimuma na periodima od 24 h, 12 h i 8 h (Ray i Poulou, 2005) koji se po poziciji savršeno slažu s maksimumima prisutnim u mjerenjima. Dok je maksimum na 24 h glavni je mod u hodu vjetra, maksimum na 12 h njegov je sljedeći viši harmonik. Maksimum na 8 h te maksimum na Nyquistovoj frekvenciji od 6 h koji se naziru u mjerenjima i simulacijama posljedica su frekvencija sinusnih funkcija pomoću kojih se rekonstruira dnevni hod brzine vjetra.

Promatrajući 3-h podatke možemo primijetiti očite razlike između ETHZ-CCLM-11 i -02 (Sl. 19) simulacija i uočiti dodanu vrijednost simulacije s manjim prostornim korakom (slično


kao u Ban i sur., 2014; 2015). Na skali većoj od dnevne, simulacije pokazuju vrlo slično ponašanje i vrlo se dobro poklapaju s mjerenjima. Međutim, prelaskom na periode manje od 24 h, ETHZ-CCLM-02 simulacija ostaje blizu mjerenja, dok ETHZ-CCLM-11 simulacija počinje blago odstupati. Vidljivo je da ETHZ-CCLM-02 najbolje odgovara mjerenjima, dok DHMZ-RegCM42 pokazuje najviše energije i najveća odstupanja. Na Slici 19 pokazano je da simulacije s manjim prostornim korakom postižu veći maksimuma brzine vjetra (kao na Sl. 15 i 16). Posljedično, modificira se spektar gustoće energije, a pozicije maksimuma u spektru ostaju nepromijenjene. Smanjenjem prostornog i vremenskog koraka mreže, simulacije su u mogućnosti reproducirati više detalja u prostoru i vremenu. To je također potvrda činjenice da RCM-i dobro simuliraju gibanja na velikoj skali, ali imaju poteškoća sa simuliranjem gibanja na najfinijoj prostorno-vremenskoj skali.



Slika 19. Uvećani prikaz maksimuma energije u mjerenom i simuliranom spektru za Varaždin. Legenda je ista kao na Slici 18.

Slika 20 prikazuje odnos između gustoće energije po različitim periodima normalizirane s ukupnom gustoće energije sumirane po svim periodima (x- os) i gustoće energije po različitim periodima normalizirane s gustoćom energije u pripadnom periodu u mjerenjima (y- os; kao u Žagar i sur., 2006). Svaka postaja označena je pripadnim simbolom, a simulacija bojom kao na Slici 18. Promatrani rasponi perioda su dulji od dnevnog (> 26 h), dnevni (od 22 h do 26 h) i

kraći od dnevnog (od 6 h do 22 h). Svi simboli koji se nalaze u okolini crvene linije, a blizu pripadnog crnog simbola smatraju se uspješnim.



Slika 20. Odnos između gustoće energije po različitim periodima normalizirane s ukupnom gustoćom energije sumirane po svim periodima (x- os) i gustoće energije po različitim periodima normalizirane s gustoćom energije u pripadnom periodu u mjeranjima (y- os). Rasponi perioda su: a) dulji od dnevnog (> 26 h), b) dnevni (od 22 h do 26 h) i c) manji od dnevnog (od 6 h do 22 h). Simboli označavaju pojedinu postaju, dok boje odgovaraju legendi kao na Slici 18. Svi simboli koji se nalaze u okolini crvene linije, a blizu pripadnog crnog simbola smatraju se uspješnim.


Promatrajući Sliku 20, može se primijetiti da sve simulacije imaju najviše energije za periode veće od dnevnog (isto potvrđeno u Žagar i sur., 2006 i Horvath i sur., 2011) te istovremeno veću energiju od izmjerene u navedenom periodu (npr. za zračnu luku Cervia za ETH-CCLM-02 simulaciju oko 58%, dok period dulji od dnevnog u mjeranjima iznosi 51% od ukupne gustoće). Time sinoptička i dulja vremenska skala doprinose u ukupnom spektru sa više od 70% energije. Dnevni period je uglavnom dobro simuliran u odnosu na mjerenja te u ukupnom spektru simulacija pridonose s malim udjelom (za isti primjer oko 16% u mjeranjima i 20% u simulaciju u odnosu na ukupnu sumu). Za period kraći od dnevnog uočeno je nejednoliko ponašanje simulacija; dio ih precjenjuje, a dio blago podcjenjuje mjerenja (za isti primjer oko 34% u mjeranjima i 24% u simulaciju u odnosu na ukupnu sumu). Sveukupno gledajući, simulacije uglavnom precjenjuju ukupnu spektralnu gustoću energije.

4.2 Usporedba mjerenja i povijesnog razdoblja

CORDEX povijesno razdoblje završava 2005. godine, a sve lokacije imaju dostupne mjerene podatke od 1996./2001. do 2005 godine. Stoga je moguće analizirati koliko su RCM-i uspješni u simuliranju klimatologije brzine vjetra kada za rubne uvjete ne koriste globalnu reanalizu, već GCM. Ova analiza provedena je na dnevnoj skali za predstavnike pojedine grupe postaja po područjima za veći ansambl simulacija u razdoblju za koji su simulacije i mjerenja bili dostupni.

Rezultati usporedbe na Slici 21 pokazuju da se GCM-RCM kombinacije ponašaju vrlo slično (u statističkom smislu) kao i simulacije koje za rubne uvjete imaju ERA-Interim reanalizu (Sl. 10) navodeći na iste zaključke kao u evaluacijskom razdoblju (vidi Poglavlje 4.1.2). Robusnost dobivenih rezultata provjerena je dodatnom analizom razdoblja dugog 10 godina (1996.-2005., gdje je to bilo moguće). Nisu pronađene značajne razlike u QQ dijagramima za dvije duljine razdoblja ni za zračnu luku Zagreb ni za Senj. Generalno dobro slaganje, u statističkim obilježjima, u razdobljima dugom 5, 10 i 13 godina, vodi k zaključku da možemo očekivati da će statistička svojstva ostati usporediva i za dulje razdoblje (30 godina). To upućuje na zaključak da RCM-i u povijesnom razdoblju, bez forsiranja reanalizom, sami vjerno razvijaju odgovarajuća gibanja na maloj skali. Međutim, treba imati na umu da to izravno ne povlači da pripadni model dobro opisuje gibanja male skale i u projekcijama (Jurry i sur., 2015), ali opravdava korištenje CORDEX klimatskih projekcija za analizu klimatskih promjena.

Osim na dnevnoj skali, ovdje imamo mogućnost usporedbe 6-h mjerenja i simulacija za Senj i zračnu luku Zagreb za devet simulacija (RCA za pet različitih GCM-a i RegCM za četiri različita GCM-a). QQ dijagrami dobiveni iz 6-h podataka pokazali su za Senj vrlo slično ponašanje s istim rasapom simulacija, dok je za zračnu luku Zagreb odstupanje simulacija od mjerenja veće nego na dnevnoj skali. Zanimljivo je primijetiti što uzrokuje takvo odstupanje. Analizom viših percentila za zračnu luku Zagreb pokazalo se da u promatranom razdoblju ima svega pet vrijednosti koje su veće od 15 m/s te time pripadni percentili izgledaju ovako: 90. percentil: 4 m/s, 99. percentil: 6 m/s, te maksimum: 22 m/s. S druge strane, simulacije ne




pokazuju vrijednosti veće od 15 m/s. Izbacivanjem maksimuma (100. percentil) raspodjela linija na Slici 21i postaje vrlo slična Slici 21e.

Pristranost (simulacije - mjerenja) brzine vjetra (Sl. 22) je pozitivna za zračne luke Zagreb i Zadar (Sl. 22b i c), a uglavnom negativna za lokaciju Srednji Jadran - Južna Dalmacija (Sl. 20a) u svim sezonama (što se slaže s rezultatima na Sl. 6). Za postaju Senj dominira negativna pristranost (simulacije podcjenjuju mjerenja) u zimskoj sezoni, dok u svim ostalim sezonama dominira pozitivna pristranost koja je najveća u jesenskoj sezoni. Najveće raspršenje među simulacijama također je u jesenskoj sezoni. Takvo ponašanje u jesen primjećuje se i za druge dvije postaje koje su pod utjecajem Jadranskog mora (zračna luka Zadar i Srednji Jadran - Južna Dalmacija). To vodi k zaključku da RCM-i vjerojatno imaju poteškoća pri simuliranju porasta brzine vjetra u jesen s povećanjem ciklonalne aktivnosti (Penzar i sur., 2001) i tada uglavnom podcjenjuju brzine vjetra.

Osim usporedbe statističkih obilježja ovisno o rubnim uvjetima te duljini niza, ovakva analiza omogućava nam i procjenu pogreški modela ovisno o izboru RCM-a, GCM-a ili njihove kombinacije. Za svaku od četiri postaje izračunata je razlika srednjaka kroz čitav niz te razlika srednjaka simulacija i mjerenja za pojedine sezone, te je u postocima određeno koji dio varijabilnost je opisan pojedinom komponentom (Tab. 3, ANOVA dekompozicija varijance, Déqué i sur., 2007; 2012; Gampe i sur., 2016). Može se primijetiti da najveći dio pogreške za svaku lokaciju nosi izbor RCM-a, a u manjoj mjeri izbor GCM-a i njihove kombinacije.

Udio pogreške RCM-a se smanjuje udaljavanjem od obale (zračna luka Zagreb i osobito Srednji Jadran – Južna Dalmacija za čitavi niz). U zimskoj (DJF) sezoni udio pojedine komponente rastava varijance ostaje nepromijenjen za obalne postaje (Senj i zračna luka Zadar). Za lokaciju na otvorenom moru povećava se udio RCM varijance u odnosu na čitavi niz. U ljetnoj (JJA) sezoni opada udio varijance RCM-a za zračnu luku Zadar i lokaciju nad otvorenim morem u odnosu na čitavi niz. Zanimljivo je primijetiti gotovo jednaki udio varijance RCM-a i GCM-a za zračnu luku Zagreb zimi i lokaciju Srednji Jadran – Južna Dalmacija ljeti. Razlike ovisno o geografskoj lokaciji povezane su s povećanim utjecajem sinoptičkih gibanja dobivenih



Slika 22. Pristranost brzine vjetra za: a) Srednji Jadran - Južna Dalmacija, b) zračnu luku Zagreb, c) zračnu luku Zadar, d) Senj za razdoblje 2001.-2005. godine. Boje označavaju pojedinu simulaciju, dok simbol označava pojedini GCM kao što je naznačeno legendom.

iz rubnih uvjeta (GCM) nad Zagrebom zimi te utjecajem temperature mora koja također dolazi iz GCM-a nad otvorenim morem ljeti.

Tablica 3. Postoci varijance dobiveni ANOVA statističkom metodom dekompozicije varijance. R se odnosi na udio pogreške objašnjene RCM-om, G na udio objašnjen GCM-om, a GR njihovom kombinacijom. Najveće vrijednosti za odgovarajuću sezonu i postaju su podebljane.

		Čitavi niz	DJF	JJA
Zračna luka Zagreb (1996.-2005.)	R	83%	51%	95%
	G	14%	43%	2%
	GR	3%	7%	3%
Senj (1996.-2005.)	R	95%	95%	90%
	G	2%	2%	4%
	GR	3%	3%	6%
Zračna luka Zadar (2001.-2005.)	R	91%	91%	66%
	G	6%	6%	17%
	GR	3%	9%	17%
Srednji Jadran – Južna Dalmacija (2001.-2005.)	R	66%	88%	43%
	G	16%	4%	37%
	GR	18%	8%	20%

Najveći doprinos pogrešci dolazi uslijed izbora RCM-a i može se objasniti lokalnim strujanjem koje je uglavnom modificirano unutar RCM-a. Iznimka je zračna luka Zagreb zimi. Iako se Zagreb i njegova šira okolica nalaze u području slabijeg prizemnog strujanja (Lisac, 1984) te pod čestim utjecajem vjetrova obronka i dolinskog vjetrova, oko 20% brzina vjetrova odgovara umjerenom do olujnom vjetru. Takav tip vjetrova povezan je sa sinoptičkim poremećajima u zimi i proljeće kada utjecaj energije sinoptičkih poremećaja na lokalni režim strujanja raste s udaljenošću od Medvednice.


4.3 Klimatske projekcije – promjene u polju prizemnog tlaka

4.3.1 Sinoptička analiza tlaka


Sezonska obilježja gibanja na velikoj skali preko cijele EURO-CORDEX domene u svrhu boljeg razumijevanja promjena u prizemnom vjetru prikazana su na Slikama 23-26 za promjene u $P2$ razdoblju u odnosu na referentnu klimu $P0$ za RCP8.5 scenarij. Analizirane su promjene u prizemnom tlaku ($MSLP$), promjene u gradijentu navedenog tlaka (iznos i pojedine komponente gradijenta tlaka) te geostrofički vjetar kao izravna poveznica s gradijentom tlaka (Aagaard, 1969; Clarke i Hess, 1975; Cardoso i sur., 2016). Ovakav pristup omogućava bolje razumijevanje: (i) promjena gibanja na velikoj skali s obzirom na različite kombinacije GCM-RCM-a te (ii) odnosa promjena gibanja na velikoj skali i ekstremnih događaja brzine vjetra nad Jadranom.

U zimskom periodu, simulacije pokazuju tri različite prostorne strukture promjena u $MSLP$ polju ovisne o GCM-u koji se koristi za početne i rubne uvjete. Kao što je i očekivano za gibanja na većoj skali, prostorna obilježja za različite RCM-e vrlo su slična ako se za početne i rubne uvjete koristi isti GCM. Za SMHI-RCA4 (Sl. 23 i 24), MOHC-HadGEM2-ES stvara povećanje $MSLP$ -a preko gotovo cijele EURO-CORDEX domene (Sl. 23a i c), dok CNRM-CERFACS-CNRM-CM5, ICHEC-EC-EARTH, IPSL-IPSL-CM5A-MR i MPI-M-MPI-ESM-MR pokazuju dipolnu strukturu uz smanjenje $MSLP$ -a sjevernije od oko 60° N (Sl. 24a; CNRM-CERFACS-CNRM-CM5-SMHI-RCA4). S druge strane MPI-M-MPI-ESM-LR pokazuje povećanje $MSLP$ -a osim na zapadu domene (Sl. 24d). Navedene prostorne strukture za pojedini model slične su u sva tri promatrana razdoblja, ali signal promijene jača prema kraju 21. stoljeća.

Promjene u zimskom periodu iznad Sredozemlja su pozitivne gotovo kod svih 19 članova ansambla, što je konzistentno s rezultatima u radu Hueging i sur. (2013). Ovakav rezultate ide u prilog smanjenju gustoće putanja ciklona te time i manje ciklonalne aktivnosti nad Sredozemljem zimi. Promjene u gradijentu tlaka su pozitivne nad sjevernim Atlantikom, a negativne nad južnim Sredozemljem (kao u Hu i Wu, 2004), dok su promjene iznosa gradijenta tlaka slabije izražene nego u ostatku domene (Sl. 23d i 24b i e).



Slika 23. Promjene u polju prizemnog tlaka i vjetra u zimskoj (DJF) sezoni za RCP8.5 scenarij u $P2$ razdoblju u odnosu na $P0$. (a, b) GCM HadGEM2-ES, (c-f) MOHC-HadGEM2-ES-SMHI-RCA4. Prvi red: (a, c) $MSLP$; drugi red: (b, d) iznos gradijenta $MSLP$ -a i treći red: (e) geostrofički vjetar i (f) prizemni vjetar. Bijeli pravokutnik označava jadransku domenu.




Slika 24. Promjene u polju prizemnog tlaka i vjetra u zimskoj (DJF) sezoni za RCP8.5 scenarij u P2 razdoblju u odnosu na P0. (a-c) MOHC-HadGEM2-ES-SMHI-RCA4 i (d-f) CNRM-CERFACS-CNRM-CM5-SMHI-RCA4. Prvi red: (a, d) $MSLP$; drugi red: (b, e) gradijenta $MSLP$ -a i treći red: (c, f) prizemni vjetar. Bijeli kvadrat označava jadransku domenu.

U ljetnoj sezoni (JJA), promjene $MSLP$ -a u RCM-ima također ovise samo o GCM-u koji daje početne i rubne uvjete. Promjene su u ovoj sezoni znatno slabije, a gotovi svi članovi ansambla pokazuju slične promjene preko cijele domene. Javlja se smanjenje $MSLP$ -a na jugu i

sjeveru domene (kao u Hueging i sur., 2013) uz izolirano područje povećanja tlaka na samom zapadu domene (Sl. 25a za SMHi-RCA4 u $P2$). U takvoj strukturi promjene u tlaku nad širim jadranskim područjem su nepouzidane (iako je veća težina na smanjenju tlaka, raspršenje među simulacijama je veliko) i gotovo su zanemarive (Sl. 25a). Slično kao i zimi, povećanje iznosa gradijenta tlaka vidljivo je iznad sjevernog Atlantika. Povećanje gradijenta tlaka na sjeveru, zajedno s smanjenjem tlaka u području Islandskog minimuma, može biti povezano s pomicanjem centra Islandskog minimuma prema sjeveroistoku (kao što su pronašli Hu i Wu, 2004), što je osobito izraženo ljeti (Giorgi i Lionello, 2008).


Sa Slika 23-25 može se primijetiti da se promjene u prizemnom vjetru uglavnom ne mogu opisati pomoću promjena u geostrofičkom vjetru (odnosno u gradijentu tlaka), osobito u zimskom periodu (prostorni koeficijent korelacije između Sl. 23e i f je 0.23). Razlog leži u samoj primjeni teorijskog koncepta geostrofičkog vjetra koji daje najbolje i najrealnije rezultate za umjerene geografske širine u središnjoj atmosferi. Međutim usporedba geostrofičkog i prizemnog vjetra daje mjeru utjecaja lokalnih režima strujanja (npr. mistral, tramontana, bura) koja pridonose jačanju ageostrofičke komponente ukupnom strujanju.



Slika 25. Promjene u polju prizemnog tlaka i vjetra u ljetnoj (JJA) sezoni za RCP8.5 scenarij u $P2$ razdoblju u odnosu na $P0$ za MOHC-HadGEM2-ES-SMHI-RCA4. a) $MSLP$, b) promjene gradijenta $MSLP$ -a i c) prizemni vjetar. Bijeli kvadrat označava jadransku domenu.

Sažeti prikaz odnosa promjene $MSLP$ -a i prizemnog vjetra usrednjen nad Jadranom (bijeli kvadrat) za svaku od 19 simulacija, može se uočiti na Slici 26. Kao što je prethodno i

obrazloženo, u zimskoj (DJF) sezoni dominira povećanje *MSLP*-a uz smanjenje brzine prizemnog vjetra. Ovdje je osobito izražen utjecaj pojedinog GCM-a na rezultate; dijamantni simboli koji pokazuju porast brzine vjetra odgovaraju CNRM-CERFACS-CNRM-CM5 GCM-u za različite RCM-ove. Nasuprot zimskoj (DJF), u ljetnoj (JJA) sezoni, veću težinu imaju negativne promjene *MSLP*-a, dok promjene u prizemnom vjetru nisu jasno definirane unutar ansambla RCM-a i nisu korelirane s promjenama u tlaku. Naposljetku, možemo zaključiti da su dobiveni rezultati za prizemni tlak u slaganju s rezultatima prethodnih studija (Hu i Wu, 2004; Hueging i sur., 2013; Tobin i sur., 2015), te ih stoga smatramo robusnim.



Slika 26. Promjene u polju prizemnog tlaka (y- os) i vjetra (x- os) u zimskoj (DJF) i ljetnoj (JJA) sezoni za RCP8.5 scenarij u *P2* razdoblju u odnosu na *P0* za sve dostupne simulacije nad morem jadranske domene (bijeli kvadrat na Sl. 21-23). Svaki GCM prikazan je jednim simbolom, a svaki RCM jednom bojom kao na Slici 22.

4.3.2 Tipovi vremena

Dosadašnji rezultati istraživanja koji se temelje na proučavanju ciklonalne i anticiklonalne aktivnosti zasigurno imaju odjek i na gibanja i u Jadranskom moru, osobito na buru i jugo koji su pod utjecajem formacija tlaka nad sjevernim Atlantikom i Sredozemnim morem. U tu svrhu u


Tablicama 4 i 5 prikazani su odnosi ciklona i anticiklona nad Jadranom, a dobiveni su iz dva RCM-a iz CORDEX inicijative. Tablica 4 pokazuje ukupan odnos broja ciklona i anticiklona, dok su podaci u Tablici 5 grupirani obzirom na tip vremena koji obuhvaća određeni sektor ciklone/anticiklone nad jadranskom domenom. Time se može steći uvid u putanje baričkih tvorbi u sadašnjoj i budućoj klimi. Ukupno gledajući, i u zimskoj (DJF) i u ljetnoj (JJA) sezoni sve simulacije pokazuju da broj ciklona nad jadranskom domenom opada, a broj anticiklona raste uz vrlo male promjene u srednjaku tlaka (u rasponu -2 do 2 hPa) za sve događaje. To je u skladu s dosadašnjim analizama da ciklona zimi ima manje, a one koje i nastaju su intenzivnije i zimi se premještaju nešto sjevernije (Knippertz i sur., 2000; Hu i Wu, 2004; Bengtsson i sur., 2009).

Tablica 4. Promjena u broju ciklonalnog i anticiklonalnog tipa vremena nad jadranskom domenom u budućoj klimi (P2) iz SMHI-RCA4 i DHMZ-RegCM42 simulacija u odnosu na referentnu klimu P0. Crveno su naznačene pozitivne, a plavo negativne vrijednosti.

	Ciklonalno strujanje		Anticiklonalno strujanje	
	DJF: P2-P0	JJA: P2-P0	DJF: P2-P0	JJA: P2-P0
SMHI-RCA4:				
1. CNRM-CERFACS-CNRM-CM5	-44	-86	44	86
2. ICHEC-EC-EARTH	-123	-116	122	116
3. IPSL-IPSL-CM5A-MR	-123	86	120	-86
4. MOHC-HadGEM2-ES	-47	-43	48	43
5. MPI-M-MPI-ESM-LR	-111	-22	108	22
DHMZ-RegCM42:				
6. CNRM-CERFACS-CNRM-CM5	6	-44	-6	44
7. ICHEC-EC-EARTH	-60	-70	60	70
8. MOHC-HadGEM2-ES	-89	-85	89	85
9. MPI-M-MPI-ESM-LR	-204	-47	204	47

Strujanje nad Jadranom nije određeno samo prisustvom ciklonalne/anticiklonalne aktivnosti, već je važno i koji sektor ciklone/anticiklone pokriva jadransku domenu (prema Poje, 1965). Time su pojedine ciklone/anticiklone podijeljene u četiri osnovna sektora u odnosu na jadransku domenu: prednji dio (ekstrem prizemnog tlaka nalazi se između 40° N i 48° N te zapadnije od 16° E), gornji dio (ekstrem prizemnog tlaka na geografskoj širini manjoj od 40° N),

stražnji dio (ekstrem tlaka između 40° N i 48° N te istočnije od 16° E) te donji dio (ekstrem prizemnog tlaka na geografskoj širini manjoj od 48° N). Odvajanjem svih vremenskih trenutaka čija prostorna raspodjela tlaka odgovara utjecaju određenog sektora i računanjem srednjaka, sve dostupne simulacije pokazuju gotovo jednaku strukturu tipova vremena prikazanih na Slici 27.



Slika 27. Prostorna struktura srednjaka tlaka svedenog na srednju morsku razinu za dane kada na jadransku domenu djeluje odgovarajući sektor ciklone/anticiklone; (a) združeni C1C i C1A, (b) združeni C2C i C2A, (c) združeni C3C i C3A, (d) združeni C4C i C4A, (e) združeni A1C i A1A, (f) združeni A2C i A2A, (g) združeni A3C i A3A, (h) združeni A4C i A4A. Prikazano je iz simulacije MOHC-HadGEM2-ES-SMHI-RCA4 za zimsku (DJF) sezonu i referentnu ($P0$) klimu. Za sve ostale analizirane RCM simulacije prostorna raspodjela je slična.

Iz Tablice 5 uočava se da zimi najveći utjecaj na jadransku domenu u referentnoj ($P0$) klimi imaju tipovi vremena gdje dominiraju gornji i donji dio ciklone (Sl. 27b i d), dok je udio prednjeg dijela ciklone nešto manji. U budućoj klimi ($P2$) promjene za sve sektore, gledajući u smislu srednjaka preko svih simulacija, su negativne. Najčešći sektor anticiklone zimi je gornji (Sl. 27f) te njegov udio u budućoj klimi raste. Za ostale sektore anticiklone zimi, promjene su

slabije izražene (utjecaj prednjeg i donjeg dijela blago raste, a stražnjeg opada). Ljeti je najčešći ciklonalni tip vremena koji djeluje na jadransku domenu gornji sektor ciklone, a njegova čestina u *P2* razdoblju raste. Preostali sektori su slabije zastupljeni, a njihov utjecaj opada u budućoj klimi. Anticiklone ljeti najčešće djeluju sa svojim prednjim sektorom čiji utjecaj u budućoj klimi raste. Učestalost utjecaja gornjeg, stražnjeg i donjeg sektora anticiklone opadaju. Rasap (standardna devijacija) među simulacijama je slična u oba razdoblja za sve promatrane slučajeve.

Tablica 5. Srednjak i standardna devijacija, dobiveni od 9 simulacija, broja ciklonalnog i anticiklonalnog tipa vremena s obzirom na sektor prizemnog strujanja koji djeluje na strujanje nad jadranskom domenom neovisno o strujanju na 500 hPa plohi. Vrijednosti su za buduću klimu (*P2*) i referentnu klimu (*P0*) iz SMHI-RCA4 i DHMZ-RegCM42 simulacija.

			P0	P2
Ciklonalni tip vremena	DJF	C1	199±40	188±46
		C2	275±74	245±70
		C3	113±19	102±21
		C4	486±92	452±71
	JJA	C1	103±25	91±26
		C2	298±100	325±112
		C3	144±46	125±33
		C4	160±55	124±59
Anticiklonalni tip vremena	DJF	A1	323±166	354±200
		A2	942±178	998±229
		A3	118±35	113±39
		A4	271±133	277±145
	JJA	A1	1230±245	1427±212
		A2	407±120	319±121
		A3	84±79	78±72
		A4	334±140	270±82

Ovakav odnos budućih promjena u tlaku zaista može ukazivati da će zimi i ljeti ciklone biti djelomično kompenzirane anticiklonama i uslijed premještanja ciklona prema sjeveru. Takav

scenarij poklapa se s rezultatima Hu i Wu (2004) te Reyers i sur. (2015) koji su uočili sjeveroistočno pomicanje Islandskog minimuma i Azorskog maksimuma što bi doprinijelo povećanju anticiklonalnog utjecaja nad područjem Sredozemlja. Pri tome će doći do jačanja utjecaja gornjeg i prednjeg sektora anticiklone.

Kako bi se odredila robusnost odabrane metodologije, testirano je nekoliko veličina i položaja manje (unutarnje) domene i granica po kojima se određuju sektori ciklonalnog i anticiklonalnog tipa vremena. Razlike u srednjaku (ili medijanu) tlaka zbog promjene veličine domene su do reda veličine razlike među simulacijama ili manje. Ipak razlike u broju pojedinih sektora ciklona/anticiklona su jako ovisne o veličini i postavljenim granicama domene.

4.4 Klimatske projekcije – promjene u polju prizemnog vjetra

4.4.1 Analiza brzine vjetra

U prethodnom je poglavlju pokazano da RCM-i zadržavaju informaciju o tlaku s velike skale iz GCM-a, a sada će taj iznos biti kvantificiran (u %) i za prizemni vjetar pomoću ANOVA pristupa za RCP8.5 scenarij. Pristup je sličan kao u poglavlju 4.2, ali se rezultati interpretiraju u smislu opisa varijabilnost promjene brzine vjetra s obzirom na odabir RCM-a, GCM-a ili njihove kombinacije. Za svaku od četiri korištene postaje izračunata je razlika srednjaka između buduće (P_2) i sadašnje (P_0) klime za pojedine sezone, te je u postocima određeno koji dio varijabilnosti je opisan pojedinom komponentom (Tab. 6). Veći postotak znači da je tu veći rasap među simulacijama.

Zimi uglavnom dominira utjecaj GCM-a i GCM-RCM kombinacije koji objašnjava oko 60% varijance promjene brzine vjetra za analizirane lokacije. To potvrđuje činjenicu da zimi signal klimatske promjene varira obzirom na varijabilne utjecaje gibanje velike skale unutar pojedinog GCM-a. Ljeti dominira utjecaj RCM-a, a vrijednosti jako ovise o geografskoj lokaciji. Nepouzdanost zbog odabira simulacije RCM-a za buduće promjene brzine vjetra dolazi od

činjenice da je strujanje na pojedinoj lokaciji uglavnom definirano lokalnim modifikacijama definiranim detaljnijim razlučivanjem lokalnog terena i procesa na koje rubni uvjeti GCM-a imaju manji utjecaj. RCM-i slobodno razvijaju gibanja na manjoj skali što je osobito izraženo ljeti.

Tablica 6. Postoci varijance dobiveni ANOVA statističkom metodom dekompozicije varijance. R se odnosi na udio nepouzdanosti objašnjen RCM-om, G na udio objašnjen GCM-om, a GR na udio objašnjen njihovom kombinacijom. Najveće vrijednosti za odgovarajuću sezonu i postaju su podebljane.

		DJF	JJA
Zračna luka Zagreb	R	24%	45%
	G	45%	14%
	GR	31%	41%
Senj	R	26%	87%
	G	41%	3%
	GR	33%	10%
Zračna luka Zadar	R	14%	38%
	G	23%	36%
	GR	63%	26%
Srednji Jadran – Južna Dalmacija	R	33%	53%
	G	12%	30%
	GR	55%	17%
More jadranske domene	R	11%	44%
	G	62%	32%
	GR	27%	24%


Slični rezultati pronađeni su za evaporaciju (Gampe i sur., 2016) koja je izrazito pozitivno korelirana s brzinom vjetra, dok kod analize temperature i oborine (Déqué i sur., 2012) dominira utjecaj isključivo RCM-a. Razlog leži u velikom broju nelinearnih odnosa među varijablama tijekom proračuna polja vjetra (kao i kod evaporacije). Takvo ponašanje, u kojem dominantan utjecaj pokazuje GCM i kombinacije GCM-RCM daje potvrdu da je za određivanje klimatskih promjena prizemnog vjetra potrebo imati multi-modelski ansambl. Ova metoda nam daje samo

informaciju o (ne)pouzdanosti promjene, ali ne daje i informaciju koji je fizikalni proces izvor nepouzdanosti.

Nadalje, promjene u prizemnom vjetru odvojene su posebno u smislu brzine i smjera vjetra. Kod analize brzine vjetra fokus je na funkciji gustoće vjerojatnosti, osobito na pripadnim ekstremnim događajima koji u jadranskom području odgovaraju tipičnim tipovima lokalnog vjetra (bura i jugo). Promjene raspodjele brzine i razdiobe komponenti vjetra za svaku od četiri lokacije kvantificirane su pomoću *PCC* parametra. Preklapanje raspodjela čestina u *P0* razdoblju i pojedinom budućem razdoblju (*PX*) prikazane su na Slici 28 za zračnu luku Zadar za obje sezone. Ostala tri predstavnika pokazuju slične rezultate. Što su veće *PCC* vrijednosti, to je veća razlika između dvije promatrane raspodjele. Uspoređujući postaje, najveće *PCC* vrijednosti i istovremeno najveći rasap među simulacijama je upravo za zračnu luku Zadar. Razlog se ponovno može pronaći u izrazitoj varijabilnosti vjetra na toj lokaciji, što se vidi iz ruže vjetra (Sl. 15). Time su i buduće promjene za tu lokaciju najnepouzdanije. Za sve četiri promatrane postaje razlike između raspodjela za brzinu vjetra su male (do 20%), a i rasap među simulacijama je mali (Sl. 28 a i d; $PCC < 0.2$). Rasap među simulacijama kod pojedinih komponenti vjetra je veći, ali nije pronađena pravilnost u ponašanju pomakom prema kraju 21. stoljeća (tj. *PCC* vrijednosti se ne povećavaju od *P1* prema *P3* razdoblju).

PCC parametar je testiran i na 6-h skali za manji ansambl simulacija (njih 9, vidi poglavlje 2.4) te je pokazano da je odnos između brzine vjetra i komponenti ostao isti. Uočene su veće promjene i veća varijabilnost između simulacija kod komponenti vjetra (Sl. D1). Zaključujemo da je metoda pomoću *PCC* parametra robusna jer ne ovisi o veličina ansambla ni o vremenskom koraku.


Buduće promjene u višim percentilima raspodjele prikladni su parametri za određivanje promjena u ekstremima vjetra iz ansambla RCM-a (Rockel i Woth, 2007). Analizirao se 99. percentili vjetra u RCP8.5 scenariju klimatskih promjena. Slični rezultati dobiveni su i za RCP4.5 scenariji samo uz slabiji intenzitet promjene. Sve simulacije se ne podudaraju ni u lokaciji ili predznaku najintenzivnije buduće promjene nad širim jadranskim područjem. Međutim, prikazom




Slika 28. PCC vrijednosti za zračnu luku Zadar u RCP8.5 scenariju za: a), d) brzinu vjetra, b), e) *u*-komponentu brzine vjetra, c), f) *v*-komponentu brzine vjetra. Prvi stupac predstavlja rezultate za zimsku (DJF) sezonu, a drugi stupac za ljetnu (JJA) sezonu. Tablica prikazana na svakoj podslici pokazuje broj simulacija koje zadovoljavaju određeni kriterij ($PCC > 0.3$, $0.1 < PCC \leq 0.3$, $0 < PCC \leq 0.1$). Broj na x-osi predstavlja jednu simulaciju redom kao na Slici 21. Svakom broju na x-osi pridružena su tri stupca; *P1* (plavo), *P2* (zeleno), *P3* (crveno). Svaka simulacija naznačena je brojem kao u Tablici 1 u 5. stupcu.

ansambl medijana relativne promjene ($PX/P0-1$) za zimsku (Sl. 29) i ljetnu (Sl. 30) sezonu zasebno uočavaju se područja konzistentnog signala.

Medijan ansambla za promjene u 99. percentilu brzine vjetra pokazuje smanjenje iznad otvorenog mora, a povećanje iznad kopna u zimskom periodu. Vrlo se slabo uočava povećanje u sjevernom Jadranu, u području oko Senja. U tom je području, povećanje brzine 99. percentila zasigurno povezano s burom. Suprotno, ljeti se uočava lokalno sporadično povećanje nad otvorenim morem u području jezika bure (do 8%), a smanjenje iznosa 99. percentila drugdje do kraja 21. stoljeća. Općenito, brzine vjetra (i ekstremne brzine vjetra) manje su ljeti nego zimi, pa se ni uz ove promjene ne očekuju izmjene u takvom odnosu.



Slika 29. Ansambl medijan (prvi red) i pripadni *IQR* raspon (drugi red) relativne promjene ($PX/P0-1$) po simulacijama za 99. percentila brzine vjetra za RCP8.5 scenarij u zimskoj sezoni. Ansambl se sastoji od 19 članova, osim u *P3* koji sadrži pet članova.



Slika 30. Isto kao Slika 29 ali za ljetnu (JJA) sezonu.

Dobiveni je rezultat zanimljiv iz aspekta korištenja energije vjetra te je konzistentan s rezultatima za gustoću energije vjetra nad Jadranom zimi i ljeti (Hueging i sur., 2013). Intenzitet promjene medijana ansambla na sezonskoj skali nigdje ne prelazi 12% što se pokazalo i za analize koje obuhvaćaju cijelu Europu (Rockel i Woth, 2007; Outten i Esau, 2013; Tobin i sur., 2014), ali se može pokazati korisnim za vjetro-potencijal na području Jadrana. Turbine vjetro-elektrana mogu raditi do određenog praga brzine (eng. *cut off speed*) te zahtijevaju uniformne umjerene brzine vjetra radi čim efikasnije produkcije. Tako blago smanjenje ekstremnih brzina uz povećanje umjerenih (bez mahova) može doprinijeti većoj produkciji energije iz vjetro-elektrana (npr. Pryor i sur., 2005).

Rasap među simulacijama nije homogen tijekom godine, veći je ljeti nego zimi i reda je veličine intenziteta buduće promjene. To znači da je standardna devijacija između signala pojedine simulacije reda veličine medijana pripadnih promjena (Reyers i sur., 2015). *IQR* za *P1* i

P2 u obje sezone je mali, ali su i promjene manje. *IQR* raste prema kraju 21. stoljeća (Sl. 29d-f i 30d-f), osobito u obalnom području i u ljetnoj sezoni. *IQR* je oko 4% što je istog reda veličine samih promjena, stoga je nepouzdanost uglavnom velika. Može se reći da je nepouzdanost reda veličine prirodne varijabilnosti (Pryor i sur., 2005.). U ljetnoj sezoni krajem 21. stoljeća iznos promjene je nešto veći nego *IQR*, pa su te promjene pouzdanije. Takav odnos iznosa promjene ekstremnih brzina vjetra i nesigurnosti pronađen je i ranije za ekstremne brzine vjetra za područje Europe (Schwierz i sur., 2010; Otten i Esau, 2013; Reboita i sur., 2017).

Robusnost dobivenih rezultata testirana je pomoću 6-h podataka unutar manjeg ansambla od 9 simulacija (Dodatak D). Primjetno je izrazito slaganje između dnevnih vrijednosti većeg i 6-h vrijednosti manjeg ansambla, uz nešto detaljniju prostornu strukturu u 6-h rezultatima.

4.4.2 Čestine vjetra s obzirom na smjer

U ovom potpoglavlju analiziraju se promjene smjera vjetra temeljene na rezultatima resultantnog sezonskog vektora vjetra (Tab. 7 i Sl. 31). U Tablici 7 u referentnom razdoblju (*P0*) za Senj, zračnu luku Zadar i lokaciju Srednji Jadran - Južna Dalmacija većina simulacija se poklapa s rezultatima dobivenim u evaluacijskom dijelu (Sl. 17). Tako je u referentnoj klimi (*P0*) prevladavajući SI smjer vjetra za Senj i zračnu luku Zadar, a JI za lokaciju Srednji Jadran - Južna Dalmacija u obje sezone. U projekcijama za zimsku sezonu za Senj i zračnu luku Zadar dominira pomak u smjeru kazaljke na satu, dok u projekcijama za ljetnu sezonu dominira pomak u smjeru suprotnom od kazaljke na satu. Za lokaciju Srednji Jadran - Južna Dalmacija simulacije nisu usklađene oko signala pomaka resultantnog sezonskog vektora vjetra.

Uspoređujući zimsku i ljetnu sezonu po postajama, najveći rasap među simulacijama (*IQR* u Tab. 7) uočava se zimi (maksimalna promjena je 152.50° u *P3* za lokaciju Srednji Jadran - Južna Dalmacija). Veliki rasap označava da postoji vrlo mala konzistentnost među promjenama pojedinih simulacija. Nije iznenađujuće da analiza smjera vjetra po postajama ne daje robusne rezultate te je takav rezultat primijećen i ranije u Merryfield i sur. (2009) koristeći istu

metodologiju. Usprkos tome, većina simulacija pokazuje umjereniji pomak od oko 5° zimi i -3° ljeti, dok je na lokaciji Srednji Jadran - Južna Dalmacija pomak zimi negativan, a ljeti pozitivan. Takvo ponašanje uključuje i moguću tranziciju resultantnog vektora iz SI kvadranta u II kvadrant zimi iznad sjevernog i srednjeg dijela Jadrana što može dovesti do djelomične zamjene bure za jugo na tim lokacijama.

Tablica 7. Buduće (PX) promjene u resultantnom sezonskom (DJF i JJA) vektoru vjetra u odnosu na *P0* za postaje Senj, zračna luka Zadar i lokaciju Srednji Jadran – Južna Dalmacija.


		DJF			JJA		
		Senj	Zračna luka Zadar	Srednji Jadran - Južna Dalmacija	Senj	Zračna luka Zadar	Srednji Jadran - Južna Dalmacija
Broj simulacija koje pokazuju promjene u smjeru kazaljke na satu	P1	13	11	10	5	5	10
	P2	15	12	6	5	4	11
	P3	14	12	7	2	1	9
Broj simulacija koje pokazuju promjene u smjeru suprotnom od kazaljke na satu	P1	6	8	9	14	14	9
	P2	4	7	13	14	15	8
	P3	1	3	8	13	14	6
Medijan (°)	P1	4.8°	1.3°	-1.2°	-1.3°	1.0°	0.8°
	P2	5.1°	-0.9°	-7.4°	-2.3°	-2.3°	2.1°
	P3	8.4°	3.8°	0.5°	-4.4°	-4.4°	4.0°
IQR (°)	P1	13.7°	6.4°	23.4°	3.2°	5.0°	2.4°
	P2	10.0°	9.0°	21.9°	3.8°	7.2°	6.0°
	P3	22.8°	17.4°	54.2°	6.1°	6.4°	7.0°
Raspon (°)	P1	(-12.6°, 11.1°)	(-17.7°, 17.8°)	(-34.0°, 72.6°)	(-11.4, 4.3°)	(-4.00°, 5.7°)	(-4.1°, 5.7°)
		(-8.3°, 18.1°)	(-26.0°, 21.7°)	(-48.1, 108.9°)	(-20.0°, 4.5°)	(-7.9°, 4.5°)	(-4.0°, 8.3°)
	P2	(-4.1°, 54.2°)	(-4.8°, 27.4°)	(-141.9, 152.5°)	(-22.0°, 2.5°)	(-13.00°, 2.5°)	(-5.4°, 11.0°)
	P3						

Na Slici 31 (dnevni podaci i veći ansambl), Slici D3 (6-h podaci i manji ansambl) te u Tablici 8 prikazane su relativne ($P2/P0-1$) promjene za broj događaja vjetra iz raspona smjerova: SSI do ISI ($22.5^\circ - 67.5^\circ$, tipično za buru) i IJI do JJI ($112.5^\circ - 157.5^\circ$, tipično za jugo). Buduće promjene pokazuju da bi zimi moglo doći do smanjenja čestine sjevernog vjetra, odnosno SI-ISI raspona kutova na postajama Senj, zračna luka Zadar i na lokaciji Srednji Jadran - Južna Dalmacija (Sl. 31a-c) i povećanje čestine iz raspona kutova SSI-ISI za lokaciju Srednji Jadran - Južna Dalmacija (Sl. 31c).

Ponovno, neovisno o veličini ansambla (Sl. 31 i Sl. D3), postoje indikacije da bi ljeti vjetar iz SSI-ISI smjerova mogao biti češći za zračnu luku Zadar i Senj (Sl. 31e i f), a IJI-JJI rjeđi za zračnu luku Zadar i lokaciju Srednji Jadran - Južna Dalmacija (Sl. 31e i a). Međutim, usporedbom dobivenih signala za promjene u smjeru vjetra s pripadnim pogreškama simulacija u $P0$ razdoblju u odnosu na petogodišnja (2001.-2005.) mjerenja, uočava se da su gotovo sve pogreške veće od dobivenog signala. U takvoj situaciji treba biti oprezan s interpretacijom dobivenih rezultata. Ovo nije neočekivano te je ranije pronađeno za smjer vjetra u radu Merryfield i sur. (2009) i Pryor i sur. (2012).

Tablica 8. Broj simulacija koje pokazuju sezonske (DJF i JJA) promjene manje od -1%, veće od 1% i vrlo slabe promjene (između -1% i 1%) za smjerove vjetra koje odgovaraju buri (SSI-ISI) i jugu (IJI-JJI). Ukupan broj simulacija u razdoblju $P2$ je 19. Tablica uz Sliku 31.

		DJF		JJA	
		SSI-ISI	IJI-JJI	SSI-ISI	IJI-JJI
Sjeverni Jadran – Južna Dalmacija	$N \leq -1\%$	3	2	1	8
	$-1\% < N < 1\%$	15	10	12	11
	$N \geq 1\%$	1	7	6	0
Zračna luka Zadar	$N \leq -1\%$	8	3	3	11
	$-1\% < N < 1\%$	8	8	5	8
	$N \geq 1\%$	3	8	11	0
Senj	$N \leq -1\%$	11	1	5	4
	$-1\% < N < 1\%$	8	18	3	15
	$N \geq 1\%$	2	0	11	0




Slika 31. Relativne promjene ($P2/P0-1$) čestine vjetra iz dva smjera; SSI-ISI (gornji trokuti) i IJI-JJI (donji trokuti). Crvena boja označava povećanje, plava smanjenje čestine, dok bijela boja označava promjene u rasponu od -1% do 1%. Crtkana crna crta odvaja dvije kombinacije prikaza; Lijevo od crtkane linije matrica je definirana tako da je RCM određen na gornjoj x- osi, a GCM na y- osi lijevo. Desno od crtkane crte su dodani RCM-i čiji je naziv na y- osi desno, a pripadni GCM je na y- osi lijevo. Tablica 8 govori o broju simulacija koji zadovoljava određeni kriterij. Rezultati su za RCP8.5 scenarij.

Prednost ovakvog prikaza je u lakom uočavanju utjecaja GCM-a na različite RCM-e. Rezultati za Senj zimi pokazuju promjene koje su istog predznaka i reda veličine za isti GCM neovisno od RCM-u (npr. za MPI u 4. redu). To povlači da su u zimskoj sezoni sinoptički uvjeti dominantni čimbenici koji utječu na formiranje prizemnog strujanja. Međutim, za zračnu luku Zadar se ne uočava takav signal u ovisnosti o GCM-u. Vjerojatni razlog je taj da je vjetar na toj postaji vrlo varijabilan i dominantno pod utjecajem male (lokalne) skale. Ljeti se za Senj također ne uočava uniformno ponašanje kada se gleda isti GCM. Tada dominiraju manje brzine vjetra zbog termičkih orografskih utjecaja (tj. vjetra obronka, dolinskog vjetra i obalne cirkulacije) i slabijeg sinoptičkog forsiranja.

4.4.3 Bura i jugo

Kriterij za definiranje bure i juga postavljen je pomoću dva zahtjeva: raspon kutova za smjer vjetra (SSI-ISI i IJI-JJI) i granica za iznos brzine vjetra. Osjetljivost rezultata testira se s obzirom na tri granice za brzinu vjetra: 3, 5 i 7 m/s. Te su granice osobito važne za odvajanje slabe i jake bure, gdje je prva češća ljeti i često superponirana na noćni dio strujanja obalne cirkulacije za vrijeme situacija sa slabim gradijentom tlaka (Telišman Prtenjak i Grisogono, 2007). Zimi je slabija bura uglavnom povezana s anticiklonalnim sinoptičkim situacijama. Rezultati su prikazani kao medijani i *IQR* ansambla od ukupno devet članova (pet SMHI i četiri RegCM) pomoću 6-h vrijednosti polja prizemnog vjetra (Sl. 32-35).


Rezultati za graničnu vrijednost 5 m/s, a osobito 7 m/s (Sl. 32a i 33a) pokazuju manji broj događaja u *P0* ljeti nego zimi. Time su isključeni svi događaji slabe bure koji se isprepliću s obalnom cirkulacijom i vjetrom obronka. Simulacije za *P0* razdoblje dobro reproduciraju najjaču i najčešću buru na sjevernom Jadranu u području oko Senja te opadanje srednje brzine vjetra s udaljavanjem od obale. Jedno od glavnih obilježja bure, prostorna varijabilnost brzine vjetra, je također vrlo dobro simulirano u *P0*. Ansambl medijan promjena broja događaja bure pokazuje smanjenje broja zimi u području mlazova bure (najviše do 200 događaja manje u 30 godina što je



Slika 32. Rezultati za buru (22.5° - 67.5°) u zimskoj (DJF) sezoni prikazani kao medijan ansambla od devet RCM simulacija u (a-c) medijan za $P0$, (d-f) medijan za $P2$ i (g-i) medijan razlika 30-ogodišnjih razdoblja $P2-P0$ za pojedinačne simulacije. (a, d, g) broj događaja, (b, e, h) srednja brzina vjetra, (c, f, i) 99. percentil brzine vjetra. Prag brzine je 7 m/s, a scenarij je RCP8.5.

do 15% na Sl. 32g) i smanjenje srednje brzine vjetra (do oko 5% na Sl. 32h), osim na sjevernom Jadranu. Signal za 99. percentil brzine vjetra unutar ansambla pokazuje indikacije za povećanje brzine 99. percentila od oko 1% u sjevernom Jadranu (Sl. 32i). Dakle, očekujemo smanjenje čestine bure zimi, ali s blagim promjenama u brzini vjetra. Takav je rezultat u suprotnosti s pokazanim povećanjem tlaka zimi nad Sredozemljem. Međutim, treba imati na umu da je *MSLP*

parametar koji opisuje gibanja velike skale te su promjene slabije izražene i izgladene ako ih dodatno usrednjimo u prostoru jer se razlike među pojedinim regijama kompenziraju (npr. vidljivo za područje Sredozemlja u Rockel i Woth, 2007; Donat i sur., 2011; Tobin i sur., 2014). Promatrajući Jadran zasebno, uočava se manje područje povećanja srednje brzine i 99. percentila brzine vjetra iznad sjevernog dijela.



Slika 33. Kao Slika 32, ali za ljetnu (JJA) sezonu.


Suprotno, ansambl medijan promjena za ljeto (Slika 33g-i) pokazuje povećanje broja događaja (do oko 200 događaja u 30 godina što je oko 15%) te srednje brzine vjetra u obalnom

području osobito u području jezika bure. Intenzitet 99. percentila brzine vjetra duž Jadrana pokazuje promjene manje od 1%. Uspoređujući ove rezultate s rezultatima Slike 30, možemo zaključiti da iznos 99. percentila brzine vjetra dobivenih iz dnevnih podataka raste, ali pripadne 6-h vrijednosti ostaju manje od 7 m/s obzirom da u ovakvom prikazu povećanje iznosa nije očito duž cijelog Jadrana.

Zanimljivo je pogledati kakvi su rezultati u slučaju slabe bure kada se u simuliranom podatku brzine superponira i obalna cirkulacija i vjetar obronka. Za graničnu vrijednost brzine 3 m/s u *P0* je broj događaja bure zimi (Sl. B1) je manji nego ljeti (Sl. B2). Očekivano, srednja brzina vjetra i brzina 99. percentila su ljeti manji nego zimi (Sl. B1b i B2b). Predznak promjene zimi u *P2* u odnosu na *P0* uglavnom pokazuje smanjenje broja događaja i srednje brzine vjetra bure osim iznad sjevernog Jadrana (Sl. B1g, h), dok brzina 99. percentila raste također iznad sjevernog dijela Jadrana (Sl. B1i). Ljeti broj događaja s brzinom većom od 3 m/s te srednja brzina vjetra intenzivno rastu u područjima jezika bure (Sl. B2g, h). To je vjerojatno posljedica povećanja broja događaja umjerene bure u *P2* razdoblju (porast 99. percentila dnevnih srednjaka na Sl. 30).

Jugo granične brzine 7 m/s je u *P0* razdoblju najčešće u uskom obalnom području južnog Jadrana zimi (Sl. 34a). Klimatološka obilježja juga uočavaju se unutar RCM simulacija; češće i jače jugo iznad južnog Jadrana, dok se ljeti javlja samo nekoliko događaja juga (Sl. 35a). Buduće promjene pokazuju povećanje broja događaja zimi (oko 200 događaja u 30 godina, Sl. 34g-i) do 10% u obalnom području srednjeg Jadrana, a smanjenje srednje brzine vjetra. Povećanje broja događaja juga osobito se primjećuje za područje sjevernog i srednjeg Jadrana gdje jugo u *P0* razdoblju nije bilo toliko često. To upućuje na zaključak da će se jugo proširiti na većem području duž jadranske obale. Ljeti juga ima vrlo malo te se uočava smanjenje broja događaja juga (od oko 100 događaja u 30 godina), dok ljetni signal za srednju brzinu vjetra i 99. percentil brzine vjetra nije sasvim jasan duž Jadrana.

U *P0* razdoblju broj događaja bure (s pragom 7 m/s) iznad sjevernog Jadrana je gotovo dva puta veći nego broj događaja juga na istom području. Rezultati su pokazali smanjenje broja




Slika 34. Isto kao Slika 32, ali za jugo (112.5° - 157.5°).

događaja bure, a povećanje juga za sjeverni i srednji dio Jadrana. Sukladno tome, klimatske projekcije za graničnu vrijednost brzine 7 m/s pokazuju da bi brojevi događaja bure i juga u tom području Jadrana mogli postati bliski. Očekuje se da do promjena u broju događaja bure i juga dolazi zbog promjene u broju događaja sinoptičkih sustava koji iste i generiraju.

U Dodatku C prikazani su rezultati analize provedene na isti način ali uz dodani uvjet da bura i jugo moraju puhati istovremeno u 50% točaka iznad Jadrana. Time smo obuhvatili one najintenzivnije događaje kada sinoptički sustavi obuhvaćaju cijeli Jadran. Ljeti i za buru (Sl. C2)

i za jugo (Sl. C4) postoji vrlo mali broj takvih događaja, što je i očekivano. Zimi broj takvih intenzivnih događaja bure opada (isto kao na Sl. 32), ali srednja brzina raste gotovo duž cijelog Jadrana. Signal za medijan promjene 99. percentila brzine vjetra je nešto slabiji, ali postoje naznake za povećanje uz samu obalu u područjima mlazova bure. Broj intenzivnih juga zimi se smanjuje, smanjuje se i srednja brzina te 99. percentil brzine vjetra iznad južnog Jadrana, a rastu iznad sjevernog Jadrana. Iz toga zaključujemo da će intenzivnih događaja bure i juga zimi zaista biti manje, ali će njihov intenzitet, osobito na sjevernom Jadranu, jačati.



Slika 35. Isto kao Slika 32, ali za ljeto (JJA).


4.5 Veza između vremenskih tipova i bure i juga

S obzirom na sinoptičku raspodjelu tlaka koja se mijenja od anticiklonalne do ciklonalne formacije, dobro je poznato kakva raspodjela tlaka može proizvesti buru ili jugo. Istraživanje koje su proveli Pandžić i Likso (2005) temelji se na mjerenim podacima vjetra i geopotencijala. Autori su pokazali da je bura zimi uglavnom anticiklonalnog i ciklonalno-anticiklonalnog karaktera (njihova Sl. 8), dok je jugo uglavnom ciklonalno (njihova Sl. 10). Ljeti je anticiklonalna (slaba) bura najčešća. Na temelju rezultata RCM-a, cilj je povezati sinoptičku raspodjelu tlaka s događajima bure i juga koji su podijeljeni po tipovima vremena pomoću dnevnih srednjaka tlaka, geopotencijala, te smjera i brzine vjetra.

Podaci tlaka i geopotencijala odnose se na dnevne srednjake pa je radi konzistencije s 6-h podacima brzine i smjera iz prethodnog poglavlja, prag za brzinu dnevnih srednjaka brzine vjetra reduciran s 7 m/s na 5 m/s. Već je prije spomenuto da se kod brzine vjetra manje od 5 m/s ne može isključiti međudjelovanje bure s termički induciranim vjetrom. Iz tog je razloga fokus u ovom poglavlju na brzinama većim od 5 m/s. Time je broj pojedinih sektora ciklonalnog/anticiklonalnog tipa vremena manji nego što je to prikazano u Tablici 5. Rezultati Slika 36-43 dobiveni su tako da su za svaku točku izdvojeni dani s burom/jugom i za te dane je određena raspodjela vremenskih tipova te je prikazan medijan od 9 simulacija (vidi poglavlje 3.2).

4.5.1 Bura

Sa Slika 36 i E1 zaključujemo da je za nastanak bure iznad sjevernog Jadrana uglavnom odgovoran gornji sektor (C2C) ciklone, a manje doprinose imaju stražnji sektor (C3C) i prednji sektor (C1C). Ciklone koje spadaju pod C2C su ciklone koje nad područje Jadrana dolaze iz zapadnog dijela Sredozemlja ili rjeđe su to Genovske ciklone koje su nakon nastanka krenule na jug. Anticiklonalnu buru, koja se javlja rjeđe, iznad južnog Jadrana uglavnom generira prednji (A1C, A1A), a iznad sjevernog i srednjeg Jadrana donji sektor (A4C, A4A) anticiklone. Prijelazni



Slika 36. Broj dana s određenim vremenskim tipom kada u pojedinoj točki domene puše bura (22.5° - 67.5° s pragom brzine 5 m/s) u zimskoj (DJF) sezoni prikazani kao medijan ansambla od devet RCM simulacija. Rezultati za *P0* razdoblje.


tipovi (ciklona dolje - anticiklona gore i anticiklona dolje-ciklona gore) su vrlo slabo zastupljeni.

Buduće promjene tipova vremena kod pojave bure u zimskoj sezoni (Sl. 37) pokazuju izrazito smanjenje broja dana s burom duž cijelog Jadrana koju generira gornji sektor ciklone (C2C). Broj dana s prednjim (C1C) i stražnjim (C3C) sektorom se smanjuje iznad sjevernog Jadrana. Dani s anticiklonalnom burom zimi rastu zbog većeg utjecaja prednjeg sektora anticiklone (A1A), a smanjuju se zbog donjeg sektora anticiklone (A4C, A4A). Uočeno smanjenje broja događaja bure zimi (Sl. 32h) dolazi zbog manjeg utjecaja ciklonalne aktivnosti nad Jadranom, a povećanje srednje brzine vjetra i iznosa 99. percentila može biti posljedica promjene u intenzitetu ciklona/anticiklona. Primjećeno je da u budućoj klimi postoji naznaka da se smanjuje broj umjerenih ciklona ($MSLP \sim 1010$ hPa), a broj intenzivnijih ciklona (minimum $MSLP$ -a u rasponu 980-990 hPa) ostaje sličan.


Ljeti u generiranju bure dominira prednji sektor anticiklone (A1A, Sl. 38), a buduće su promjene u broju događaja bure (Sl. 39) uglavnom pozitivne (kao na Sl. 33h). Povećani broj dana posljedica je povećanja tipova vremena prednjeg dijela anticiklone (A1C i A1A) te gornjeg dijela ciklone (C2C, C2A). Promjene na Slici 39 su najizraženije iznad sjevernog Jadrana što je u skladu s prethodnim poglavljem. Uočeno povećanje srednje brzine vjetra bure u području oko Senja može biti posljedica većeg broja događaja tipova C2C, A1C i A1A. Analizom tlaka za pojedinačne anticiklone koje pripadaju grupama A1C i A1A uočeno je da je udio anticiklona s tlakom između 1015 i 1020 hPa povećan u odnosu na raspon tlaka 1020-1030 hPa te to može uzrokovati blago povećanje srednje brzine vjetra.

4.5.2 Jugo


Jugo (Sl. 40, E3) duž cijelog Jadrana u najvećem dijelu generiraju prednji dio ciklone (C1C, ali s centrom zapadnije od ciklona koje su odgovorne za buru), gornji dio ciklone (C2C, također s centrom zapadnije od ciklona koje su odgovorne za buru), gornji dio anticiklone (A2A), i stražnji dio anticiklone (A3A). Buduće pozitivne promjene u broju dana s jugom zimi (Sl. 41) u najvećem su dijelu posljedica povećanja utjecaja gornjeg sektora anticiklone (A2C, A2A), dok su




Slika 37. Isto kao Slika 36, ali za $P2-P0$.




Slika 38. Isto kao Slika 36, ali za ljetnu (JJA) sezonu.



Slika 39. Isto ako Slika 37, ali za ljetnu (JJA) sezonu.




Slika 40. Broj dana s određenim vremenskim tipom kada u pojedinoj točki domene puše jugo (112.5° - 157.5° s pragom brzine 5 m/s) u zimskoj (DJF) sezoni prikazani kao medijan od devet simulacija. Rezultati za P0 razdoblje.




Slika 41. Isto ako Slika 40, ali za P2-P0.

u manjem omjeru posljedica povećanja utjecaja prednjeg sektora ciklone (C1C) i donjeg sektora anticiklone (A4C, A4A). Primjećuje se i blago smanjenje utjecaja prednjeg sektora ciklone kada je u visini strujanje anticiklonalno (C1A) te stražnjeg dijela anticiklone (A3A). Smanjenje srednje brzine juga zimi uz porast broja događaja anticiklonalnog juga vodi k zaključku da anticiklonalno jugo puše nešto slabijim intenzitetom od ciklonalnog.

Ljeti juga ima vrlo malo, a dominira utjecaj prednjeg i gornjeg dijela anticiklone (A1A i A2A, Sl. 42). Uočena je pojava juga iznad južnog Jadrana za gornji dio anticiklone (A2A; slično kao Sl. 6.20 iz Penzar i sur., 2001). Prema položajima najvišeg tlaka u anticiklonama kad je na Jadranu zabilježeno anticiklonalno jugo, centri povišenog tlaka se nalaze južno od Jonskog mora nad Sredozemljem (tip A2A) ili nad južnim dijelom Balkanskog poluotoka (tip A3A). Promatranjem pojedinačnih slučajeva pokazalo se da su strujnice ponekad za vrijeme dominacije A2A iznad južnog Jadrana (zbog orografije i razlike temperature kopno more) blago izobličene na način da podržavaju generiranje juga. Smanjenje broja dana s jugom ljeti dolazi ponajviše od smanjenja broja dana s gornjim dijelom anticiklone (A2A). Broj dana s utjecajem prednjeg dijela anticiklone (A1A) blago raste duž obale, ali manje nego što opadaju utjecaji ostalih tipova vremena zajedno (Sl. 43).



Slika 42. Isto kao Slika 40, ali za ljetnu (JJA) sezonu.



Slika 43. Isto kao Slika 41, ali za ljetnu (JJA) sezonu.

5 ZAKLJUČAK

U ovom su radu prikazani rezultati evaluacijske analize i analize klimatskih projekcija prizemnog vjetra iz simulacija RCM-a nad širim područjem Jadrana. Evaluacijska analiza provedena je za razdoblje 1996./2001.-2008. za 12 simulacija, dok je za klimatske projekcije za referentno razdoblje odabrano razdoblje 1971.-2000. te tri razdoblja projekcija *P1* (2011.-2040.), *P2* (2041.-2070.) i *P3* (2071.-2099.). Uvažena su i dva GHG scenarija: RCP4.5 i RCP8.5 za ukupno 19 simulacija. U tu su svrhu simulacije najprije detaljno istražene kroz osnovne (pristranost, *RMSD*, koeficijent korelacije, QQ dijagrami, dijagrami s pravokutnikom), izvedene (*BSS*, *PSS*) i napredne (EOF analiza i spektralna analiza) statističke metode za evaluacijsko razdoblje. Zatim su analizirane klimatske projekcije kroz promjene u tlaku i geopotencijalu, dnevne ekstremne brzine vjetra, uveden je novi *PCC* parametar te se na kraju analiziralo strujanje u rasponu kutova koji odgovaraju smjeru bure i juga. Na kraju su promjene u buri i jugu interpretirane putem novog objektivnog algoritma za određivanje tipova vremena nad Jadranom. Slijede glavni zaključci provedene analize.

Simulacije s prostornim korakom mreže 0.11° i 0.02° mogu realistično simulirati važna prostorna i vremenska obilježja prizemnog vjetra koja nisu uočena u simulacijama s grubljim prostornim korakom. Razlike zbog odabira metode interpolacije vidljive su samo u nekim parametrima (npr. kod *BSS*-a). Dodana vrijednost je uočena pri reskaliranju simulacija s izvornim korakom 0.11° na 0.44° u usporedbi sa simulacijama s izvornim korakom od 0.44° ovisno o promatranom statističkom parametru (QQ dijagrami pokazuju razlike, dok Taylorovi dijagrami ne). Kod analize raspodjela uočava se da su medijan i *IQR* reskaliranih simulacija bliži medijanu i *IQR* mjerenja. Međutim, modificirani *BSS* nije pokazao jasna poboljšanja reskaliranih simulacija, za razliku od *PSS*-a. Razlike između dviju nehidrostatskih ETHZ simulacija (s 0.11° i 0.02° prostornim korakom mreže) najbolje se uočavaju kod analize procesa na skalama kraćim od jednog dana, gdje se uočava da zaista finiji prostorni korak vodi k boljem slaganju s mjerenjima prizemnog vjetra u jadranskom području.

Prostorni detalji u polju prizemnog vjetra poboljšavanju se smanjenjem prostornog koraka mreže. To je popraćeno s intenzivnijim vjetrom u dijelovima domene gdje je bura dominantan vjetrovni režim. ERA-Interim reanaliza i ETHZ simulacije imaju viši vremenski koeficijent korelacije od RCM-a CORDEX inicijative. Tome doprinose različiti razlozi. ERA-Interim reanaliza asimilira mjerenja, a ETHZ-CCLM-02 simulacija ima dovoljno mali prostorni korak da vjerno opiše gibanja male skale u vremenskom slijedu. Očito je da smanjenje prostornog koraka ne dovodi do linearnog poboljšanja u statističkim parametrima. Sukladno tome i modificirani *BSS* ne pokazuje da RCM-i mogu nadvladati ERA-Interim reanalizu po pitanju vremenske koherentnosti događaja. U svakom slučaju uspješnost ovih statističkih parametara u postupku evaluacije modela treba uzeti s dozom opreza.

Za područje otvorenog mora simulacije uglavnom podcjenjuju, a za kopneno područje precjenjuju izmjerenu brzinu vjetra. To sugerira da treba kontinuirano raditi na poboljšanjima shema za parametrizaciju atmosferskog graničnog sloja. Vremenski koeficijent korelacije veći je nad otvorenim morem i za obalno područje s kompleksnim terenom. U četiri regionalno odabrane skupine postaja maksimalna brzina vjetra najveća je u obalnom području, a opada prema unutrašnjosti. Lokacije nad otvorenim morem i postaje u unutrašnjosti pokazuju manji rasap među članovima ansambla u usporedbi s obalnim postajama gdje dominira precjenjivanje manjih brzina vjetra. Uglavnom su svi promatrani parametri pokazali da su najuspješnije ETHZ RCM simulacije, CNRM-ALADIN53 te SMHI-RCA4, dok su najveće pogreške uočene kod DHMZ-RegCM42 i ICTP-RegCM43 simulacija. ETHZ simulacije i CNRM-ALADIN53 su uspješniji od ERA-Interim reanalize za područje otvorenog mora kod primjene *BSS*-a, što je neočekivano. Važno je napomenuti da nisu uočene značajne razlike koje bi upućivale na bolju izvedbu nehidrostatskih modela na dnevnoj skali. Razlike ovisne o nehidrostatičkoj dinamici modela bile bi lakše uočene kada bi se sve dostupne simulacije usporedile na finoj prostorno-vremenskoj skali ($\sim 1 \text{ h}$ i $< 10 \text{ km}$).

Područja veće brzine SI vjetra i veće stalnosti vjetra zimi duž istočne Jadranske obale uočavaju se u simulacijama i povezana su s opaženim mlazovima bure. Suprotno, jugo se ne uočava lako u klimatologiji prizemnog vjetra, ali se nazire kroz područja manje perzistencije SZ

vjetra iznad južnog Jadrana zimi. Ljeti se iznad sjevernog Jadrana uglavnom uočava SI strujanje povezano s termički generiranim vjetrom (obalnom cirkulacijom i vjetrom obronka koji mijenjaju smjer strujanja unutar 24 h) i slabom burom, dok se iznad južnog Jadrana u klimatologiji uočavaju etezije. Dominanti periodi opisanih strujanja uočavaju se kroz spektralnu analizu koja je pokazala vrlo dobro slaganje s izmjerenim maksimumima na 24 h, 12 h i 8 h.

Analiza klimatskih projekcija tlaka za područje Sredozemlja pokazala je da će zimi *MSLP* rasti, a gradijent tlaka opadati, dok je za ljeti veća težina na smanjenju tlaka, ali su promjene nepouzdanе i vrlo slabe. Prostorna obilježja promjene prizmenog vjetra direktno su povezana s promjenama u gradijentu tlaka.

Klimatologija izvedena iz dnevnih podataka brzine vjetra ukazuje da promjene razdiobe čestina, srednje brzine vjetra i 99. percentil vjetra dostižu vrijednosti od oko 10% promatrajući medijan ansambla krajem 21. stoljeća. Rasap među simulacijama je uglavnom reda veličine samih promjena što ih čini nepouzdanima. Signal promjene jači je pomicanjem prema kraju stoljeća.

Područje Jadrana je zimi, klimatološki gledano, pod jačim utjecajem sinoptičkih gibanja koji onda utječu na formaciju polja prizemnog vjetra. S druge strane, ljeti je sinoptički utjecaj općenito slabiji, a lokalni efekti dominiraju. Stoga je ljeti rasap između članova ansambla veći nego zimi. Zimi se uočava i uniformno ponašanje RCM-a obzirom na odabrani GCM koji upravlja gibanjima na velikoj skali.

Simulacije RCM-a ukazuju na pomak putanja ciklona zimi prema sjeveru. Stoga će se broj ciklonalnih bura vjerojatno smanjiti duž Jadrana. Međutim, ciklone koje zahvate srednji i južni Jadran mogle biti biti intenzivnije, a time onda intenzivnije i pripadne brzine vjetra što se uočava za 99. percentil. Smanjenje srednje brzine juga zimi uz porast broja događaja anticiklalnog juga vodi k zaključku da anticiklono jugo puše nešto slabijim intenzitetom od ciklalnog. Ljeti simulacije pokazuju povećanje broja događaja bure za područja mlazova bure. Istovremeno raste 99. percentil dobiven iz dnevnih srednjaka također u području mlazova bure. Sve navedeno implicira da raste broj događaja umjerene bure, a smanjuje se broj događaja slabe

bure koja je vrlo često superponirana na termički generirano strujanje (obalnu cirkulaciju i vjetar obronka) za vrijeme situacija sa slabim gradijentom tlaka.

Nepouzdanost klimatskih projekcija zbog različitih scenarija emisije stakleničkih plinova (RCP4.5 i RCP8.5) je slabije izražena od nepouzdanosti uvedene zbog odabira određenog RCM-a. Stoga rezultati za RCP4.5 nisu prikazani. Takvo ponašanje ne vrijedi za temperaturu i oborinu, ali je i ranije pronađeno za brzinu vjetra. Razlike između dva analizirana klimatska scenarija su uglavnom oko 5% te rastu prema kraju stoljeća. Također, uočava se i razlika u samom predznaku signala promjene ovisno o scenariju što nije iznenađujuće s obzirom na to da signal budućih promjena nije intenzivan.

Robusnost analize i rezultata pokazana je usporedbom dobivenih rezultata na dnevnoj skali s 15 simulacija (*P2*) te na 6-h skali s devet simulacija. Zaključci ostaju isti, samo je ponegdje intenzitet promjene pojačan. Osim robusnosti rezultata, primijenjena analiza pokazuje da istovremeno naši rezultati ne ovise o veličini ansambla ako izaberemo simulacije koje dobro opisuju rasap unutar većeg ansambla.

Ovaj rad može doprinijeti budućim analizama klimatskih simulacija nad Jadranom, npr. u istraživanju vertikalne strukture atmosfere (pomoću uzgonske, ponekad zvane Brunt Vaisaila frekvencije), odnosno utjecaja topografije na polje strujanja (pomoću Burgerovog broja, Grisogono i Enger, 2004). Osim za meteorološke potrebe, rezultati ovog rada relevantni su i za oceanografska istraživanja termohaline cirkulacije Jadrana i formacije duboke vode, s obzirom na to da bura igra važnu ulogu u interakciji atmosfera-more. Prilikom puhanja bure, važan utjecaj na formiranje Sjeverojadranske vode visoke gustoće, odnosno prilikom puhanja juga često dolazi do obalnog poplavlivanja riva duž jadranske obale (npr. Međugorac i sur., 2015; 2018). Uočeni porast u 99. percentile brzine vjetra ljeti za SSI-ISI strujanje upućuje da je moguć porast vjetro-potencijala duž jadranske obale.

U budućnosti će za potrebe analize prizemnog vjetra biti izrazito važno imati detaljne analize klimatskih promjena koje se mogu dobiti združenim atmosfersko-oceanografskim simulacijama i/ili simulacijama koje razlučuju konvekciju (Belušić i sur., 2018a). Ovo istraživanje potvrđuje potrebu za korištenjem multi-modelskog ansambla za proučavanje rasapa

među simulacijama (ANOVA i *IQR*) zbog izrazite prostorne i vremenske varijabilnosti polja prizemnog vjetra, osobito na najfinijim skalama.

6 LITERATURA

- Aagaard, K., 1969. Relationship between geostrophic and surface winds at weather ship M. *J. Geophys. Res. Atmos.*, **74**(13), 3440–3442. doi:10.1029/JC074i013p03440.
- Accadia, C., Zecchetto, S., Lavagnini, A., Speranza, A., 2007. Comparison of 10-m wind forecasts from a regional area model and QuikSCAT scatterometer wind observations over the Mediterranean Sea. *Mon. Wea. Rev.*, **135**, 1945–1960. doi: 10.1175/MWR3370.1
- Baklanov, A., Grisogono, B., 2007. *Atmospheric Boundary Layers: Nature, Theory and Applications to Environmental Modelling and Security*. *Boundary-Layer Meteorol.* **125**: special issue. Springer: New York
- Bellafiore, D., Bucchignani, E., Gualdi, S., Carniel, S., Djurdjević, V., Umgiesser G., 2012. Assessment of meteorological climate models as inputs for coastal studies. *Ocean Dynamics* **62**(4), 555–568. doi: <https://doi.org/10.1007/s10236-011-0508-2>
- Ban, N., Schmidli, J., Schär, C., 2014. Evaluation of the convection-resolving regional climate modeling approach in decade-long simulations. *J. Geophys. Res. Atmos.*, **119**, 7889–7907. doi:10.1002/2014JD021478
- Ban, N., Schmidli, J., Schär, C., 2015. Heavy precipitation in a changing climate: Does short-term summer precipitation increase faster? *Geophys. Res. Lett.*, **42**, 1165–1172. doi: 10.1002/2014GL062588
- Belušić, A., Telišman Prtenjak, M., Güttler, I., Ban, N., Leutwyler, D., Schär, C., 2018a. Near-surface wind variability over the broader Adriatic region: insights from an ensemble of regional climate models. *Clim. Dyn.*, **50**, 4455–4480. doi:10.1007/s00382-017-3885-5
- Belušić, A.; Güttler, I.; Ahrens, B.; Obermann-Hellhund, A.; Telišman Prtenjak, M., 2018b. Wind over the Adriatic Region in CORDEX Climate Change Scenarios. *J. Geophys. Res. Atmos.*, doi: 10.1029/2018JD028552
- Belušić, D., Güttler, I., 2010. Can mesoscale models reproduce meandering motions? *Q. J. Roy. Meteorol. Soc.*, **136**, 553–565. doi: 10.1002/qj.606
- Benetazzo, A., Fedele, F., Carniel, S., Ricchi, A., Bucchignani, E., Sclavo, M., 2012. Wave climate of the Adriatic Sea: a future scenario simulation, *Nat. Hazards Earth Syst. Sci.*, **12**, 2065–2076. <https://doi.org/10.5194/nhess-12-2065-2012>, 2012.
- Bengtsson, L., Hodges, K.I., Keenlyside, N., 2009. Will extratropical storms intensify in a warmer climate? *J. Clim.*, **22**, 2276–2301. doi:10.1175/2008JCLI2678.1
- Beniston, M., Stephenson, D.B., Christensen, O.B., Ferro, C.A.T., Frei, C., Goyette, S., Halsnaes, K., Holt, T., Jylhä, K., Koffi, B., Palutikof, J., Schöll, R., Semmler, T., Woth, K., 2007. Future extreme events in European climate: an exploration of regional climate model projections. *Clim. Change*, **81**, 71–95. doi:10.1007/s10584-006-9226-z

- Bissolli, P., Dittmann, E., 2001. The objective weather type classification of the German Weather Service and its possibilities of application to environmental and meteorological investigations. *Meteorol. Z.*, **10**, 253-260.
- Bluestein, H. B., 1992. Synoptic-dynamics meteorology in midlatitudes. Oxford University Press, New York, 431 p.
- 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**, 803–817. doi: 10.1007/s00382-013-1742-8
- Branković, Č., Gütler, I., Gajić-Čapka, M., 2013. Evaluating climate change at the Croatian Adriatic from observations and regional climate models' simulations. *Clim. Dyn.*, **41**, 2353–2373. doi: 10.1007/s00382-012-1646-z.
- Cardoso, R. M., Soares, P. M. M., Lima, D. C. A., Semedo, A., 2016. The impact of climate change on the Iberian low-level wind jet: EURO-CORDEX regional climate simulation. *Tellus A*, **68**. doi:10.3402/tellusa.v68.29005
- Cavaleri, L., Bertotti, L., Tescaro, N., 1996. Long term wind hindcast in the Adriatic Sea. *Il nuovo cimento C*, **19**, 67–89. doi: 10.1007/BF02511834
- Christensen, J. H., Carter, T. R., Giorgi, F., 2002. PRUDENCE employs new methods to assess European climate change. *Eos. Trans.*, **83**, 147–147. doi:10.1029/2002EO000094
- Christensen, O. B., Drews, M., Christensen, J. H., Dethloff, K., Ketelsen, K., Hebestadt, I., Rinke, A., 2006. The HIRHAM regional climate model, version 5, *Tech. Rep. 06-17, Dan Meteorol Inst, Copenhagen*. Retrieved from <https://www.dmi.dk/fileadmin/Rapporter/TR/tr06-17.pdf>
- Clarke, R. H., Hess, G. D., 1975. On the relation between surface wind and pressure gradient, especially in lower latitudes. *Bound.-Lay. Meteorol.*, **9**, 325–339. doi:10.1007/BF00230774
- 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*, **62**, 591–604. doi:10.1111/j.1600-0870.2010.00467.x
- Dee, D. P., Uppala, S. M., Simmons, A. J., Berrisford, P., Poli, P., Kobayashi, S., Andrae, U., Balmaseda, M. A., Balsamo, G., Bauer, P., Bechtold, P., Beljaars, A. C. M., Van de Berg, L., Bidlot, J., Bormann, N., Delsol, C., Dragani, R., Fuentes, M., Geer, A. J., Haimberger, L., Healy, S. B., Hersbach, H., Hólm, E. V., Isaksen, L., Kållberg, P., Köhler, M., Matricardi, M., McNally, A. P., Monge-Sanz, B. M., Morcrette, J. J., Park, B. K., Peubey, C., De Rosnay, P., Tavolato, C., Thépaut, J. N., Vitart, F., 2011. The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Q. J. Roy. Meteorol. Soc.*, **137**, 553–597. doi: 10.1002/qj.828
- Déqué, M., Rowell, D. P., Lüthi, D., Giorgi, F., Christensen, J.H., Rockel, B., Jacob, D., Kjellström, E., De Castro, M., Van den Hurk, B., 2007. An intercomparison of regional climate simulations for Europe: Assessing uncertainties in model projections. *Clim. Change*, **81**, 53–70. doi: <https://doi.org/10.1007/s10584-006-9228-x>
- Déqué, M., Somot, S., Sanchez-Gomez, E., Goodess, C. M., Jacob, D., Lenderink, G., Christensen, O. B., 2012. The spread amongst ENSEMBLES regional scenarios: Regional climate models, driving

- general circulation models, and interannual variability. *Clim. Dyn.* **38**, 951–964. doi: <https://doi.org/10.1007/s00382-011-1053-x>
- Di Luca, A., De Elía, R., Laprise, R., 2015. Challenges in the Queste for Added Value of Regional Climate Dynamical Downscaling. *Curr. Clim. Change Rep.*, **1**, 10–21. doi: 10.1007/s40641-015-0003-9
- Domínguez, M., Gaertner, M. A., De Rosnay, P., Losada, T., 2010. A regional climate model simulation over West Africa: Parameterization tests and analysis of land surface fields. *Clim. Dyn.*, **35**, 249–265. doi: 10.1007/s00382-010-0769-3
- Donat, M. G., Leckebusch, G. C., Wild, S., Ulbrich, U., 2011. Future changes in European winter storm losses and extreme wind speeds inferred from GCM and RCM multi-model simulations. *Nat. Hazards Earth Sys*, **11**, 1351–1370. doi:10.5194/nhess-11-1351-2011
- Dufresne, J. L., Foujols, M. A., Denvil, S., Caubel, A., Marti, O., Aumont, O., Balkanski, Y., Bekki, S., Bellenger, H., Benshila, R., Bony, S., Bopp, L., Braconnot, P., Brockmann, P., Cadule, P., Cheruy, F., Codron, F., Cozic, A., Cugnet, D., Noblet, N. de, Duvel, J. P., Ethé, C., Fairhead, L., Fichefet, T., Flavoni, S., Friedlingstein, P., Grandpeix, J. Y., Guez, L., Guilyardi, E., Hauglustaine, D., Hourdin, F., Idelkadi, A., Ghattas, J., Joussaume, S., Kageyama, M., Krinner, G., Labetoulle, S., Lahellec, A., Lefebvre, M. P., Lefevre, F., Levy, C., Li, Z. X., Lloyd, J., Lott, F., Madec, G., Mancip, M., Marchand, M., Masson, S., Meurdesoif, Y., Mignot, J., Musat, I., Parouty, S., Polcher, J., Rio, C., Schulz, M., Swingedouw, D., Szopa, S., Talandier, C., Terray, P., Viovy, N., Vuichard, N., 2013. Climate change projections using the IPSL-CM5 Earth System Model: from CMIP3 to CMIP5. *Clim. Dyn.*, **40**, 2123–2165. doi:10.1007/s00382-012-1636-1
- Dunion, J. P., Landsea, C. W., Houston, S. H., Powell, M. D., 2003. A reanalysis of the surface winds for hurricane Donna of 1960. *Mon. Wea. Rev.*, **131**, 1992–2011. [https://doi.org/10.1175/1520-0493\(2003\)131<1992:AROTSW>2.0.CO;2](https://doi.org/10.1175/1520-0493(2003)131<1992:AROTSW>2.0.CO;2)
- Enger, L., Grisogono, B., 1998. The response of bora-type flow to sea surface temperature. *Q. J. Roy Meteorol. Soc.*, **124**, 1227–1244.
- Feser, F., Rockel, B., Von Storch, H., Winterfeldt, J., Zahn, M., 2011. Regional climate models add value to global model data: A review and selected examples. *B. Am. Meteorol. Soc.*, **92**, 1181–1192. doi: 10.1175/2011BAMS3061.1
- Gampe, D., Nikulin, G., Ludwig, R., 2016. Using an ensemble of regional climate models to assess climate change impacts on water scarcity in European river basins. *Science of The Total Environment*, **573**, 1503–1518. doi: <https://doi.org/10.1016/j.scitotenv.2016.08.053>.
- Gibbons, J. D., Chakraborti, S., 2011. *Nonparametric Statistical Inference*, 5th Ed. Boca Raton, FL: Chapman & Hall/CRC Press, Taylor & Francis Group, 672 p.
- Giorgetta, M. A., Jungclaus, J., Reick, C. H., Legutke, S., Bader, J., Böttinger, M., Brovkin, V., Crueger, T., Esch, M., Fieg, K., Glushak, K., Gayler, V., Haak, H., Hollweg, H. D., Ilyina, T., Kinne, S., Kornblueh, L., Matei, D., Mauritsen, T., Mikolajewicz, U., Mueller, W., Notz, D., Pithan, F., Raddatz, T., Rast, S., Redler, R., Roeckner, E., Schmidt, H., Schnur, R., Segschneider, J., Six, K.D., Stockhause, M., Timmreck, C., Wegner, J., Widmann, H., Wieners, K. H., Claussen, M., Marotzke, J., Stevens, B., 2013. Climate and carbon cycle changes from 1850 to 2100 in MPI-

- ESM simulations for the Coupled Model Intercomparison Project phase 5. *J. Adv. Model. Earth Syst.*, **5**, 572–597. doi:10.1002/jame.20038
- Giorgi, F., Bi, X., 2000. A study of internal variability of a regional climate model. *J. Geophys. Res. Atmos.*, **105**, 29503–29521. doi:10.1029/2000JD900269
- Giorgi, F. & Lionello, P., 2007. Climate change projections for the Mediterranean region. *Global and Planetary Change*, **63**, 90–104. 10.1016/j.gloplacha.2007.09.005.
- Giorgi, F., Coppola, E., Solmon, F., Mariotti, L., Sylla, M., Bi, X., Elguindi, N., Diro, G., Nair, V. S., Giuliani, G., Turuncoglu, U., Cozzini, S., Güttler, I., O'Brien, T., Tawfik, A., Shalaby, A., Zakey, S., Steiner, A., Stordal, F., Brankovic, C., 2012. RegCM4: Model description and preliminary tests over multiple CORDEX domains. *Clim. Res.*, **936**, 7–29. doi:10.3354/cr01018
- Giorgi, F., Csaba, T., Coppola, E., Ban, N., Schär, C., Somot, S., 2016. Enhanced summer convective rainfall at Alpine high elevations in response to climate warming. *Nat. Geosci.*, **9**, 584–589 doi:10.1038/ngeo2761
- Giorgi, F., Gutowski, W. J., 2015. Regional dynamical downscaling and the CORDEX initiative. *Ann. Rev. Env. Resour.*, **40**, 467–490. doi:10.1146/annurev-environ-102014-021217
- Gohm, A., Mayr, G. J., Fix, A., Giez, A., 2008. On the onset of bora and the formation of rotors and jumps near a mountain gap. *Q. J. Roy. Meteorol. Soc.*, **134**, 21–46. doi:10.1002/qj.206.
- Gómez-Navarro, J. J., Raible, C. C., Dierer, S., 2015. Sensitivity of the WRF model to PBL parametrisations and nesting techniques: evaluation of wind storms over complex terrain. *Geosci. Model Dev.*, **8**, 3349–3363. doi:10.5194/gmd-8-3349-2015.
- Grieger, J., Leckebusch, G. C., Donat, M. G., Schuster, M., Ulbrich, U., 2014. Southern Hemisphere winter cyclone activity under recent and future climate conditions in multi-model AOGCM simulations. *Int. J. Climatol.*, **34**, 3400–3416. doi:10.1002/joc.3917
- Grisogono, B., Enger, L., 2004: Boundary-layer variations due to orographic wave-breaking in the presence of rotation. *Quart. J. Roy. Meteorol. Soc.*, **130**, 2991–3014.
- Grisogono, B., Belušić, D., 2009. A review of recent advances in understanding the meso- and microscale properties of the severe Bora wind. *Tellus A*, **61**, 1–16. doi:10.1111/j.1600-0870.2008.00369.x
- Grubišić, V., 2004. Bora-driven potential vorticity banners over the Adriatic. *Q. J. Roy. Meteorol. Soc.*, **130**, 2571–2603. <https://doi.org/10.1256/qj.03.71>
- Güttler, I., Stepanov, I., Branković, Č., Nikulin, G., Colin, J., 2015. Impact of Horizontal Resolution on Precipitation in Complex Orography Simulated by the Regional Climate Model RCA3. *Mon. Wea. Rev.*, **143**, 3610–3627. doi: 10.1175/MWR-D-14-00302.1
- Halpern, D., 1979. Surface wind measurements and low-level cloud motion vectors near the Inter-tropical Convergence Zone in the central Pacific Ocean from November 1977 to March 1978. *Mon. Wea. Rev.*, **107**, 1525–1534.
- Hazeleger, W., Wang, X., Severijns, C., Ștefănescu, S., Bintanja, R., Sterl, A., Wyser, K., Semmler, T., Yang, S., van den Hurk, B., van Noije, T., van der Linden, E., van der Wiel, K., 2012. EC-Earth

- V2.2: description and validation of a new seamless earth system prediction model. *Clim. Dyn.*, **39**, 2611–2629. doi:10.1007/s00382-011-1228-5
- Heimann, D., 2001. A model-based wind climatology of the eastern Adriatic coast. *Meteorol. Z.*, **10**, 5–16. doi: 10.1127/0941-2948/2001/0010-0005
- Herrmann, M., Somot, S., Calmanti, S., Dubois, C., Sevault, F., 2011. Representation of spatial and temporal variability of daily wind speed and of intense wind events over the Mediterranean Sea using dynamical downscaling: impact of the regional climate model configuration. *Nat. Hazards Earth Sys. Sci.*, **11**, 1983–2001. doi: 10.5194/nhess-11-1983-2011
- Horvath, K., Lin, Y. L., Ivančan-Picek, B., 2008. Classification of cyclone tracks over the Apennines and the Adriatic Sea. *Mon. Wea. Rev.*, **136**, 2210–2227. doi:10.1175/2007MWR2231.1
- Horvath, K., Bajić, A., Ivatek-Šahdan, S., 2011. Dynamical downscaling of wind speed in complex terrain prone to bora-type flows. *J. Appl. Meteorol. Clim.*, **50**, 1676–1691. doi:10.1175/2011JAMC2638.1
- Hu, Z. Z., Wu, Z., 2004. The intensification and shift of the annual North Atlantic Oscillation in a global warming scenario simulation. *Tellus A*, **56**, 112–124. doi:10.1111/j.1600-0870.2004.00050.x
- Hueging, H., Haas, R., Born, K., Jacob, D., Pinto, J. G., 2012. Regional changes in wind energy potential over Europe using regional climate model ensemble projections. *J. Appl. Meteor. Climatol.*, **52**, 903–917. doi:10.1175/JAMC-D-12-086.1
- 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., Kriegsman, 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*, **14**, 563–578. doi:10.1007/s10113-013-0499-2
- Jurčec, V., Ivančan-Picek, B., Tutiš, V., Vukičević, V., 1996. Severe Adriatic jugo wind. *Meteorol. Z.*, **5**, 67–75.
- Jury, M. W., Prein, A. F., Truhetz, H., Gobiet, A., 2015. Evaluation of CMIP5 models in the context of dynamical downscaling over Europe. *J. Clim.*, **28**, 5575–5582. doi:10.1175/JCLI-D-14-00430.1
- Katragkou, E., García-Díez, M., Vautard, R., Sobolowski, S., Zanis, P., Alexandri, G., Cardoso, R. M., Colette, A., Fernandez, J., Gobiet, A., Goergen, K., Karacostas, T., Knist, S., Mayer, S., Soares, P. M. M., Pytharoulis, I., Tegoulis, I., Tsikerdekis, A., Jacob, D., 2015. Regional climate hindcast simulations within EURO-CORDEX: evaluation of a WRF multi-physics ensemble. *Geosci. Model Dev.*, **8**, 603–618. <https://doi.org/10.5194/gmd-8-603-2015>
- Kjellström, E., Nikulin, G., Hansson, U., Strandberg, G., Ullerstig, A., 2011. 21st century changes in the European climate: uncertainties derived from an ensemble of regional climate model simulations. *Tellus A*, **63**, 24–40. doi:10.1111/j.1600-0870.2010.00475.x
- 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.*, **7**, 1297–1333. doi: 10.5194/gmd-7-1297-2014
- Knippertz, P., Ulbrich, U., Speth, P., 2000. Changing cyclones and surface wind speeds over the North Atlantic and Europe in a transient GHG experiment. *Clim. Res.*, **15**, 109–122. doi:10.3354/cr015109
- Kuzmić, M., Li, X. M., Grisogono, B., Tomažić, I., Lehner, S., 2013. TerraSAR-X observations of the northeastern Adriatic bora : Early results. *Acta Adriatica*, **54**, 13–26.
- Kuzmić, M., B. Grisogono, X.-M. Li, and S. Lehner, 2015: Discerning a deep and a shallow Adriatic bora event. *Q. J. Roy. Meteorol. Soc.*, **141**, 3434–3438.
- Lamb, H. H., 1950. Types and spells of weather around the year in the British Isles. *Q. J. Roy. Meteorol. Soc.*, **76**, 393–438.
- Laprise, R., de Elía, R., Caya, D., Biner, S., Lucas-Picher, P., Diaconescu, E., Leduc, M., Alexandru, A., Separovic, L., 2008. Challenging some tenets of Regional Climate Modelling. *Meteorol. Atmos. Phys.*, **100**, 3–22. doi:10.1007/s00703-008-0292-9
- Leutwyler, D., Fuhrer, O., Lapillonne, X., Lüthi, D., Schär, C., 2016. Towards European-Scale Convection-Resolving Climate Simulations. *Geosci. Model Dev.*, **9**, 3393–3412. doi: 10.5194/gmd-2016-119
- Leutwyler, D., Lüthi, D., Ban, N., Fuhrer, O., Schär, C., 2017. Evaluation of the Convection-Resolving Climate Modeling Approach on Continental Scales. *J. Geophys. Res. Atmos.*, **122**, 5237–5238 <https://doi.org/10.1002/2016JD026013>
- Lisac, I., 1984. The wind in Zagreb (A contribution to the knowledge of climate of the city of Zagreb, II). *Geofizika*, **1**, 47–134.
- Ludwig, F. L., Horel, J., Whiteman, C. D., 2004. Using EOF Analysis to Identify Important Surface Wind Patterns in Mountain Valleys. *J. Appl. Meteorol.*, **43**, 969–983. doi: 10.1175/1520-0450
- Makjanić, B., 1978. *Bura, Jugo, Etezija*. Contributions to the Knowledge of Weather and Climate, Vol. 5, Yugoslavian Federal Meteorological Institute, 43 p.
- Mayer, S., Fox Maule, C., Sobolowski, S., Christensen, O. B., Sorup, H. J. D., 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
- McCabe, G. J., Clark, M. P., Serreze, M. C., 2001. Trends in northern hemisphere surface cyclone frequency and intensity. *J. Clim.*, **14**, 2763–2768. doi:10.1175/1520-0442(2001)014<2763:TINHSC>2.0.CO;2
- Međugorac, I., Pasarić, M., Orlić, M., 2015. Severe flooding along the eastern Adriatic coast: the case of 1 December 2008. *Ocean Dynamics*, **65**, 817–830. doi:<https://doi.org/10.1007/s10236-015-0835-9>

- Međugorac, I., Orlić, M., Janeković, I., Pasarić, Z., Pasarić, M., 2018. Adriatic storm surges and related cross-basin sea-level slope. *Journal of marine systems*, **181**, 79–90. doi:10.1016/j.jmarsys.2018.02.005
- Menendez, M., García-Díez, M., Fita, L., Fernández, J., Méndez, F. J., Gutiérrez, J. M., 2014. High-resolution sea wind hindcasts over the Mediterranean area. *Clim. Dyn.*, **42**, 1857–1872. doi: 10.1007/s00382-013-1912-8
- Merryfield, W. J., Pal, B. Foreman, M. G. G., 2009. Projected future changes in surface marine winds off the west coast of Canada. *J. Geophys. Res. Atmos.*, **114**. <https://doi.org/10.1029/2008JC005123>.
- Moss, R. H., Edmonds, J. A., Hibbard, K. A., Manning, M. R., Rose, S. K., van Vuuren, D. P., Carter, T. R., Emori, S., Kainuma, M., Kram, T., Meehl, G. A., Mitchell, J. F. B., Nakicenovic, N., Riahi, K., Smith, S. J., Stouffer, R. J., Thomson, A. M., Weyant, J. P., Wilbanks, T. J., 2010. The next generation of scenarios for climate change research and assessment. *Nature*, **463**, 747–756. doi:10.1038/nature08823
- Nakićenović N i sur. (2000) Special report on emission scenarios. A special report of Working Group III of the IPCC. Cambridge University Press, Cambridge
- Nikulin, G., Kjellström M, E., Hansson, U., Strandberg, G., Ullerstig, A., 2011. Evaluation and future projections of temperature, precipitation and wind extremes over Europe in an ensemble of regional climate simulations. *Tellus A*, **63**, 41–55. doi:10.1111/j.1600-0870.2010.00466.x
- Nissen, K. M., Leckebusch, G. C., Pinto, J. G., Renggli, D., Ulbrich, S., Ulbrich, U., 2010. Cyclones causing wind storms in the Mediterranean: characteristics, trends and links to large-scale patterns. *Nat. Hazard Earth Sys., Sci*, **10 (7)**, 1379–1391. ISSN 1684-9981
- Obermann-Hellhund, A., Bastin, S., Belamari, S., Conte, D., Gaertner, M.A., Li, L., Ahrens, B., 2016. Mistral and Tramontane wind speed and wind direction patterns in regional climate simulation. *Clim. Dyn.*, **47**, 1–18. doi: 10.1007/s00382-016-3053-3
- Obermann-Hellhund, A., Conte, D., Somot, S., Torma, C.Z., Ahrens, B., 2017. Mistral and Tramontane wind systems in climate simulations from 1950 to 2100. *Clim. Dyn.* doi:10.1007/s00382-017-3635-8
- Orlić, M., Kuzmić, M., Vučak, Ž., 1986. Wind-curl currents in the Northern Adriatic and formulation of bottom friction. *Oceanol. Acta*, **9**, 425–431.
- Outten, S.D., Esau, I., 2013. Extreme winds over Europe in the ENSEMBLES regional climate models. *Atmos. Chem. Phys.*, **13**, 5163–5172. doi:10.5194/acp-13-5163-2013
- Pandžić, K., 2002. Analiza meteoroloških polja i sustava. HINUS, Zagreb, 315 p.
- Pandžić, K., Likso, T., 2005. Eastern Adriatic typical wind field patterns and large-scale atmospheric conditions. *Int. J. Climatol.*, **25**, 81–98. doi:10.1002/joc.1085
- Pasarić, M., Orlić, M., 2004. Meteorological forcing of the Adriatic: present vs. projected climate conditions. *Geofizika*, **21**, 69–87.

- Pašičko, R., Branković, Č., Šimić, Z., 2012. Assessment of climate change impacts on energy generation from renewable sources in Croatia. *Renewable Energy*, **46**, 224–231. doi: 10.1016/j.renene.2012.03.029
- Penzar, B., Penzar, Ivan, Orlić, M., 2001. *Vrijeme i klima hrvatskog Jadrana*. Nakladna kuća “Dr. Feletar”, Hrvatski hidrografski institute, Zagreb, 258 p.
- Perkins, S. E., Pitman, A. J., Holbrook, N. J., McAneney, J., 2007. Evaluation of the AR4 climate models’ simulated daily maximum temperature, minimum temperature, and precipitation over Australia using probability density functions. *J. Clim.*, **20**, 4356–4376. doi:10.1175/JCLI4253.1
- Perry, K. L., 2001. Sea Winds on QuikSCAT Level 3 Daily, Gridded Ocean Wind Vectors (JPL Sea Winds Project) Version 1.1. (JPL Document D-20335). Jet Propulsion, Pasadena, CA, 40 p.
- Philipp, A., Bartholy, J., Beck, C., Erpicum, M., Esteban, P., Fettweis, X., Huth, R., James, P., Jourdain, S., Kreienkamp, F., Krennert, T., Lykoudis, S., Michalides, S., Pianko, K., Post, P., Rassilla Álvarez, D., Spekat, A., Tymvios, F. S., 2010. COST 733CAT – a database of weather and circulation type classifications. *Phys. Chem. Earth*, **35**, 360–373.
- Pielke, R. A., 2002. *Mesoscale meteorological modeling*. Academic Press, USA, 760 p.
- Pinto, J.G., Fröhlich, E.L., Leckebusch, G.C., Ulbrich, U., 2007. Changing European storm loss potentials under modified climate conditions according to ensemble simulations of the ECHAM5/MPI-OM1 GCM. *Nat. Hazard Earth Sys., Sci.* **7**, 165–175. doi:10.5194/nhess-7-165-2007
- Pinto, J., Karremann, M., Born, K., Della-Marta, P., Klawns, M., 2012. Loss potentials associated with European windstorms under future climate conditions. *Clim. Res.*, **54**, 1–20. doi:10.3354/cr01111
- Poje, D., 1965. Glavni tipovi vremena u Jugoslaviji i njihova zavisnost o visinskim strujanjima. Doktorska disertacija, Prirodoslovno-matematički fakultet Sveučilišta u Zagrebu, 215 pp.
- Poje, D., 1992. Wind persistence in Croatia. *Int. J. Climatol.*, **12**, 569–586. doi:10.1002/joc.3370120604
- Powell, M. D., Houston, S. H., Ares, I., 1995. Real-time damage assessment in hurricanes. Preprints, 21st Conf. on Hurricanes and Tropical Meteorology, Miami, FL, *Amer. Meteor. Soc.*, 500–502.
- Prein, A. F., Gobiet, A., Truhetz, H., Keuler, K., Goergen, K., Teichmann, C., Fox Maule, C., Van Meijgaard, E., Déqué, M., Nikulin, G., Vautard, R., Colette, A., Kjellström, E., Jacob, D., 2016. Precipitation in the EURO-CORDEX 0.11° and 0.44° simulations: high resolution, high benefits? *Clim. Dyn.*, **46**, 383–412. doi: 10.1007/s00382-015-2589-y
- Prein, A. F., Langhans, W., Fosser, G., Ferrone, A., Ban, N., Goergen, K., Keller, M., Tlle, M., Gutjahr, O., Feser, F., Brisson, E., Kollet, S., Schmidli, J., van Lipzig, N. P. M., Leung, R., 2015. A review on regional convection-permitting climate modeling: Demonstrations, prospects, and challenges. *Rev. Geophys.*, **53**, 323–361. doi: 10.1002/2014RG000475
- Pryor, S. C., Barthelmie, R. J., 2003. Long-term trends in near-surface flow over the Baltic. *Int. J. Climatol.*, **23**, 271–289. doi:10.1002/joc.878

- Pryor, S. C., Barthelmie, R. J., Kjellström, E., 2005. Potential climate change impact on wind energy resources in northern Europe: analyses using a regional climate model. *Clim. Dyn.*, **25**, 815–835. doi:10.1007/s00382-005-0072-x
- Pryor S. C., Schoof J.T., 2010. Importance of the SRES in projections of climate change impacts on near-surface wind regimes. *Meteorol. Z.*, **9**, 267–274. doi:10.1127/0941-2948/2010/0454
- Pryor, S. C., Barthelmie, R. J., Clausen, N. E., Drews, M., MacKellar, N., Kjellström, E., 2012. Analyses of possible changes in intense and extreme wind speeds over northern Europe under climate change scenarios. *Clim. Dyn.*, **38**, 189–208. doi:10.1007/s00382-010-0955-3
- Pryor, S. C., Nikulin, G., Jones, C., 2012. Influence of spatial resolution on regional climate model derived wind climates. *J. Geophys. Res. Atmos.*, **117**. doi:10.1029/2011JD01682
- Räisänen, P., Barker, H. W., Khairoutdinov, M. F., Li, J., Randall, D. A., 2004. Stochastic generation of subgrid-scale cloudy columns for large-scale models. *Q. J. R. Meteorol. Soc.*, **130**, 2047–2067. doi:10.1256/qj.03.99
- Ranjha, R., Tjernström, M., Svensson, G., Semedo, A., 2016. Modelling coastal low-level wind-jets: does horizontal resolution matter? *Meteorol. Atmos. Phys.*, **128**, 263–278. doi: 10.1007/s00703-015-0413-1
- Ray, R. D., Poulou, S., 2005. Terdiurnal surface-pressure oscillations over the continental United States. *Mon. Wea. Rev.*, **133**, 2526–2534. doi: 10.1175/MWR2988.1
- Reboita, M. S., Amaro, T. R., de Souza, M. R., 2017. Winds: intensity and power density simulated by RegCM4 over South America in present and future climate. *Clim. Dyn.*, **51**, 187–205 doi:10.1007/s00382-017-3913-5
- Reyers, M., Moemken, J., Pinto, J. G., 2016. Future changes of wind energy potentials over Europe in a large CMIP5 multi-model ensemble. *Int. J. Climatol.*, **36**, 783–796. doi: <http://dx.doi.org/10.1002/joc.4382>
- Rockel, B., Woth, K., 2007. Extremes of near-surface wind speed over Europe and their future changes as estimated from an ensemble of RCM simulations. *Clim. Change*, **81**, 267–280. doi:10.1007/s10584-006-9227-y
- Rockel, B., Will, A., Hense, A., 2008. The Regional Climate Model COSMO-CLM (CCLM). *Meteorol. Z.*, **17**, 347–348. doi:10.1127/0941-2948/2008/0309
- Rummukainen, M., 2010. State-of-the-art with regional climate models. *WIREs Clim. Change*, **1**, 82–96. doi: 10.1002/wcc.8
- Rummukainen, M., 2016. Added value in regional climate modeling. *WIREs Clim. Change*, **7**, 145–459. doi: 10.1002/wcc.378
- Ruti, P. M., Marullo, S., D'Ortenzio, F., Tremant, M., 2008. Comparison of analysed and measured wind speeds in the perspective of oceanic simulations over the Mediterranean basin: analyses, QuikSCAT and buoy data. *J. Mar. Syst.*, **70**, 33–48. doi: 10.1016/j.jmarsys.2007.02.02640.

- 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-Cloch , S., Brauch, J., Cabos, W., Calmanti, S., Calvet, J., Carillo, A., Conte, D., Coppola, E., Djurdjevic, V., Drobinski, P., Elizalde-Arellano, A., Gaertner, M., Gal n, P., Gallardo, C., Gualdi, S., Goncalves, M., Jorba, O., Jord , G., L'Heveder, B., Lebeaupin-Brossier, C., Li, L., Liguori, G., Lionello, P., Maci s, D., Nabat, P.,  nol, B., Raikovic, B., Ramage, K., Sevault, F., Sannino, G., Struglia, M. V., Sanna, A., Torma, C., Vervatis, V., 2016. Med-CORDEX initiative for Mediterranean climate studies. *B. Am. Meteorol. Soc.*, **97**, 1187–1208. <https://doi.org/10.1175/BAMS-D-14-00176.1>
- Samuelsson, P., Jones, C. G., Will n, U., Ullerstig, A., Gollvik, S., Hansson, U., Jansson, C., Kjellstr m, E., Nikulin, G., Wyser, K., 2011. The Rossby Centre Regional Climate model RCA3: model description and performance. *Tellus A*, **63**, 4–23. doi:10.1111/j.1600-0870.2010.00478.x
- Serafin, S., Adler, B., Cuxart, J. & De Wekker, S., Gohm, A., Grisogono, B., Kalthoff, N., Kirshbaum, D., Rotach, M., Schmidli, J., Stiperski, I., Ve enaj,  ., Zardi, D., 2018. Exchange Processes in the Atmospheric Boundary Layer Over Mountainous Terrain. *Atmosphere*, **9**, 102. doi:10.3390/atmos9030102.
- Shchepetkin, A. F., McWilliams, J. C., 2003. A method for computing horizontal pressure-gradient force in an oceanic model with a nonaligned vertical coordinate, *J. Geophys. Res. Atmos.*, **108**(C3), 3090, doi:10.1029/2001JC001047
- Schwierz, C., K llner-Heck, P., Mutter, E. Z., Bresch, D. N., Vidale, P. L., Wild, M., Sch r, C., 2010. Modelling European winter wind storm losses in current and future climate. *Clim. Change*, **101**, 485–514. doi:10.1007/s10584-009-9712-1
- Skamarock, W., Klemp, J., Dudhia, J., Gill, D., Barker, D., Duda, M., Huang, X., Wang, W., Powers, J., 2008. A description of the advanced research WRF version 3. Technical Report, NCAR. <http://opensky.ucar.edu/islandora/object/technotes:500>. Accessed 21 September 2016, 125 p.
- Smith, A., Lott, N., Vose, R., 2011. The integrated surface database: recent developments and partnerships. *B. Am. Meteorol. Soc.*, **92**, 704–708. doi: 10.1175/2011BAMS3015.1
- Somot, S., Ruti, P. M. and the MedCORDEX team, 2011. The Med-CORDEX initiative: towards fully coupled Regional Climate System Models to study the Mediterranean climate variability, change and impact. https://www.medcordex.eu/somot_MedCORDEX_WCRP2011_Denver_oct2011.pdf. Accessed 9 November 2016
- Sotillo, M. G., Ratsimandresy, A. W., Carretero, J. C., Bentamy, A., Valero, F., Gonz lez-Rouco, F., 2005. A high-resolution 44-year atmospheric hindcast for the Mediterranean Basin: contribution to the regional improvement of global reanalysis. *Clim. Dyn.*, **25**, 219–236. doi: 10.1007/s00382-005-0030-7
- Stiperski, I., Ivan an-Picek, B., Grubi i , V., Baji , A., 2012. Complex Bora flow in the lee of Southern Velebit. *Q. J. Roy. Meteorol. Soc.*, **138**, 1490-1506. doi: 10.1002/qj.1901
-  oljan, V., Belu i , A.,  arovi , K., Nimac, I., Brzaj, S., Suhin, J., Belavi , M., Ve enaj,  ., Grisogono, B., 2018. Micro-Scale Properties of Different Bora Types. *Atmosphere*, **9**. <https://doi.org/10.3390/atmos9040116>

- Tang, W., Liu, W. T., Stiles, B. W., 2004. Evaluation of high-resolution ocean surface vector winds measured by QuikSCAT scatterometer in coastal regions., *IEEE Transactions on Geoscience and Remote Sensing*, **42**, 1762–1769. doi: 10.1109/TGRS.2004.831685
- 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
- Teichmann, C., Eggert, B., Elizalde, A., Haensler, A., Jacob, D., Kumar, P., Moseley, C., Pfeifer, S., Rechid, D., Remedio, A. R., Ries, H., Petersen, J., Preuschmann, S., Raub, T., Saeed, F., Sieck, K., Weber, T., 2013. How does a regional climate model modify the projected climate change signal of the driving GCM: A study over different CORDEX regions using REMO. *Atmosphere*, **4**, 214–236. doi:10.3390/atmos4020214
- Telišman Prtenjak, M., Grisogono, B., 2007. Sea/land breeze climatological characteristics along the northern Croatian Adriatic Coast. *Theor. Appl. Climatol.*, **90**(3-4), 201–215. doi:https://doi.org/10.1007/s00704-006-0286-9
- Telišman Prtenjak, M., Viher, M., Jurković, J., 2010a. Sea-land breeze development during a summer Bora event along the north-eastern Adriatic coast. *Q. J. Roy. Meteorol. Soc.*, **136**, 1554–1571. doi: 10.1002/qj. 649
- Telišman Prtenjak, M., Tomažić, I., Kavčič, I., Đivanović, S., 2010b. Characteristics of shallow thermally driven flow in the complex topography of the south-eastern Adriatic. *Ann. Geophys.*, **28**, 1905–1922. doi:10.5194/angeo-28-1905-2010
- Telišman Prtenjak, M., Horvat, I., Tomažić, I., Kvakić, M., Viher, M., Grisogono, B., 2015. Impact of mesoscale meteorological processes on anomalous radar propagation conditions over the northern Adriatic area. *J. Geophys. Res. Atmos.*, **120**, 8759–8782. doi:10.1002/2014JD022626
- The HadGEM2 Development Team: Martin, G. M., Bellouin, N., Collins, W. J., Culverwell, I. D., Halloran, P. R., Hardiman, S. C., Hinton, T. J., Jones, C. D., McDonald, R. E., McLaren, A. J., O'Connor, F. M., Roberts, M. J., Rodriguez, J. M., Woodward, S., Best, M. J., Brooks, M. E., Brown, A. R., Butchart, N., Dearden, C., Derbyshire, S. H., Dharssi, I., Doutriaux-Boucher, M., Edwards, J. M., Falloon, P. D., Gedney, N., Gray, L.J., Hewitt, H. T., Hobson, M., Huddleston, M. R., Hughes, J., Ineson, S., Ingram, W. J., James, P. M., Johns, T. C., Johnson, C. E., Jones, A., Jones, C. P., Joshi, M. M., Keen, A. B., Liddicoat, S., Lock, A. P., Maidens, A. V., Manners, J. C., Milton, S. F., Rae, J. G. L., Ridley, J. K., Sellar, A., Senior, C. A., Totterdell, I. J., Verhoef, A., Vidale, P. L., Wiltshire, A., 2011. The HadGEM2 family of Met Office Unified Model climate configurations. *Geosci. Model Dev.*, **4**, 723–757. doi:10.5194/gmd-4-723-2011
- Tobin, I., Vautard, R., Balog, I., Bréon, F.-M., Jerez, S., Ruti, P. M., Thais, F., Vrac, M., Yiou, P., 2015. Assessing climate change impacts on European wind energy from ENSEMBLES high-resolution climate projections. *Clim. Change*, **128**, 99–112. https://doi.org/10.1007/s10584-014-1291-0
- Tobin, I., Jerez, S., Vautard, R., Thais, F., van Meijgaard, E., Prein, A., Michel Déqué, Kotlarski, S., Maule, C.F., Nikulin, G., Noël, T., Teichmann, C., 2016. Climate change impacts on the power generation potential of a European mid-century wind farms scenario. *Environ. Res. Lett.*, **11**. doi:10.1088/1748-9326/11/3/034013

- Torma, C., Giorgi, F., Coppola, E., 2015. Added value of regional climate modeling over areas characterized by complex terrain- Precipitation over the Alps. *J. Geophys. Res. Atmos.*, **120**, 3957–3972. doi: 10.1002/2014JD022781
- Turuncoglu, U. U., Sannino, G., 2016. Validation of newly designed regional earth system model (RegESM) for Mediterranean Basin. *Clim. Dyn.*, **47**, 1-29. doi: 10.1007/s00382-016-3241-1
- Van Bebber, W., 1891. Die Zugstraßen der barometrischen Minima nach den Bahnenkarten der Deutschen Seewarte für den Zeitraum von 1875-1890. *Meteorol. Z.*, **8**, 361–366.
- Van Brummelen, G., 2013. *Heavenly Mathematics: The Forgotten Art of Spherical Trigonometry*. Princeton University Press, 192 p.
- Van der Linden P., Mitchell, J. F. B., 2009. ENSEMBLES: Climate Change and its Impacts: Summary of research and results from the ENSEMBLES project. *Met Office Hadley Centre*. Retrieved from <https://www.eea.europa.eu/data-and-maps/indicators/global-and-european-temperature-1/ensembles-climate-change-and-its>
- Van Meijgaard, E., van Ulft, L. H., van De Berg, W. J., Bosvelt, F. C., van Den Hurk, B. J. J. M., Lenderink, G., Siebesma, A. P., 2008. The KNMI regional atmospheric model RACMO version 2.1, technical report 302. *Technical report, KNMI, De Bilt, The Netherlands*. Retrieved from <http://bibliotheek.knmi.nl/knmipubTR/TR302.pdf>.
- Vautard, R., Gobiet, A., Jacob, D., Belda, M., Colette, A., Déqué, M., Fernández, J., García-Díez, M., Goergen, K., Güttler, I., Halenka, T., Karacostas, T., Katragkou, E., Keuler, K., Kotlarski, S., Mayer, S., Van Meijgaard, E., Nikulin, G., Patarčić, M., Scinocca, J., Sobolowski, S., Suklitsch, M., Teichmann, C., Warrach-Sagi, K., Wulfmeyer, V., Yiou, P., 2013. The simulation of European heat waves from an ensemble of regional climate models within the EURO-CORDEX project. *Clim. Dyn.*, **41**, 2555–2575. doi: 10.1007/s00382-013-1714-z
- Večenaj, Ž., Belušić, D., Grisogono, B., 2010. Characteristics of the near-surface turbulence during a Bora event. *Ann. Geophys.*, **28**, 155-163. <https://doi.org/10.5194/angeo-28-155-2010>
- Vilibić, I., Šepić, J., Proust, N., 2013. Weakening of thermohaline circulation in the Adriatic Sea. *Clim. Res.*, **55**, 217–225. doi: 10.3354/cr01128.
- Vilibić, I., Šepić, J., Pasarić, M., Orlić, M., 2017. The Adriatic Sea: A long-standing laboratory for sea level studies. *Pure and Applied Geophysics*, **174**, 3765–3811.
- Voldoire, A., Sanchez-Gomez, E., Mélia, D. S., Decharme, B., Cassou, C., Sénési, S., Valcke, S., Beau, I., Alias, A., Chevallier, M., Déqué, M., Deshayes, J., Douville, H., Fernandez, E., Madec, G., Maisonnave, E., Moine, M.-P., Planton, S., Saint-Martin, D., Szopa, S., Tyteca, S., Alkama, R., Belamari, S., Braun, A., Coquart, L., Chauvin, F., 2013. The CNRM-CM5.1 global climate model: description and basic evaluation. *Clim. Dyn.*, **40**, 2091–2121. doi:10.1007/s00382-011-1259-y
- Von Storch, H., Langenberg, H., Feser, F., 2000. a spectral nudging technique for dynamical downscaling purposes. *Mon. Wea. Rev.*, **128**, 3664–3673. [https://doi.org/10.1175/1520-0493\(2000\)128<3664:ASNTFD>2.0.CO;2](https://doi.org/10.1175/1520-0493(2000)128<3664:ASNTFD>2.0.CO;2)

- Welch, P. D., 1967. The use of Fast Fourier Transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms". *IEEE Transactions on Audio and Electroacoustics*, **AU-15** (2), 70–73, doi:10.1109/TAU.1967.1161901
- Weisman, M., Skamarock, W., Klemp, J., 1997. The resolution dependence of explicitly modeled convective systems. *Mon. Wea. Rev.*, **125**, 527–548. [https://doi.org/10.1175/1520-0493\(1997\)125<0527: TRDOEM >2.0.CO;2](https://doi.org/10.1175/1520-0493(1997)125<0527: TRDOEM >2.0.CO;2)
- Williams, D. N., Lawrence, Bryan N., Lautenschlager, M., Middleton, D., Balaji, V., 2011. The Earth System Grid Federation: Delivering globally accessible petascale data for CMIP5. *Climate of the Past*, **32**, 121–121, doi:10.7125/apan.32.15.
- Winterfeldt, J., Weisse, R., 2009. Assessment of Value Added for Surface Marine Wind Speed Obtained from Two Regional Climate Models. *Mon. Wea. Rev.*, **137**, 2955–2965. doi: 10.1175/2009MWR2704.1
- Winterfeldt, J., Geyer, B., Weisse, R., 2011. Using QuikSCAT in the added value assessment of dynamically downscaled wind speed. *Int. J. Climatol.*, **31**, 1028–1039. doi: 10.1002/joc.2105
- Wu, W., Lynch, A., Rivers, A., 2005. Estimating the uncertainty in a regional climate model related to initial and lateral boundary conditions. *J. Clim.*, **18**, 917–933. doi: <https://doi.org/10.1175/JCLI-3293.1>
- Yarnal, B., Comrie, A.C., Frakes, B., Brown, D. P., 2001. Developments and prospects in synoptic climatology. Review. *Int. J. Climatol.*, **21**, 1923–1950.
- Zappa, G., Shaffrey, L. C., Hodges, K. I., 2013. The Ability of CMIP5 Models to Simulate North Atlantic Extratropical Cyclones. *J. Clim.*, **26**, 5379–5396. doi: <https://doi.org/10.1175/JCLI-D-12-00501.1>
- Zecchetto, S., Cappa, C., 2001. The spatial structure of the Mediterranean Sea winds revealed by ERS-1 scatterometer. *Int. J. Remote Sens.*, **22**, 45–70. doi: 10.1080/014311601750038848
- Žagar, N., Žagar, M., Cedilnik, J., Gregorič, G., Rakovec, J., 2006. Validation of mesoscale low-level winds obtained by dynamical downscaling of ERA40 over complex terrain. *Tellus A*, **58**, 445–455. doi: 10.1111/j.1600-0870.2006.00186.x

Dodatak A

Područje izračuna algoritma za određivanje tipova vremena obuhvaća vanjsku domenu s težinom 1 u izračunu ($5-21^{\circ}$ E i $35-50^{\circ}$ N) i unutarnju (jadranska) domenu s težinom 2 u izračunu ($11-20^{\circ}$ E, $40-48^{\circ}$ N). → Izračun težinskog srednjaka preko čitave domene od $\nabla^2 p$ i $\nabla^2 \phi_{500}$. Najprije se provjerava je li minimum (maksimum) tlaka u domeni manji (veći) od 1013.25 hPa zajedno s uvjetima A te na kraju uvjeti B. Ukoliko se jave slučajevi u kojima $\nabla^2 p > 0$ i minimum tlaka > 1013.25 hPa, tada se vrtloženje smatra anticiklonalnim. Ukoliko se jave slučajevi u kojima $\nabla^2 p < 0$ i maksimum tlaka < 1013.25 hPa, tada se vrtloženje smatra ciklonalnim.

A1. Ako $\nabla^2 p > 0$ i $\nabla^2 \phi_{500} > 0$, onda ciklonalno vrtloženje prizemno i u visini.

B1. Ako minimum tlaka (ne mora nužno biti centar) između 41° N i 47° N i zapadnije od 16° E, onda **C1C**.

B2. Ako minimum tlaka (ne mora nužno biti centar) južnije od 41° N, onda **C2C**.

B3. Ako minimum tlaka (ne mora nužno biti centar) između 41° N i 47° N i istočnije od 16° E, onda **C3C**.

B4. Ako minimum tlaka (ne mora nužno biti centar) sjevernije od 47° N, onda **C4C**.

A2. Ako $\nabla^2 p > 0$ i $\nabla^2 \phi_{500} < 0$, onda ciklonalno vrtloženje prizemno, a anticiklonalno u visini.

B1. Ako minimum tlaka (ne mora nužno biti centar) između 41° N i 47° N i zapadnije od 16° E, onda **C1A**.

B2. Ako minimum tlaka (ne mora nužno biti centar) južnije od 41° N, onda **C2A**.

B3. Ako minimum tlaka (ne mora nužno biti centar) između 41° N i 47° N i istočnije od 16° E, onda **C3A**.

B4. Ako minimum tlaka (ne mora nužno biti centar) sjevernije od 47° N, onda **C4A**.

A3. Ako $\nabla^2 p < 0$ i $\nabla^2 \phi_{500} < 0$, onda anticiklonalno vrtloženje prizemno i u visini.

B1. Ako maksimum tlaka (ne mora nužno biti centar) između 41° N i 47° N i zapadnije od 16° E, onda **A1A**.

B2. Ako maksimum tlaka (ne mora nužno biti centar) južnije od 41° N, onda **A2A**.

B3. Ako maksimum tlaka (ne mora nužno biti centar) između 41° N i 47° N i istočnije od 16° E, onda **A3A**.

B4. Ako maksimum tlaka (ne mora nužno biti centar) sjevernije od 47° N, onda **A4A**.

A4. Ako $\nabla^2 p < 0$ i $\nabla^2 \phi_{500} > 0$, onda anticiklonalno vrtloženje prizemno, a ciklonalno u visini.

B1. Ako maksimum tlaka (ne mora nužno biti centar) između 41° N i 47° N i zapadnije od 16° E, onda **A1C**.


B2. Ako maksimum tlaka (ne mora nužno biti centar) južnije od 41° N, onda **A2C**.

B3. Ako maksimum tlaka (ne mora nužno biti centar) između 41° N i 47° N i istočnije od 16° E, onda **A3C**.


B4. Ako maksimum tlaka (ne mora nužno biti centar) sjevernije od 47° N, onda **A4C**.

Dodatak B

Rezultati za graničnu vrijednost brzine 3 m/s. U *P0* (1971.-2000.) je broj događaja bure zimi (Sl. B1) manji nego ljeti (Sl. B2). Srednja brzina vjetra i brzina 99. percentila su ljeti manje nego zimi (Sl. B1b i B2b). Predznak promjene zimi u *P2* (2041.-2070.) u odnosu na *P0* pokazuje smanjenje broja događaja i srednje brzine vjetra bure osim iznad sjevernog Jadrana (Sl. B1g, h), dok brzina 99. percentila raste iznad sjevernog dijela Jadrana (Sl. B1i). Ljeti, broj događaja s brzinom većom od 3 m/s te srednja brzina vjetra intenzivno rastu u područjima jezika bure (Sl. B2g, h).




Slika B1. Rezultati za buru (22.5° - 67.5°) u zimskoj (DJF) sezoni prikazani kao medijan ansambla od devet RCM simulacija u (a-c) medijan za *P0*, (d-f) medijan za *P2* i (g-i) medijan razlika *P2-P0* za pojedinačne simulacije. (a, d, g) broj događaja, (b, e, h) srednja brzina vjetra, (c, f, i) 99. percentil brzine vjetra. Prag brzine je 3 m/s, a scenarij je RCP8.5.




Slika B2. Isto kao Slika B1, ali za JJA sezonu.

Dodatak C


Rezultati analize uz uvjet da bura i jugo moraju puhati istovremeno u 50% točaka iznad Jadrana. Ljeti i za buru (Sl. C2) i za jugo (Sl. C4) postoji vrlo mali broj takvih događaja. Zimi broj takvih intenzivnih događaja opada, ali srednja brzina raste duž gotovo cijelog Jadrana. Signal za medijan promjene 99. percentila brzine vjetra je nešto slabiji, ali postoje naznake za povećanje uz samu obalu u područjima mlazova bure. Broj intenzivnih juga zimi se smanjuje, smanjuje se i srednja brzina te 99. percentil brzine vjetra iznad južnog Jadrana, a rastu iznad sjevernog Jadrana.




Slika C1. Rezultati za buru (22.5° - 67.5°) u zimskoj (DJF) sezoni prikazani kao medijan ansambla od devet RCM simulacija u (a-c) medijan za $P0$, (d-f) medijan za $P2$ i (g-i) medijan razlika $P2-P0$ za pojedinačne simulacije. (a, d, g) broj događaja, (b, e, h) srednja brzina vjetra, (c, f, i) 99. percentil brzine vjetra. Prag brzine je 7 m/s, a dodan je uvjet da barem 50% točaka preko Jadrana mora zadovoljavati uvijek za raspon kutova i brzinu. Scenarij koncentracije stakleničkih plinova je RCP8.5.



Slika C2. Isto kao Slika C1, ali za JJA sezonu.




Slika C3. Isto kao Slika C1, ali za jugo (112.5° - 157.5°).



Slika C4. Isto kao Slika C3, ali za ljetnu (JJA) sezonu.


Dodatak D

PCC parametar na 6-h skali za manji ansambl simulacija (njih 9).




Slika D1. *PCC* vrijednosti za zračnu luku Zadar u RCP8.5 scenariju za: a), d) brzinu vjetra, b), e) *u*-komponentu brzine vjetra, c), f) *v*-komponentu brzine vjetra. Prvi stupac predstavlja rezultate za zimsku (DJF) sezonu, a drugi stupac za ljetnu (JJA) sezonu. Tablica prikazana na svakoj podslici pokazuje broj simulacija koje zadovoljavaju određeni kriterij ($PCC > 0.3$, $0.1 < PCC \leq 0.3$, $0 < PCC \leq 0.1$). Svaki broj na x-osi predstavlja jednu simulaciju redom kao legenda na Slici 19. Svakom broju na x-osi pridružena su tri stupca; P1 (plavo), P2 (zeleno), P3 (crveno). Svaka simulacija naznačena je brojem kao u Tablici 1 u 5. stupcu. Analiza je ponovljena na 6-h podacima za devet simulacija.

Medijan i *IQR* ansambla od 9 simulacija na 6-h skali.




Slika D2. Ansambl medijan (a) i pripadni *IQR* raspon (b) relativne promjene ($P2/P0-1$) po simulacijama za 99. percentil brzine vjetra za RCP8.5 scenarij u zimskoj sezoni. Ansambl se sastoji od devet članova, osim u *P3* koji sadrži pet članova na 6-h skali.



Slika D3. Isto kao Slika D2, ali za JJA sezonu.

Relativne ($P2/P0-1$) promjene za broj događaja vjetra iz raspona smjerova: SSI do ISI ($22.5^\circ - 67.5^\circ$, tipično za buru) i IJI do JJI ($112.5^\circ - 157.5^\circ$, tipično za jugo) za ansambl od 9 simulacija na


6-h skali. Buduće promjene pokazuju da bi zimi moglo doći do smanjenja čestine vjetra iz SI-ISI raspona kutova na postajama Senj, zračna luka Zadar i na lokaciji Srednji Jadran - Južna Dalmacija i povećanje čestine iz raspona kutova SSI-ISI za lokaciju Srednji Jadran - Južna Dalmacija.




Slika D4. Relativne promjene ($P2/P0-1$) čestine vjetra iz dva smjera; SSI-ISI (gornji trokuti u pojedinom polju) i JJI-JJI (donji trokuti u pojedinom polju). Crvena boja označava povećanje čestine, plava smanjenje čestine, dok bijela boja označava promjene u rasponu od -1% do 1%. Rezultati dobiveni iz 6-h podataka.

Dodatak E


Na temelju rezultata RCM-a, povezani su sinoptičku raspodjelu tlaka i događajima bure i juga koji su podijeljeni po tipovima vremena pomoću dnevnih srednjaka tlaka, geopotencijala, te smjera i brzine vjetra.




Slika E1. Broj dana s određenim vremenskim tipom kada u pojedinoj točki domene puše bura (22.5° - 67.5° s pragom brzine 5 m/s) u zimskoj (DJF) sezoni prikazani kao medijan ansambla od devet RCM simulacija. Rezultati za P2 razdoblje.



Slika E2. Isto ako Slika E1, ali za ljetnu (JJA) sezonu.



Slika E3. Broj dana s određenim vremenskim tipom kada u pojedinoj točki domene puše jugo (112.5° - 157.5° s pragom brzine 5 m/s) u zimskoj (DJF) sezoni prikazani kao medijan od devet simulacija. Rezultati za P2 razdoblje.



Slika E4. Isto kao Slika E3, ali za ljetnu (JJA) sezonu.

Životopis

Andreina Belušić Vozila rođena je 04.03.1991. u Rijeci. Srednješkolosko obrazovanje završila je u klasičnoj gimnaziji u Pazinu 2009. godine. Diplomski studij završava 2014. godine na Prirodoslovno-matematičkom fakultetu (PMF) u Zagrebu te stječe zvanje magistra fizike-geofizike. U studenom 2014. 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 2015. godine do kolovoza 2018. godine zaposlena je na Geofizičkom odsjeku PMF-a Sveučilišta u Zagrebu na radnom mjestu asistenta i kao suradnik na projektima CATURBO i VITCLIC. Od kolovoza 2018. do danas zaposlena je u Hrvatskoj kontroli zračne plovidbe (HKZP) na mjestu zrakoplovno meteorološkog motritelja, a znanstveno usavršavanje nastavlja kao suradnik na projektima VITCLIC i SWALDRIC na Geofizičkom odsjeku PMF-a.

Suradnje na projektima

- od 2018. "SWALDRIC" (Severe Weather over the Alpine-Adriatic region in a Changing Climate; Croatian-Swiss Research Programme 2017-2023–CSR)
- od 2017. "VITCLIC" (Viticulture and climate changes in Croatia; HrZZ, br. 09/151)
- 2015. "CATURBO" (Characteristics of turbulence of the bora wind; HrZZ, PKP-2016-06-2975),

Nagrade i priznanja

- Stipendija L'Oreal – UNESCO "Za žene u znanosti" za 2019. godinu
- Godišnja nagrada *Društva sveučilišnih nastavnika i drugih znanstvenika u Zagrebu* mladim znanstvenicima i umjetnicima u 2017. godini
- Sudjelovanje na radu koju je 2017. godine dobio Rektorovu nagradu; Malečić, B.; Simić, N.: "*Development of the cyclone detection and tracking algorithm from regional climate model output*".

- Nagrada Vijeća PMF-a za uspješnog mladog znanstvenika Geofizičkog odsjeka 2017. godine
- Dodjela sredstava *Hrvatske akademije znanosti i umjetnosti (HAZU)* za projekt pod naslovom *Karakteristike prizemnog vjetra dobivenih na temelju simulacija regionalnih klimatskih modela za šire područje Jadrana*
- Mobilnost Sveučilišta u Zagrebu za nekoliko međunarodnih konferencija od 2015. do 2017. godine
- Sufinanciranje *Svjetske meteorološke organizacije (WMO)* sudjelovanja na konferenciji
- e-COST stipendija *Međunarodnog centra za teorijsku fiziku (ICTP)* u Trstu za sudjelovanje na međunarodnoj radionici
- Godišnja nagrada *Roberto i Daniela Giannini* za uspješnog mladog znanstvenika Grada Labina 2015. godine
- Stipendija *Međunarodnog centra za teorijsku fiziku (ICTP)* u Trstu za istraživače iz zemalja u razvoju za sudjelovanje na dvjema međunarodnim radionicama
- Dekanova nagrada za izvrsnost na studiju
- Stipendistica Istarske županije
- Stipendistica Grada Labina

Sudjelovanje u nastavnim aktivnostima

Dinamička meteorologija 3 i 4

Ostalo

- Recenzent na dva rada za hrvatske časopise
- Članica organizacijskog odbora za međunarodnu konferenciju
- Od 2015. godine članica *Hrvatskog meteorološkog društva (HMD)*
- 2014. izrada studentskog projekta *Concentration of PM1 particles in the Geophysical Department building during the period 12/11/2012-26/4/2013*

Popis radova

<http://bib.irb.hr/lista-radova?autor=-333633&print=true>

Objavljeni CC radovi:

4. Soares, P.; Maraun, D.; Brands, S.; Jury, M. W.; Gutiérrez, J. M.; San Martin, D.; Hertig, E.; Huth, R.; **Belušić Vozila, A.**; Cardoso, R. M.; Kotlarski, S.; Dorbinski, P.; Obermann-Hellhund, A., 2018. Process-based evaluation of the VALUE perfect predictor experiment of statistical downscaling methods. *International Journal of Climatology*. doi: 10.1002/joc.5911
3. **Belušić Vozila, A.**; Güttler, I.; Ahrens, B.; Obermann-Hellhund, A.; Telišman Prtenjak, M. Wind over the Adriatic Region in CORDEX Climate Change Scenarios. *Journal of Geophysical Research: Atmospheres* **124**, 110-130. doi: 10.1029/2018JD028552
2. **Belušić, A.**; Telišman Prtenjak, M.; Güttler, I.; Ban, N.; Leutwyler, D.; Schär, C., 2017. Near-surface wind variability over the broader Adriatic region: Insights from an ensemble of regional climate models. *Climate Dynamics* **50**, 4455-4480. doi: 10.1007/s00382-017-3885-5
1. Šoljan, V.; **Belušić, A.**; Šarović, K.; Nimac, I.; Brzaj, S.; Suhin, J.; Belavić, M.; Večenaj, Ž.; Grisogono, B., 2018. Micro-Scale properties of Different Bora Types. *Atmosphere* **9(4)**, 116. doi: 10.3390/atmos9040116

Objavljeni radovi u ostalim časopisima:

1. **Belušić, A.**; Herceg-Bulić, I.; Klaić, B. Z., 2015. Using generalised additive models to quantify the influence of local meteorology on air quality in Zagreb. *Geofizika* **32**, 47-77. doi: 10.15233/gfz.2015.32.5

Sažetci u zbornicima skupova:

25. Marko K.; Telišman Prtenjak, M.; Šimon, S.; Osrečak, M.; Karoglan Kontić, J.; Andabaka, Ž.; Tomaz, I.; Grisogono, B.; **Belušić, A.**; Marki, A.; Prša, Ž.; Omazić, B.; Jelić, D.; Večenaj, Ž.; Petric, I. V.; Leder, R.; Prša, I.; Vučetić, V.; Počakal, D.; Anić, M.; 2019. Within-vineyard temperature variability in the Jazbina hills of Croatia. *Proceedings of 54th Croatian & 14th International Symposium on Agriculture*. Vodice (Hrvatska)

24. Jelić, D.; Megyeri, O. A.; **Belušić Vozila, A.**; Telišman Prtenjak, M.; 2019. Hail climatology along northeastern Adriatic and corresponding weather types. *FIMO-CROHUN & VITCLIC WORKSHOP*, Čigoč (Hrvatska)
23. Karoglan, M.; Telišman Prtenjak, M.; Šimon, S.; Osrečak, M.; Anić, M.; Karoglan Kontić, J.; Andabaka, Ž.; Tomaz, I.; Grisogono, B.; **Belušić, A.**; Marki, A.; Prša, Ž.; Omazić, B.; Jelić, D.; Večenaj, Ž.; Vučetić, V.; Počakal, D.; Petric, I. V.; Leder, R.; Prša, I.; 2018. Classification of Croatian winegrowing regions based on bioclimatic indices. *XII Congreso Internacional Terroir Zaragoza*, Zaragoza (Španjolska)
22. **Belušić, A.**; Güttler, I.; Ahrens, B.; Obermann-Hellhund, A.; Jelić, D.; Megyeri O. A.; Telišman Prtenjak, M.; 2018. The relationship between wind and pressure fields over the broader Adriatic Region in CORDEX Climate Change Scenarios. *EMS Annual Meeting*, Budimpešta (Mađarska)
21. Omazić, B.; Prša, I.; Vučetić, V.; Karlogan, M.; **Belušić, A.**; Telišman Prtenjak, M.; Karlogan Kontić, J.; Osrečak, M.; Andabaka, Ž.; Tomaz, I.; Prša, Ž.; Simon, S.; Vladimira Petrić, I.; Leder, R.; 2018. Analyses of agroclimatic indices applied to Croatian grapevine growing regions in the present climate. *EMS Annual Meeting*, Budimpešta (Mađarska)
20. Omazić, B.; Prša, I.; Vučetić, V.; Karlogan, M.; **Belušić, A.**; Telišman Prtenjak, M.; Karlogan Kontić, J.; Osrečak, M.; Andabaka, Ž.; Tomaz, I.; Prša, Ž.; Simon, S.; Vladimira Petrić, I.; Leder, R.; 2018. Agroclimatic characteristics in the future climate over the Croatian Territory. *EMS Annual Meeting*, Budimpešta (Mađarska)
19. Jelić, D.; Megyeri, O. A.; **Belušić, A.**; Telišman Prtenjak, M.; 2018. Hail climatology and lightning jump climatology along northeastern Adriatic region with accompanying weather types. *EMS Annual Meeting*, Budimpešta (Mađarska)
18. Jelić, D.; Megyeri, O. A.; **Belušić, A.**; Telišman Prtenjak, M.; 2018. New perspectives and applications of lightning jump. *EMS Annual Meeting*, Budimpešta (Mađarska)
17. Soares, P.; Maraun, D.; Brands, S.; Jury, M. W.; Gutiérrez, J. M.; San Martin, D.; Hertig, E.; Huth, R.; **Belušić, A.**; Cardoso, R. M.; Kotlarski, S.; Dorbinski, P.; Obermann-Hellhund, A.; 2018. The VALUE perfect predictor experiment of statistical downscaling methods: process-based evaluation. *EGU General Assembly 2018*, Beč (Austrija)
16. **Belušić, A.**; Güttler, I.; Telišman Prtenjak, M.; 2018. CORDEX projections of the wind flow changes over the Adriatic region. *EGU General Assembly 2018*, Beč (Austrija)
15. Telišman Prtenjak, M.; Karoglan, M.; Šimon, S.; Kordej-De Villa, Ž.; Grisogono, B.; **Belušić, A.**; Vecenaj, Ž.; Marki, A.; Jelić, D.; Omazić, B.; Prša, Ž.; Vučetić, V.; Počakal, D.; Karoglan-

KontiĆ, J.; Tomaz, I.; Osrećak, M.; Andabaka, Ź.; Petrić, I. V.; Leder, R.; Prša, I.; Plavša, T.; Vehovec, M.; Rašić Bakarić, I. (2017). VITCLIC project. *EMS Annual Meeting: European Conference for Applied Meteorology and Climatology 2017*, Dublin (Irska)

14. **BelušiĆ, A.**; Telišman Prtenjak, M.; Güttler, I.; Ban, N.; Leutwyler, D.; Schär, C. (2017). Near-surface wind pattern in regional climate projections over the broader Adriatic region. *EGU General Assembly 2017*, Beć (Austrija)

13. Telišman Prtenjak, M.; Karoglan, M.; Šimon, S.; Kordej-De Villa, Ź.; Grisogono, B.; **BelušiĆ, A.**; Vecenaj, Ź.; Marki, A.; Jelić, D.; Omazić, B.; Prša, Ź.; Vućetić, V.; Poćakal, D.; Karoglan-KontiĆ, J.; Tomaz, I.; Osrećak, M.; Andabaka, Ź.; Petrić, I. V.; Leder, R.; Prša, I.; Plavša, T.; Vehovec, M.; Rašić Bakarić, I. (2017). VITiculture and CLImate Change in Croatia (VITCLIC). *3rd PannEx workshop on the climate system of the Pannonian basin*, Cluj-Napoca (Rumunjska)

12. **BelušiĆ, A.**; Telišman Prtenjak, M.; Güttler, I.; Ban, N.; Leutwyler, D.; Schär, C. (2017). Can regional climate models realistically reproduce the near-surface wind variability over broader Adriatic region? *Joint Congress of the 6th International Conference on Meteorology and Climatology of the Mediterranean and Challenges in Meteorology 5*, Zagreb (Hrvatska)

11. **BelušiĆ, A.**; Keresturi, E.; Šoljan, V.; Većenaj, Ź.; Grisogono, B. (2017). Estimation of Bora Turbulence at the New Micrometeorological Research Facility. *17th Conference on Mountain Meteorology*, Burlington VT (USA)

10. **BelušiĆ, A.**; Telišman Prtenjak, M.; Güttler, I. (2016). Near-surface wind patterns obtained by regional climate simulations for south-eastern Europe. *2nd PannEx Workshop on the climate system of the Pannonian basin*, Budimpešta (Mađarska)

9. Grisogono, B.; Vecenaj, Ź.; **BelušiĆ, A.**; Šarovic, K.; Brzaj, S.; Nimac, I.; Suhin, J.; Šoljan, V.; Belavić, M. (2016). Microscale properties of bora turbulence at the new micrometeorological research facility. *2nd PannEx Workshop on the climate system of the Pannonian basin*, Budimpešta (Mađarska)

8. Viher, M.; Telišman Prtenjak, M.; **BelušiĆ, A.**; Petrović J. (2016). Spectral analysis of six years long time series of radio wave surface refraction index. *10th Annual Baška GNSS Conference*, Baška (Hrvatska)

7. **BelušiĆ, A.**; Telišman Prtenjak, M.; Güttler, I. (2016). RegCM performance over the Adriatic region with respect to EURO-CORDEX and MED-CORDEX regional climate model simulations: evaluation of the near-surface wind. *Eighth ICTP Workshop on the Theory and Use of Regional Climate Models*, Trst (Italija)

6. Güttler, I.; Giuliani, G.; Coppola, E.; Giorgi, F.; **Belušić, A.**; Telišman Prtenjak, M. (2016). Nonhydrostatic vs. hydrostatic dynamics: testing new capabilities in RegCM. *Eighth ICTP Workshop on the Theory and Use of Regional Climate Models*, Trst (Italija)
5. **Belušić, A.**; Telišman Prtenjak, M.; Güttler, I. (2016). EURO-CORDEX and MED-CORDEX near-surface wind field over the Adriatic region: is there an added value in high resolution RCM simulations? *ICRC-CORDEX 2016*, Stockholm (Švedska)
4. **Belušić, A.**; Güttler, I.; Telišman Prtenjak, M. (2015). Near-surface wind climatology over Adriatic and Pannonian regions in an ensemble of RCM simulations. *Challenges in Meteorology 4*, Zagreb (Hrvatska)
3. **Belušić, A.**; Güttler, I.; Telišman Prtenjak, M. (2015). Evaluation of near-surface wind characteristics obtained by an ensemble of RCM simulations over the Pannonian region. *GEWEX workshop on the climate system of the Pannonian basin*, Osijek (Hrvatska)
2. **Belušić, A.**; Güttler, I.; Telišman Prtenjak, M. (2015). Near-surface wind climatology over the eastern Adriatic coast in an ensemble of RCM simulations. *33rd International Conference on Alpine Meteorology*, Innsbruck (Austrija)
1. **Belušić, A.**; Herceg-Bulić, I.; Lowe, R. (2014). Quantifying the influence of local meteorological conditions on air quality in Zagreb using generalized additive models. *Workshop on advances in meso- and micro-meteorology*, Donja Stubica (Hrvatska)