Termohalina svojstva i dinamički procesi u Jadranskome moru simulirani regionalnim klimatskim modelima

Dunić, Natalija

Doctoral thesis / Disertacija

2019

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:557448

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb



Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet
Geofizički odsjek

Natalija Dunić

TERMOHALINA SVOJSTVA I DINAMIČKI PROCESI U JADRANSKOME MORU SIMULIRANI REGIONALNIM KLIMATSKIM MODELIMA

DOKTORSKI RAD

Mentor:
dr. sc. Ivica Vilibić

Zagreb, 2019.



Sveučilište u Zagrebu

Faculty of Science
Department of Geophysics

Natalija Dunić

THERMOHALINE PROPERTIES AND DYNAMICAL PROCESSES IN THE ADRIATIC SEA SIMULATED WITH REGIONAL CLIMATE MODELS

DOCTORAL DISSERTATION

Supervisor:
dr. sc. Ivica Vilibić

Zagreb, 2019

Nitko nije ravnodušan prema moru. Posebno ljudi koji su okusili njegovu zastrašujuću snagu. Ljudi kojima sam okružena od malena - lokalni mještani, naši pomorci. I moj tata me učio da treba poštovati snagu mora, ali mi je pokazao i ljepotu njegove smirenosti. Veoma sam zahvalna što sam dobila priliku učiti i proučavati neke od tajni koje more krije. More je za mene oduvijek bilo fascinantno. Stoga, hvala svima koji su bili uz mene na mom zadnjem koraku, stjecanja doktorata znanosti iz oceanografije.

Posebno se želim zahvaliti svom mentoru i prijatelju, dr. sc. Ivici Vilibiću, na njegovom stručnom vodstvu tijekom studija te na njegovoj nesebičnoj pomoći i podršci tijekom izrade doktorske disertacije. U radu mi je omogućio samostalnost, a svojim savjetima me je uvijek usmjeravao na pravi put. Prilike koje mi je pružio tijekom studija su nebrojene, čime je ovaj rad prepoznat i u međunarodnim znanstvenim krugovima. Također se želim zahvaliti članovima povjerenstva dr. sc. Miri Pasarić, dr. sc. Nastjenjki Supić i dr. sc. Ivanu Güttleru na njihovim konstruktivnim komentarima.

Svoju zahvalnost želim uputiti i svim znanstvenicima grupe CNRM, posebice Samuelu Somotu, Florence Sevault i Robinu Waldmanu, na njihovom gostoprimstvu te na tome što su mi omogućili pristup numeričkim modelima i bili od iznimne pomoći u razumijevanju modela NEMOMED.

Hvala svim profesorima Geofizičkog odsjeka Prirodoslovno - matematičkog fakulteta Sveučilišta u Zagrebu, posebice akademiku Mirku Orliću i dr. sc. Zoranu Pasariću, na njihovim prenešenim znanjima i korisnim savjetima.

Hvala i svim djelatnicima Instituta za oceanografiju i ribarstvo u Splitu i Centra za istraživanje mora u Rovinju koji su sudjelovali u prikupljanju oceanografskih podataka korištenih u ovoj disertaciji. Bez njih ovo istraživanje, kao i brojna prije, ne bi bila moguća.

Veliko hvala svim mojim kolegama, Jadranki Šepić, Maji Bubalo, Žarku Kovaču, Tomislavu Džoiću, Franu Matiću i Hrvoju Mihanoviću na svoj pomoći koju su mi pružili u ovih zadnjih 4 i pol godine. Hvala i mojim dragim prijateljima koji su bili uz mene u svakom teškom trenutku.

Posebno hvala mom bratu Stefanu, za sve što je napravio. Još jednom si mi pokazao da boljeg brata nisam mogla dobiti!

I na kraju, svoju najveću zahvalnost želim izraziti svojim roditeljima, Alli i Zdenku, na njihovoj velikoj ljubavi, potpori i razumijevanju kroz sve ove godine. Uz vas su i najteži trenutci bili lakši!

Natalija Dunić



"*More, kad jednom baci svoje čini, pojedinca zauvijek zarobljava u svojoj mreži divljenja"*

Jacques Yves Cousteau

Ovaj rad je u potpunosti izrađen u Laboratoriju za fiziku mora Instituta za oceanografiju i ribarstvo u Splitu pod vodstvom dr. sc. Ivice Vilibića s Instituta za oceanografiju i ribarstvo u Splitu.

Dr. sc. Ivica Vilibić je završio Prirodoslovno matematički fakultet u Zagrebu, gdje je u prosincu 2002. godine obranio disertaciju pod naslovom „Objektivna analiza vodenih masa u Jadranu“. U travnju 2004. godine zapošljava se na Institutu za oceanografiju i ribarstvo, a danas je znanstveni savjetnik u trajnom zvanju.

Aktivno se bavi raznim temama u istraživanju mora, napose dinamikom vodenih masa u Jadranu i Mediteranu, tsunamijima i meteorološkim tsunamijima, oscilacijama razine mora, klimatskim trendovima i varijacijama, interdisciplinarnim istraživanjima mora, te uvođenjem novih matematičkih metoda u oceanografiji. Vodio je i bio suradnik u više desetaka nacionalnih i međunarodnih projekata. Objavio je preko 110 izvornih znanstvenih radova, dok mu broj citata iznosi više od 1900. Recenzent je u više desetaka međunarodnih i domaćih projekata, te stotinjak znanstvenih radova, uključujući i radove iz vrhunskih znanstvenih časopisa. Bio je voditelj više doktorskih i diplomskih studenata, te poslijedoktoranada. Organizirao je nekoliko međunarodnih znanstvenih konferencija i radionica, uključujući i Prvu svjetsku konferenciju o meteorološkim tsunamijima (Split, svibanj 2019. godine). Dobitnik je Državne nagrade za znanost za 1999. godinu u kategoriji mladih znanstvenika i novaka te za 2012. godinu za značajno znanstveno dostignuće u prirodnim znanostima, kao i nagrade Ferruccio Mosetti Sveučilišta u Trstu, Italija, za 2002. godinu. Kao nacionalni predstavnik, sudjelovao je u radu Međuvladine oceanografske komisije i njezinih tijela, te je bio član više stručnih tijela, kao što su Nacionalno povjerenstvo za Okvirne istraživačke programe EU, Programski odbor za FP7 i Obzor 2020 EU, Odbor za etiku u znanosti i visokom obrazovanju, te znanstveni odbor Hrvatske zaklade za znanost.

SAŽETAK

Tijekom zimskog razdoblja, zbog izloženosti udarima hladne i snažne bure, na sjevernom i južnom Jadranu se stvaraju guste vodene mase, koje utječu na termohalinu cirkulaciju u istočnom Sredozemlju. Stvaranje guste vode u Jadranu utječu i na Jadransko-jonsku bimodalnu oscilaciju (engl. *Adriatic-Ionian Bimodal Oscillating System*, BiOS), koja određuje termohaline karakteristike Jadrana. U doktorskom istraživanju se ispituje koliko dobro regionalni oceanski klimatski modeli za Sredozemlje reproduciraju navedene procese kao i termohalina svojstva u Jadranu. Analizirano je sedam regionalnih klimatskih simulacija modelom NEMOMED. Cilj istraživanja je testiranje različitih modelskih postavki na ponašanje modela pri reprodukciji termohalinih svojstava jadransko-jonskog bazena te njihovih varijabilnosti. Simulacije su verificirane pomoću *in situ* hidroloških podataka prikupljenih na više klimatoloških postaja u razdoblju 1960. - 2012., te pomoću podataka razine mora dobivenih altimetrijskim mjerenjima. Simulacije spregnutih modela su pokazale bolju sposobnost reprodukcije stvaranja guste vode u Jadranu, s nižim zabilježenim odstupanjima temperature i saliniteta, varijabilnosti te promjena vezane uz BiOS: promjena u cirkulaciji sjevernog Jonskog mora i povezanu dekadsku varijabilnost termohalinih svojstava Jadrana. Simulacije nespregnutih modela koji imaju višu vertikalnu rezoluciju oceanskog modela pokazuju bolju sposobnost reproduciranja svojstava i dinamike Levantinske intermedijarne vode. Upotreba veće rezolucije atmosferskog i oceanskog modela je rezultirala realističnijim prostornim obilježjima procesa stvaranja guste vode u kompleksnom području sjevernog Jadrana. Utjecaj riječnih forsiranja na termohalina svojstva jadransko-jonskog sustava nije izražen. Uključivanje trenda aerosola je poboljšalo reprodukciju promjene u cirkulaciji sjevernog Jonskog mora.

Simulacije spregnutih modela u načelu imaju bolju sposobnost reprodukcije stvaranja duboke vode u Jadranu te BiOS-a i svojstava jadransko-jonskog sustava. Stoga je i analizirana simulacija buduće klime Jadrana pomoću potpuno spregnutog atmosfersko-morskog modela NEMOMED za Sredozemlje, pri čemu su pretpostavljena tri uobičajena scenarija emisije stakleničkih plinova (RCP2.6, RCP4.5 i RCP8.5). Projekcije za sva tri scenarija pokazuju porast površinske temperature i saliniteta u Jadranu i jačanje mehanizma BiOS-a do kraja 21. stoljeća, posebice izraženo u scenariju RCP8.5.

EXTENDED ABSTRACT

Wintertime cooling on the shelf and deep convection process, common for the Adriatic Sea, are recognized as major drivers of the Adriatic-Ionian thermohaline circulation (Orlić et al., 2006). To observe, simulate and understand climate-scale variability of the thermohaline circulation and its drivers is still very challenging. Because of geographical position of the Adriatic Sea and the surrounding topography, the bursts of cold and dry Bora wind blowing over the basin (Grisogono and Belušić, 2009) are responsible for the Dense Water Formation (DWF) processes, in particular for:

- Very cold and dense Northern Adriatic Dense Water (NAdDW) generated at shallow northern Adriatic shelf. After its formation, NAdDW is advected towards southeast in form of a bottom density current that travels along the western shelf and fills the deepest parts of the Adriatic (Jabuka Pit and South Adriatic Pit).
- Adriatic Deep Water (ADW) that is formed through deep convection inside the South Adriatic cyclonic gyre. Joined with NAdDW, through Otranto Strait, ADW flows towards the Ionian Sea, where it fills the deepest layers of the Eastern Mediterranean (Zore-Armanda, 1963; Schlitzer et al., 1991; Artegiani et al., 1997a; Vilibić et al., 2004).

Adriatic deep water masses are important for several reasons. As mentioned, they contribute to the Eastern Mediterranean circulation sustainability (Roether and Schlitzer, 1991; Manca et al., 2002) and refresh the deep layers of that area by bringing oxygenized waters (Malanotte-Rizzoli i Robinson, 1988). They drive the thermohaline circulation of the Adriatic-Ionian basin (Orlić et al., 2006; Vilibić et al., 2013), and influence observed decadal oscillation of the northern Ionian Sea circulation (Borzelli et al., 2009), which in turn affects the dynamics of entire middle and eastern Mediterranean, especially of the Adriatic Sea (Gačić et al., 2010). The feedback mechanism between the Adriatic DWF and the circulation patterns of northern Ionian is called The Adriatic-Ionian Bimodal Oscillating System (BiOS), and is recognized as the main feature that drives the decadal variability of the Adriatic thermohaline properties (Mihanović et al., 2015).

In this PhD research regional climate modelling approach is used to study thermohaline properties and variability of the Adriatic Sea. The research includes qualitative and quantitative analysis of the Adriatic thermohaline circulation and its variability, focusing on the processes of the DWF and the BiOS.

Past experiences in modelling studies suggest the important issues to be implemented in order to properly reproduce the Adriatic-Ionian ocean processes, such as the DWF and the BiOS:

- proper introduction of topography and bathymetry (Hendershot and Rizzoli, 1976),
- high spatial and temporal resolution of the ocean (Pinardi et al., 1996) and atmospheric (Bergamasco et al., 1999; Beg-Paklar et al., 2001) components of a model,
- proper introduction of buoyancy fluxes (Vested et al., 1998; Raicich et al., 2013) and river discharges (Janeković et al., 2014), and
- appropriate boundary conditions (Mantziafou and Lascaratos 2004, 2008; Oddo and Guarnieri, 2011).

However, all these researches were conducted with short-term numerical simulations, for which their results were limited only to the evaluation of the Adriatic-Ionian ocean processes on shorter timescales (up to 10 years). In order to quantify long-term changes of oceanographic properties related to the Adriatic-Ionian thermohaline circulation, and to test the performance of climate models with different setup in the basin (following previous suggestions), seven different regional hindcast simulations based on various configurations of NEMO–Mediterranean[1] versions covering ERA-Interim[2] period (1980 - 2012) were tested. This work is also testing the performance of coupled vs. non-coupled modelling approach. The chosen simulations of regional climate models are produced within the framework of the Med-CORDEX[3] initiative (www.medcordex.eu), and are differing in their vertical and horizontal resolution, freshwater load, surface heat fluxes, air-sea interaction, and inclusion or not of the aerosol trend. The objective of this research is to evaluate the reliability of regional climate models for the Mediterranean region to reproduce the Adriatic-Ionian ocean dynamics, through their validation on *in situ* observations, and through detailed assessment of both Adriatic DWF processes and the BiOS, as well as their multi-decadal variability. The goal is to find the optimal model which will be the most reliable for quantification of Adriatic-Ionian thermohaline circulation in the future.

Performance of all seven simulations is evaluated on the long-term *in situ* data collected over three northern Adriatic transects, along the Palagruža Sill transect, at Jabuka Pit and at

[1] NEMO (engl. *Nucleus for European Modelling of the Ocean*) is a state-of-the-art modelling framework for research activities and forecasting services in ocean and climate sciences.
[2] ERA-Interim is a global atmospheric reanalysis dataset starting from the beginning of 1979, developed by the ECMWF (engl. *European Centre for Medium-Range Weather Forecasts*).
[3] Med-CORDEX is an initiative proposed by the Mediterranean climate research community.

South Adriatic Pit, as well as on the altimetry satellite observations. Detailed description of the Adriatic-Ionian thermohaline properties and dynamics is provided in Section 1. Section 2 covers the description of all used simulations, *in situ* and altimetry obtained data, and details of the performed analysis. A performance analysis of the NEMOMED8 ocean regional circulation model is given in Section 3. The analysis was undertaken for the Adriatic Sea during the period of 1961–2012, focusing on two mechanisms: the DWF and the BiOS, which drive interannual and decadal variability in the basin. The model was verified on sea surface temperature, sea surface height and long-term hydrographic *in situ* observations from several key areas. NEMOMED8 simulation qualitatively reproduces basin-scale processes, in particular:

- thermohaline-driven cyclonic circulation and freshwater surface outflow along the western Adriatic coast,
- dense water dynamics, and
- the inflow of Ionian and Levantine waters to the Adriatic.

However, positive temperature and salinity biases are reported; the latter particularly large along the eastern part of the basin, presumably because of the inappropriate introduction of eastern Adriatic rivers into the model. The highest positive temperature biases in the vertical direction were found in dense water collectors in the Adriatic, i.e. Jabuka Pit and South Adriatic Pit, indicating either inappropriate quantification of DWF processes or temperature overestimation of modelled dense water, especially of NAdDW. Moreover, much reduced model domain compared to the real bathymetry, which does not include entire coastal area of the northern Adriatic where the largest heat losses are found, i.e. the part of the Kvarner Bay (Janeković et al., 2014), also led to an underestimation of the cumulative surface heat losses during wintertime cold outbreaks, and therefore to the underrepresentation of the NAdDW formation. As a consequence, the simulated NAdDW is of lower volume when it comes to the deep layers of South Adriatic Pit. Thus, an overestimation in vertical mixing of water column during deep convection process has been documented by the NEMOMED8 model.

The DWF rates are qualitatively well reproduced by the model, being larger when preconditioned by higher basin-wide salinities. The decadal variability in the thermohaline properties is reproduced better than interannual variability, which is considerably underestimated. However, a key process that drives the Adriatic decadal variability, the BiOS, is not properly reproduced, in particular current reversals and outreach of the Northern Ionian

gyre. The only appearance of anticyclonic circulation simulated by the NEMOMED8 in the northern Ionian Sea was found only during the Eastern Mediterranean Transient.

Next, performance analysis of seven regional ocean configurations based on NEMO has been carried out for the Adriatic Sea over a common period (1980 - 2012). The goal of the study was to test the model performances with different settings, particulary when it comes to reproduction of the Adriatic-Ionian thermohaline properties and variability. The analysis is given in Section 4. Simulations differ in resolution, model physics, atmospheric forcing (forced vs. coupled models) and river discharges imposed within the Adriatic Sea. Models have been evaluated on the long-term temperature and salinity measurements in all of the Adriatic sub-basins, in particular within dense water collectors (Jabuka Pit and South Adriatic Pit) and dense water formation sites (northern and southern Adriatic). Adriatic-wide salinity values are mostly linked to the proper introduction of the overall water budget, rather than to the local river forcing. Forced models mostly overestimate temperature and salinity values. On average, coupled models better reproduce the thermohaline properties and processes, in particular the BiOS reversals and its decadal variability. Wintertime heat losses are playing major role in defining the ADW transport rates in coupled models, while preconditioning in salinity is the most important factor in forced models. Further on, increase of resolution of the atmospheric forcing results in more realistic ocean dynamics, including the DWF in the complex coastal northern Adriatic. However, all models have large positive temperature biases at the dense water collector sites, indicating overall underrepresentation of the Adriatic DWF. Consequently, mixed-layer depth in the southern Adriatic is overestimated, reaching the bottom during some years and in some models. Ocean model resolution and river forcing seem to play a second-order role in defining the overall Adriatic-Ionian thermohaline properties, while inclusion of aerosol trend only slightly modified the reproduction of the BiOS.

Lastly, a preliminary analysis of future projections which contain the very first attempt to quantify the processes of the DWF and the BiOS in the future climate, is described in Section 5. This also applies to the evolution of surface temperatures and salinities. The NEMOMED8 simulations were forced by three future scenarios of Representative Concentration Pathways (RCP, IPCC, 2013): RCP2.6, RCP4.5 and RCP8.5. The analysis is performed for the three future periods: near (2011 - 2040), middle (2041 - 2070), and far future (2071 - 2100), with respect to the last 30 years of the referent period simulated in historical simulation (1976 - 2005). No significant trends in all analyzed parameters were found in control simulation covering the period 1950 - 2100.

Towards the end of 21st century, under all three scenarios, gradual increase in basin-wide sea surface temperature (*SST*) was found, of which RCP8.5 is resulting with highest SST at the end of the 21st century, about 2.7 °C on average. All scenarios result also in an increased sea surface salinity (*SSS*), more pronounced at the coastal parts of the Adriatic, with highest increase found in RCP8.5. All three scenarios show a decrease in maximum mixed layer depth (*MLD*), suggesting a weakening of deep convection processes by the end of the 21st century. As for the analysis of the BiOS related processes, all scenarios are projecting an increase in intensity of the positive BiOS index (anticyclonic circulation in northern Ionian Sea), which favors the advection of less saline water masses coming from the Western Mediterranean to the Adriatic. The strengthening of the both positive and negative BiOS regimes is only projected with RCP8.5 scenario, more pronounced in the anticyclonic phase.

Ključne riječi: Jadransko more, termohalina svojstva, proces stvaranja gustih voda, Jadransko-jonska bimodalna oscilacija, dekadska varijabilnost, regionalno modeliranje okrajnjih mora, validacija numeričkih simulacija, buduća klima, RCP scenariji

Keywords: Adriatic Sea, Thermohaline processes, Dense water formation, Adriatic-Ionian Bimodal Oscillating System, Decadal variations, Regional climate modelling, Model validation, Future climate, RCP scenarios

Sadržaj

1. UVOD 1

1.1. Regionalni oceanski klimatski modeli za Sredozemno more 1

1.2. Termohalina cirkulacija Jadrana 3

1.3. Stvaranje jadranskih gustih vodenih masa 5

1.4. Jadransko-jonska bimodalna oscilacija (BiOS) 7

1.5. Kratak opis doktorskog rada 9

2. MATERIJALI I METODE 11

2.1. Regionalni oceanski modeli za reproduciranje sadašnje klime 11

2.1.1. Osnovne značajke modela NEMO 11

2.1.2. Opis konfiguracija modela NEMOMED i simulacija 12

2.2. Spregnuti atmosfersko-oceanski model buduće klime 17

2.2.1. Osnovne značajke modela CNRM-RCSM4 17

2.2.2. Opis konfiguracije kontrolne, povijesne i projekcijske simulacije 17

2.3. Područja jadransko-jonskog bazena nad kojima su se vršile analize 19

2.4. Podaci korišteni za analizu simulacija 21

2.4.1. *In situ* podaci temperature i saliniteta 21

2.4.2. Satelitski podaci razine mora 22

2.5. Metode analiza 23

2.5.1. Određivanje horizontalnog transporta i volumena gustih voda 23

2.5.2. Određivanje dubine miješanja i indeksa stratifikacije 24

2.5.3. Određivanje BiOS indeksa 25

2.5.4. Metoda samo-organizirajućih polja (SOM) 25

3. ANALIZA SIMULACIJE MED8F U RAZDOBLJU 1961. - 2012. 28

3.1. Analiza srednjih polja modela 28

3.2. Validacija pomoću *in situ* mjerenja temperature i saliniteta 31

3.3. Međugodišnja i dekadska varijabilnost 35
3.4. Stvaranje guste vode 37
3.5. Dekadska varijabilnost i mehanizam BiOS-a 44
3.6. Diskusija 53
4. USPOREDBA SIMULACIJA NEMOMED U RAZDOBLJU 1980. - 2012. 56
4.1. Analiza forsiranja riječnim dotocima 56
4.2. Analiza površinskih protoka topline u zimskom razdoblju 58
4.3. Analiza srednjih termohalinih polja 60
4.4. Validacija simulacija NEMOMED pomoću mjerenja temperature i saliniteta 69
4.4.1. Sjeverni Jadran 69
4.4.2. Srednji i južni Jadran 71
4.5. Validacija procesa jadransko-jonskog sustava 75
4.5.1. Stvaranje guste vode 75
4.5.1.1. Sjeverni Jadran 76
4.5.1.2. Južni Jadran 84
4.5.1.3. Varijabilnost stvaranja jadranskih gustih voda 88
4.5.2. Jadransko-jonska bimodalna oscilacija 89
4.6. Diskusija 91
5. SIMULACIJE BUDUĆE KLIME 96
5.1. Analiza projekcija polja temperature 97
5.2. Analiza projekcija polja saliniteta 103
5.3. Analiza projekcija dubine miješanja 108
5.4. Analiza projekcija BiOS-a 110
5.5. Diskusija 113
6. ZAKLJUČCI 115
7. POPIS LITERATURE 118
8. ŽIVOTOPIS – NATALIJA DUNIĆ, mag. phys. 137

9. POPIS OBJAVLJENIH RADOVA – NATALIJA DUNIĆ 138

1. UVOD

1.1. Regionalni oceanski klimatski modeli za Sredozemno more

Razvoj globalnih oceanskih modela (engl. *Ocean General Circulation Models*, OGCM) omogućio je detaljno proučavanje svojstava i procesa u oceanima bitnih za opisivanje dinamike svjetskih oceana. Na klimatskim skalama u prošlosti i budućnosti, oceanski modeli su primarni alati za istraživanje dinamike mora (Danabasoglu, 2004; IPCC, 2014). Međutim, zbog njihove relativno grube prostorne rezolucije, globalni oceanski modeli još uvijek nisu u mogućnosti razlučiti procese koji se odvijaju na mezoskali, tj. one koji dominiraju u obalnim područjima i okrajnjim morima, budući da se ti procesi odvijaju na prostornim skalama od svega nekoliko kilometara do nekoliko desetaka kilometara i u kraćim vremenskim razdobljima.

Kompleksna morfologija Sredozemlja (uski šelfovi i strme kontinentske padine, uski prolazi, brojni otoci te složena topografska obilježja i obalna linija) utječe na prostornu i vremensku varijabilnost termohalinih svojstava Sredozemnog mora (Roether i Schlitzer, 1991; Schlitzer i sur., 1991; Estournel i sur., 2016; Waldman i sur., 2017) te na formiranje intenzivnih procesa u moru, kao što je stvaranje gustih vodenih masa (engl. *Dense Water Formation*, DWF, Ivanov i sur., 2004). U Sredozemnom moru, uzrokovani snažnim lokalnim vjetrovima (mistral, tramontana i bura, Drobinski i sur., 2001; Chronis i sur., 2011; Grisogono i Belušić, 2009) i posljedično izraženim površinskim gubicima topline i mase (Robinson i sur., 2001), odvijaju se dva tipa procesa stvaranja guste vode, obalna i duboka konvekcija. Ovi procesi pokreću termohalinu cirkulaciju Sredozemlja i njegovih pojedinih dijelova. Termohalina cirkulacija i cirkulacija općenito, u Sredozemnom moru se odlikuje jakom prostornom i međugodišnjom varijabilnošću, te izraženim sezonskim signalom. Sukladno tome, fizičke procese koji se odvijaju u Sredozemnom moru karakteriziraju dva vrlo važna svojstva: (1) oni nastaju zbog interakcije između mora i atmosfere koja se realizira u obliku povratno-spregnute veze, i (2) njihova se pojava uočava na malim prostornim skalama zbog toga što Rossbijev radijus deformacije u Sredozemnom moru varira od 5 do 12 km (Grilli i Pinardi, 1998).

Jedna od metoda kojom se pokušava poboljšati pouzdanost globalnih klimatskih modela pri reproduciranju dinamike okrajnjih mora, kao što je Sredozemno more, je ugnježđivanje regionalnih oceanskih modela unutar globalnih (Somot i sur., 2006). Time se popravila prostorna rezolucija kompleksnih područja okrajnjih mora te se omogućila bolja procjena mezoskalnih procesa, od kojih neki značajno doprinose procesima na globalnoj razini,

primjerice stvaranje guste vode u obalnim oceanskim bazenima i njezin utjecaj na termohalinu cirkulaciju (Ivanov i sur., 2004).

Razvoj regionalnih klimatskih oceanskih modela u Sredozemlju je započeo 2000. godine u istraživačkom centru Météo-France/CNRM (fran. *Centre National de Recherches Météorologiques*), s ciljem proučavanja ponašanja združenog sustava atmosfera-more, međugodišnje varijabilnosti cirkulacije mora te utjecaja klimatskih promjena na sustav Sredozemlja (Sevault i sur., 2009). Prvi takav model je bio OPAMED8[4], čije su simulacije izvođene pomoću samostalnog oceanskog modela (Somot, 2005; Somot i sur., 2006) i združenog modela atmosfere i oceana (Sevault i sur., 2002; Somot i sur., 2008). Međutim, simulacije modelom OPAMED8 su bile ograničene u smislu reproduciranja dinamike u moru, zbog korištenja brojnih parametrizacija i ograničenja u računalnoj snazi. Stoga je CNRM odlučio razviti verziju NEMO.MED8 globalnog oceanskog modela NEMO (engl. *Nucleus for European Modelling of the Ocean*, NEMO-v2, Sevault i sur., 2009) za Sredozemno more koji je uključivao realističnije parametre u jednadžbama modela te više mogućnosti pri izvođenju simulacija u smislu definiranja rubnih uvjeta modela, i drugo. Daljnji razvoj se oslanjao na razvoj finijih prostornih i vremenskih rezolucija. Danas postoje simulacije modela NEMOMED12 s horizontalnom rezolucijom od 1/12°, a u planu je i razvoj modela NEMOMED36 s horizontalnom rezolucijom od 1/36°.

Simulacije modelom NEMOMED su omogućile istraživanje mnogobrojnih dinamičkih procesa u Sredozemlju. Između ostalog, proučavao se proces stvaranja guste vode u Lionskom zaljevu te utjecaj vjetra (Herrmann i Somot, 2008; Herrmann i sur., 2008; Somot i sur., 2018; Waldman i sur., 2016). Posebna pažnja se pridavala istraživanju izmjeni atlantskih i sredozemnih vodenih masa na 14 km uskom Gibraltarskom tjesnacu (Soto-Navarro i sur., 2015). Osim toga, Sredozemno more je karakterizirano tranzijentnim procesima koji su također istraživani oceanskim simulacijama NEMOMED, kao što su Istočnosredozemni tranzijent (koji je započeo početkom 1990-tih godina, Klein i sur., 1999; Beuvier i sur., 2010) i Zapadnosredozemni tranzijent (sredina 2000-tih godina, Schroeder i sur., 2008; Herrmann i sur., 2010; Beuvier i sur., 2012).

[4] OPAMED8 je regionalna verzija globalnog oceanskog modela OPA (ORNL-PSerc-Alaska) prilagođena za Sredozemno more. Horizontalna rezolucija modela OPAMED8 je 1/8°.

1.2. Termohalina cirkulacija Jadrana

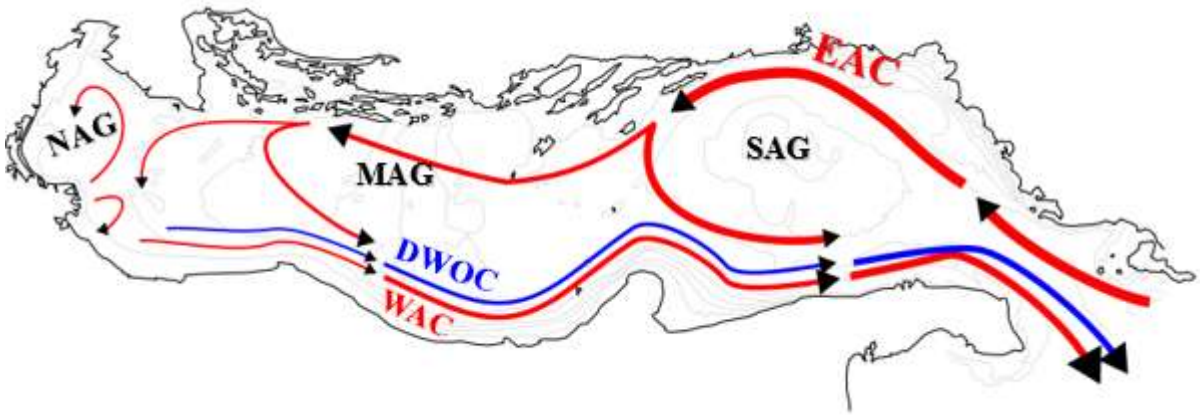
Na najsjevernijem dijelu središnjeg Sredozemlja, smješteno je poluzatvoreno Jadransko more. Jadransko more je izduženog oblika, oko 800 km dugo i oko 200 km široko, položeno u smjeru jugoistok-sjeverozapad. Sjeverni dijelovi Jadrana su plitki, s prosječnom dubinom oko 30 m, dok se najdublji dio Jadrana nalazi u njegovom južnom dijelu. Karakteriziran je s dva kružna područja (kotline): Jabučka kotlina s maksimalnom dubinom približno 280 m, i Južnojadranska kotlina s maksimalnom dubinom približno 1230 m, te dva poprečna praga: Palagruški prag koji odvaja sjeverni i srednji od južnog Jadrana (maksimalna dubina oko 170 m), i Otrantska vrata putem kojih Jadran izmjenjuje vodene mase sa sjevernim Jonskim morem (maksimalna dubina oko 850 m).

Kinematička i dinamička svojstva Jadranskog mora, zbog njegovog zemljopisnog položaja, su u prvom redu određena meteorološkim uvjetima, topografijom okolnog područja, te batimetrijom (Cushman-Roisin i Korotenko, 2007). To posebice vrijedi za sjeverni dio Jadrana gdje važnu ulogu igraju površinska forsiranja čiji se utjecaj osjeća sve do dna mora (Franco i Michelato, 1992). Dotok slatke vode putem rijeka, u kombinaciji s atmosferskim procesima i preraspodjelom energije na Otrantskim vratima zbog izmjene vodenih masa, tijekom zime utječe na stvaranje guste vode u sjevernom i južnom dijelu Jadrana, varijabilnost dinamičkih svojstava i najzad na opću ciklonalnu cirkulaciju Jadrana (Orlić i sur., 1992; Artegiani i sur., 1997b; Poulain i Raicich, 2001; Zavatarelli i sur., 2002; Grbec i sur., 2007).

Budući da su riječni dotoci značajni te unos slatke vode nadmašuje gubitke putem isparavanja, Jadran je karakteriziran kao bazen dilucije (Artegiani i sur., 1997a). Osim na površini mora, ravnoteža soli i topline se održava putem izmjena vodenih masa u Otrantskim vratima. U prosjeku, manje slana, hladnija i gušća vodena masa napušta Jadran, a zauzvrat ulazi toplija i slanija voda. Ovakvi uvjeti određuju opću ciklonalnu cirkulaciju Jadrana, te stvaraju preduvjete za formiranje guste vode zimi u sjevernom i južnom Jadranu (Buljan i Zore-Armanda, 1976; Artegiani i sur., 1981). Prva definicija jadranskih gustih vodenih masa je dana u radu Zore-Armanda (1963): Sjevernojadranska voda (Tip S) koja nastaje u plitkom sjevernom Jadranu i Južnojadranska voda (Tip J) koja nastaje u dubokim područjima južnog Jadrana. U engleskoj literaturi se mogu naći dvije verzije naziva: Sjevernojadranska voda se navodi pod imenom „*North Adriatic Deep Water*“ (NAdDW; Artegiani i sur., 1997a) ili „*North Adriatic Dense Water*“ (NADW; npr. Vilibić i Orlić, 2002), a Južnojadranska voda pod imenom „*Southern Adriatic Deep Water Water*“ (SAdDW; Artegiani i sur., 1997a) ili „*Adriatic Deep Water*“ (ADW; npr. Vilibić i Orlić, 2002). U ovom radu, da bi se olakšala usporedba s

engleskom literaturom, skraćenica NAdDW se odnosi na Sjevernojadransku vodu, a ADW na Južnojadransku vodu.

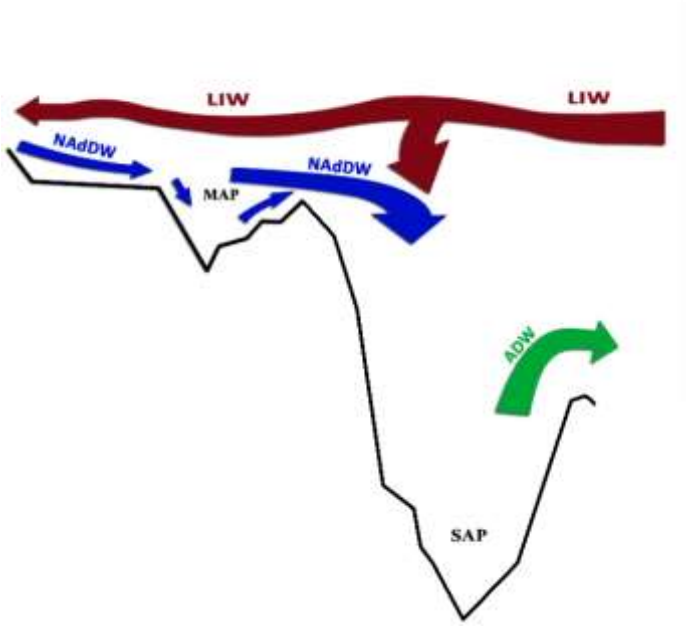
Ciklonalna cirkulacija Jadrana se sastoji od tri glavna vrtloga (slika 1). Južnojadranski (engl. *South Adriatic Gyre*, SAG), srednjejadranski (engl. *Middle Adriatic Gyre*, MAG) i sjevernojadranski vrtlozi (engl. *North Adriatic Gyre*, NAG, Artegiani i sur., 1997b) su isprepleteni s dvije obalne struje: (i) zapadnojadranskom obalnom strujom (engl. *Western Adriatic Current*, WAC), koja je pod velikim utjecajem dotoka slatke vode iz rijeke Po i putuje prema jugu uz talijansku obalu te (ii) istočnojadranskom strujom (engl. *Eastern Adriatic Current*, EAC) koja putuje prema sjeveru istočnom obalom Jadrana (Zore-Armanda, 1956). Vrtlozi u srednjem i južnom Jadranu su uglavnom kontrolirani batimetrijom, dok je sjeverni vrtlog dominantno rezultat termohaline dinamike tog područja (Malanotte-Rizzoli i Bergamasco, 1983). Zimsko stvaranje hladne i izrazito guste Sjevernojadranske vode uzrokuje pojavu horizontalnog gradijenta gustoće, pri čemu se stvara tzv. pridnena struja guste vode (engl. *Dense Water Outflow Current*, DWOC), koja putuje uz rub šelfa do talijanske obale, ispod zapadnojadranske obalne struje (Nof, 1983; Vilibić i sur., 2004; Mihanović i sur., 2013).



Slika 1. Shematski prikaz cirkulacije Jadranskog mora koja se sastoji od tri glavna vrtloga, a to su: južnojadranski vrtlog (SAG), srednjejadranski vrtlog (MAG), i sjevernojadranski vrtlog (NAG), isprepletenom s dvije obalne struje: zapadnojadranskom obalnom strujom (WAC) i istočnojadranskom strujom (EAC) te izlaznom strujom guste vode (DWOC). Slika je preuzeta s http://www.wikiwand.com/sh/Jadransko_more.

1.3. Stvaranje jadranskih gustih vodenih masa

Prethodna istraživanja su pokazala da se tijekom zime u Jadranu odvijaju snažni konvektivni procesi kojima se stvaraju jadranske guste vode (Zore-Armanda, 1963). Dinamika različitih vodenih masa u Jadranu je shematski prikazana na slici 2. Obalna konvekcija na plitkom šelfu sjevernog Jadrana se pojavljuje pri uvjetima velikih gubitaka topline s površine mora, za zimskih epizoda snažnih bura i prodora hladnog zraka nad Jadranom (do 2000 W/m^2, Mihanović i sur., 2013; Janeković i sur., 2014; Davolio i sur., 2015). Bura hlađenjem uzrokuje povećanje gustoće površinskog sloja, što dovodi do vertikalne nestabilnosti stupca mora, pa nastaje vertikalno miješanje. Povišeni salinitet koji ovisi o riječnim dotocima u sjevernom Jadranu (Artegiani i sur., 1997a; Raicich, 1996; Franco i Michelato, 1992; Supić i sur., 2004), stopi evaporacije u području stvaranja guste vode i dotoku slanije, tzv. Levantinske intermedijarne vode (engl. *Levantine Intermediate Water*, LIW, Robinson i sur., 2001), stvara preduvjete za dodatno povećanje gustoće morske vode u sjevernom Jadranu. Kako je sjeverni Jadran plitko područje, konvekcijsko miješanje se redovito proteže sve do morskog dna, stvarajući Sjevernojadransku vodu (Zore-Armanda, 1963; Vilibić i Supić, 2005). Kompleksna mezoskalna ciklonalna/anticiklonalna cirkulacija koja se javlja tijekom epizoda bure (Orlić i sur., 1994; Kuzmić i sur., 2006) dodatno utječe na oblikovanje i tok novostvorene Sjevernojadranske vode, koja nedugo nakon stvaranja počne istjecati prema jugu u obliku pridnene struje guste vode te u slijedećih nekoliko mjeseci tone prema dnu Jabučke i Južnojadranske kotline (Artegiani i Salusti, 1987; Malanotte-Rizzoli, 1977; Bergamasco i sur., 1999; Vilibić, 2003; Bensi i sur., 2013; Janeković i sur., 2014).



Slika 2. Shematski prikaz dinamike različitih tipova vodenih masa uočenih u Jadranskom moru tokom ingresijskih godina. Nakon stvaranja na sjevernom plitkom šelfu Jadrana, Sjevernojadranska voda (NAdDW) putuje prema srednjem i južnom Jadranu. U dubokoj Južnojadranskoj kotlini se stvara Južnojadranska voda (ADW) koja istječe u sjeverno Jonsko more. U srednjim slojevima Jadrana teče Levantinska intermedijarna voda (LIW), koja se tokom intenzivnih ingresijskih godina proteže sve do najsjevernijih dijelova Jadrana. Jabučka kotlina je označena s MAP, a Južnojadranska sa SAP.

Sjevernojadranska voda je karakterizirana iznimno visokom gustoćom (često preko 1029.5 kg/m^3, a u izuzetnim situacijama i preko 1030.0 kg/m^3), najvišom u Sredozemlju (Franco i sur., 1982; Malanotte-Rizzoli i sur., 1997; Vilibić i Supić, 2005; Mihanović i sur., 2013), međutim ne zauzima veliki volumen u usporedbi s Južnojadranskom vodom koja se stvara u dubokoj kotlini južnog Jadrana. Procijenjeno je da Sjevernojadranska voda doprinosi svega 20% ukupnom volumenu jadranskih dubokih voda u godinama snažne konvekcije (Mantziafou i Lascaratos, 2004), dok je u godinama slabijih konvektivnih procesa gotovo nezamijećena u Južnojadranskoj kotlini (Vilibić i Orlić, 2001, 2002).

Drugi konvektivni proces u kojem nastaje gusta voda, tzv. duboka konvekcija, se javlja u središnjem dijelu Južnojadranske kotline, također zimi uslijed snažnih gubitaka površinske topline i u prisustvu Levantinske intermedijarne vode. Površina mora tada gubi uzgon (engl. *buoyancy*) i procesom duboke konvekcije miješa se s Levantinskom intermedijarnom vodom te tone u dublje slojeve mora, čime se stvara Južnojadranska voda (Zore-Armanda, 1963; Buljan i Zore-Armanda, 1976; Gačić i sur., 2002). Maksimalna zabilježena dubina miješanja unutar Južnojadranskog vrtloga iznosi 900 m (Gačić i sur., 2002), dok obično iznosi od 600 do 800 m

(Ovchinnikov i sur., 1985; Manca and Bregant, 1998; Vilibić i Orlić, 2001; Vilibić i Šantić, 2008; Najdek i sur., 2014). Južnojadranska voda je toplija i slanija od Sjevernojadranske vode, stoga je i manje gusta, ali je za red veličine većeg volumena od Sjevernojadranske vode. Nakon stvaranja, Južnojadranska voda teče prema Otrantskim vratima te kao pridnena struja guste vode tone u sjeverno Jonsko more (Manca i sur., 2002; Bensi i sur., 2013). Jadranske vodene mase predstavljaju glavni izvor Istočnosredozemne duboke vode (engl. *Eastern Mediterannean Deep Water*, EMDW), a prepoznatljive su po termohalinim svojstvima, povišenim koncentracijama kisika i drugih spojeva iz atmosfere (Schlitzer i sur., 1991; Roether i Schlitzer, 1991; Robinson i sur., 2001; Malanotte-Rizzoli i sur., 2014; Roether i sur., 2007).

Kao što je spomenuto, tijekom tzv. ingresijskih godina[5] (Buljan, 1953) uočava se prisustvo slanije i toplije Levantinske intermedijarne vode u većem dijelu Jadranskog mora. Ona je najslanija sredozemna vodena masa (Malanotte-Rizzoli i sur., 1997), a nastaje u Levantinskom bazenu unutar ciklonalnog vrtloga južno od otoka Rodosa (Lascaratos i sur., 1993). Nakon stvaranja, za koje je zaslužno konvektivno hlađenje tijekom zime, Levantinska intermedijarna voda putuje prema zapadu na dubinama od stotinjak do više stotina metara. Jedna grana ulazi u sjeverno Jonsko more, a zatim i u Jadran, dok druga nastavlja put prema zapadnom Sredozemlju (Wu i Haines, 1996). Njen „otisak“ u Jadranu se uočava u intermedijarnom sloju, te dopire sve do sjevernih plitkih dijelova šelfa (Mihanović i sur., 2013). Kao i u Lionskom zaljevu (Bosse i sur., 2015), Levantinska intermedijarna voda u Jadranu utječe na stvaranje guste vode, ponajviše u južnom Jadranu, oblikujući termohaline karakteristike i ukupni volumen Južnojadranske vode.

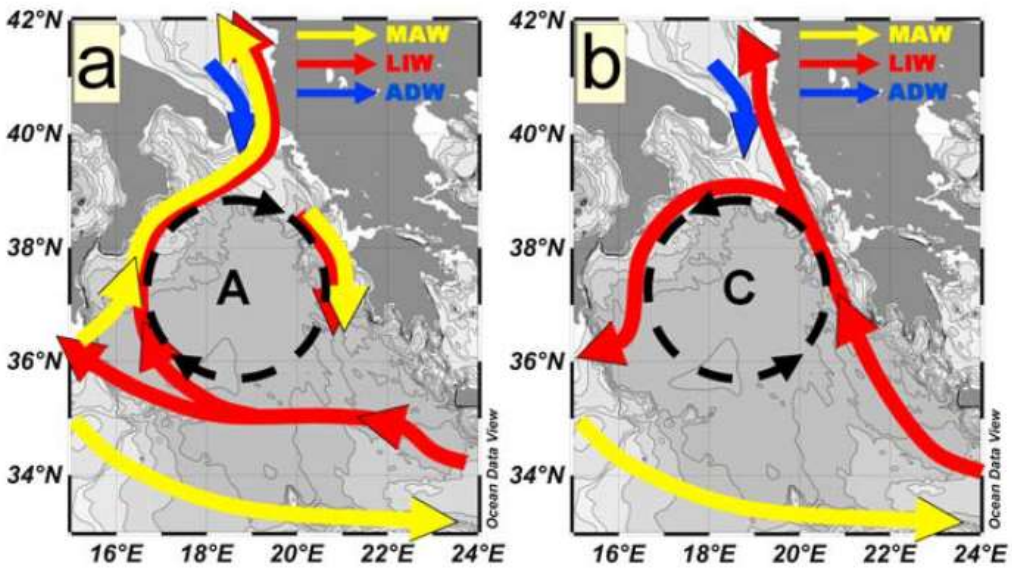
1.4. Jadransko-jonska bimodalna oscilacija (BiOS)

Mnogobrojna istraživanja su zabilježila međugodišnju i dekadsku varijabilnost termohalinih svojstava Jadrana, te povezanost intenziteta stvaranja guste vode s ingresijskim godinama (Buljan, 1953; Vilibić i Orlić, 2001; Mantziafou i Lascaratos, 2004, 2008; Oddo i Guarnieri, 2011, Vilibić i sur., 2012; Mihanović i sur., 2015). Znanstvenici su predložili nekoliko fizikalnih mehanizama koji bi mogli utjecati na pojačani utok Levantinske intermedijarne vode, kakav se uočava tijekom ingresijskih godina: promjene u polju tlaka i vjetra (Grbec i sur., 2003) te vrtloženje vjetra u Jonskom moru (Pinardi i sur., 2015). Međutim,

[5] Ingresijske godine su one godine u kojima je uočen pojačan dotok Levantinske intermedijarne vode. Termin je prvi predložio Buljan (1953).

mehanizam koji trenutno najbolje opisuje višedekadska opažanja jest povratno-spregnuti mehanizam koji se odvija između Jadranskog i sjevernog Jonskog mora. Naime, promjenjivost svojstava Južnojadranske vode utječe na geostrofičku ravnotežu sjevernog Jonskog mora, a time i na cirkulaciju tog područja, karakteriziranu izmjenama ciklonalne i anticiklonalne cirkulacije. Kad je Južnojadranska voda karakterizirana većom gustoćom, pri izlasku iz Jadrana i tonjenjem u sjeverno Jonsko more uzrokuje sažimanje vodenog stupca uz zapadni dio bazena. U tom slučaju, uspostavljena geostrofička ravnoteža između središnjih i rubnih dijelova sjevernog Jonskog mora rezultira anticiklonalnom vrtnjom. Tijekom te faze, Jadran je izložen manje slanoj vodi iz zapadnog Sredozemlja, koja je pod utjecajem atlantskih vodenih masa (*engl. Atlantic Water*, AW). Posljedično, salinitet u Jadranu biva snižen, te se stvara Južnojadranska voda niže gustoće koja, pri izlasku iz Jadrana u sjeverno Jonsko more, širi vodeni stupac uz zapadni dio bazena. Geostrofička ravnoteža se mijenja, i mehanizam ulazi u ciklonalnu fazu koja pogoduje ulasku slanije Levantinske intermedijarne vode iz istočnog Sredozemlja, a time stvara preduvjet za stvaranje Južnojadranske vode više gustoće. Tako opisani povratno-spregnuti mehanizam se naziva jadransko-jonska bimodalna oscilacija (engl. *Adriatic-Ionian Bimodal Ocillating System*, BiOS, Borzelli i sur., 2009; Gačić i sur., 2010). Shematski prikaz mehanizma BiOS-a je prikazan na slici 3.

Eksperimentalna istraživanja promjena uzrokovanih mehanizmom BiOS-a korištenjem mjerenjima razine mora (engl. *Sea Surface Height*, SSH) su pokazala dekadsku varijabilnost cirkulacije u sjevernom Jonskom moru. Prvi prijelaz je zabilježen između 1997. i 1998. godine, kad se cirkulacija sjevernog Jonskog mora promijenila iz anticiklonalne u ciklonalnu. Sljedeći prijelaz je zabilježen 2006. godine (Gačić i sur., 2010), nakon čega se anticiklonalna cirkulacija zadržala sve do 2011. godine (Gačić i sur., 2014; Mihanović i sur., 2015). Od 2011. godine cirkulacija sjevernog Jonskog mora je ciklonalna.



Slika 3. Shematski prikaz mehanizma BiOS-a u sjevernom Jonskom moru, u kojem se izmjenjuju dva glavna tipa cirkulacije. (a) Pri anticiklonalnoj cirkulaciji pojačava se dotok manje slanih voda iz zapadnog Sredozemnog mora (MAW), dok je samo manji obujam slane Levantinske intermedijarne vode (LIW) usmjeren prema Jadranskom moru. (b) Ciklonalna cirkulacija pojačava tok Levantinske intermedijarne vode, dok su vodene mase zapadnog Sredozemlja direktno advektirane prema istočnom Sredozemlju. Slika je preuzeta iz rada Gačić i sur. (2010), u kojem je dan detaljniji opis BiOS-a.

1.5. Kratak opis doktorskog rada

Dinamika i varijabilnost termohalinih svojstava i procesa u Jadranskom moru se dugotrajno i kontinuirano istraživala korištenjem *in situ* i altimetrijskih mjerenja (Buljan i Zore-Armanda, 1976; Gačić i sur., 2002; Bensi i sur., 2013; Mihanović i sur., 2013, 2015), a zadnjih desetljeća pomoću numeričkih simulacija posebno prilagođenih za istraživanje mezoskalnih procesa, kao što je stvaranje guste vode (Bergamasco i sur., 1999; Beg-Paklar i sur., 2001; Dobričić, 2002; Zavatarelli i sur., 2002; Mantziafou i Lascaratos, 2004, 2008; Cushman-Roisin i Korotenko, 2007; Janeković i sur., 2010, 2014; Oddo i Guarnieri, 2011; Gunduz i sur., 2013). Kako je stvaranje guste vode u Jadranu izrazito varijabilno u prostoru i vremenu, za pravilno kvantificiranje procesa numeričke studije ističu važnost: (i) korištenja modela visokih rezolucija (Pinardi i sur., 1996; Beg-Paklar i sur., 2001), (ii) pravilnog uvođenja topografije (Hendershott i Rizzoli, 1976) i riječnih dotoka (Janeković i sur., 2014; Vilibić i sur., 2016), (iii) pravilnog uvođenja vjetra i površinskih protoka topline i vode (Bergamasco i sur., 1999), (iv) utjecaja spregnutosti sustava more-atmosfera (Benetazzo i sur., 2014; Ličer i sur., 2016) te (v) izmjene vodenih masa na Otrantskim vratima (Mantziafou i Lascaratos, 2004, 2008; Oddo i Guarnieri, 2011). Međutim, njihovi zaključci su temeljeni na kratkoročnim simulacijama (do

jedne dekade), koje su posebno prilagođene jadranskim procesima. Uz to, do sad ni jedna numerička analiza na višegodišnjoj vremenskoj skali nije uključivala potpuno spregnuti sustav atmosfera-more.

U ovom radu su kvantificirane dugoročne promjene te međugodišnja i dekadska varijabilnost oceanografskih svojstava jadransko-jonskog bazena, analizirajući sedam klimatskih simulacija regionalnog klimatskog modela NEMOMED s različitim modelskim postavkama. Odabrane simulacije se razlikuju u horizontalnoj i vertikalnoj rezoluciji, atmosferskom i riječnom forsiranju, uključivanju trenda aerosola, te spregnutosti/nespregnutosti sustava atmosfera-more. Analizom simulacija testirana je osjetljivost reprodukcije termohalinih svojstava i odabranih procesa - stvaranje guste vode i mehanizma BiOS-a - na odabir pojedinih modelskih postavki.

Simulacije su evaluirane pomoću dugoročnih nizova *in situ* podataka temperature i saliniteta mjerenih na tri transekta u sjevernom Jadranu, na Palagruškom transektu, te na dvije postaje smještene u Jabučkoj (postaja JK) i Južnojadranskoj kotlini (postaja D1200). Evaluacija mehanizma BiOS-a je načinjena na altimetrijskim mjerenjima razine mora preuzetih iz baze podataka AVISO+ (https://www.aviso.altimetry.fr/en/home.html). Načinjene su procjene prostorne i vremenske varijabilnosti termohalinih svojstava i transporta jadranskih vodenih masa, stvaranja guste vode u sjevernom i južnom Jadranu, te cirkulacije u sjevernom Jonskom moru povezane s mehanizmom BiOS-a.

Konačno, analizirane su tri simulacije buduće klime pomoću potpuno spregnutog modelskog sustava atmosfera-more NEMOMED u jadransko-jonskom bazenu , za tri klimatska scenarija (tzv. "*Representative Concentration Pathway"* scenariji, RCP2.6, RCP4.5 i RCP8.5).

2. MATERIJALI I METODE

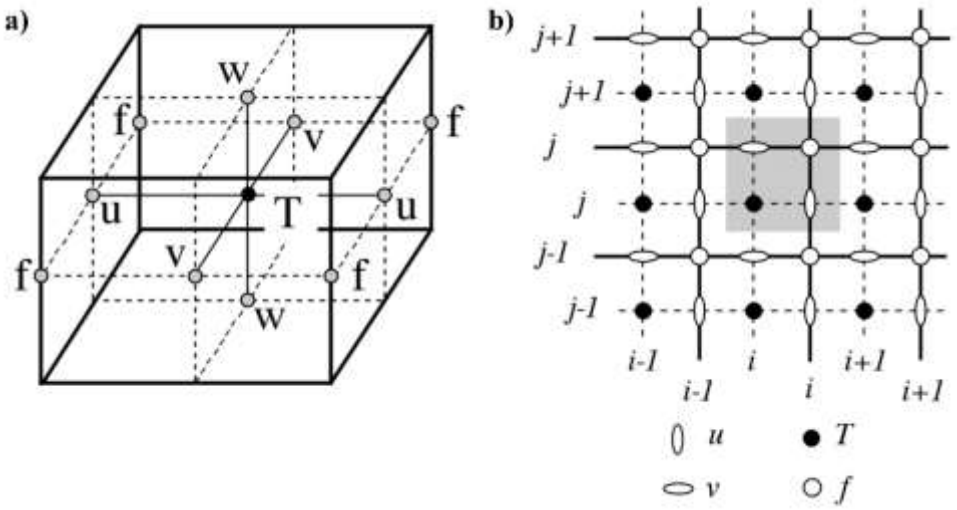
2.1. Regionalni oceanski modeli za reproduciranje sadašnje klime

U današnje vrijeme postoji više regionalnih klimatskih modela dizajniranih za Sredozemlje. Međutim, jedini potpuno spregnuti regionalni modeli trenutno javno dostupni za analize su modeli NEMOMED, što je glavni razlog odabira tih modela u ovom radu.

2.1.1. Osnovne značajke modela NEMO

Numerički modeli NEMO su 3-dimenzionalni oceanski klimatski modeli koji se koriste za reproduciranje oceanske dinamike i procesa, kako na kraćim tako i na klimatskim skalama, te kod oceanskih prognoza (Madec, 2008). U cijelosti su napisani programskim jezikom FORTRAN. Navier-Stokesove jednadžbe gibanja se računaju na rotirajućoj sferi, a jednadžbe očuvanja temperature i soli, kao i jednadžba stanja se rješavaju u krivolinijskom (engl. *curvilinear*) koordinatnom sustavu, pri čemu je odabran neujednačeni z-oblik vertikalnih koordinata. Za pojednostavljenje jednadžbi koristi se Boussinesq-ova i hidrostatska aproksimacija, uz dopušten prodor sunčevog zračenja u more. Površina mora je tretirana kao slobodna, tj. volumen mora nije očuvan, već ovisi o površinskom isparavanju. Modeli NEMO su modeli konačnih razlika diskretizirani na Arakawa-C mreži (Mesinger i Arakawa, 1976), pri čemu se kopno prekriva maskom. Mreža modela je definirana sustavom nezavisnih varijabli (i,j,k) koje opisuju zemljopisne koordinate (λ, φ, z)[6]. Jednu točku mreže (slika 4) definiraju skalarna polja temperature, saliniteta, gustoće i tlaka (*T*-mreža), vektorska polja brzina (*u,v,w*-mreža), te relativna i planetarna vrtložnost (*f*-mreža).

[6] (λ, φ, z) su zemljopisne koordinate kojima se određuje položaj točke na Zemlji, pri čemu λ i φ označavaju geografsku dužinu, odnosno širinu. z koordinata označava vertikalnu komponentu.



Slika 4. a) Položaj zavisnih varijabli unutar mreže modela NEMO. T označava položaj skalarnih polja temperature, saliniteta, gustoće i tlaka, (u,v,w) označavaju vektorska polja brzina, a f označava položaje vrtložnosti. b) Horizontalni položaji skalarnih i vektorskih polja ovisno o definiranim (i,j) točkama mreže. U sivom kvadratiću se nalaze varijable koje imaju iste vrijednosti (i,j). Slika je preuzeta iz Madec (2012).

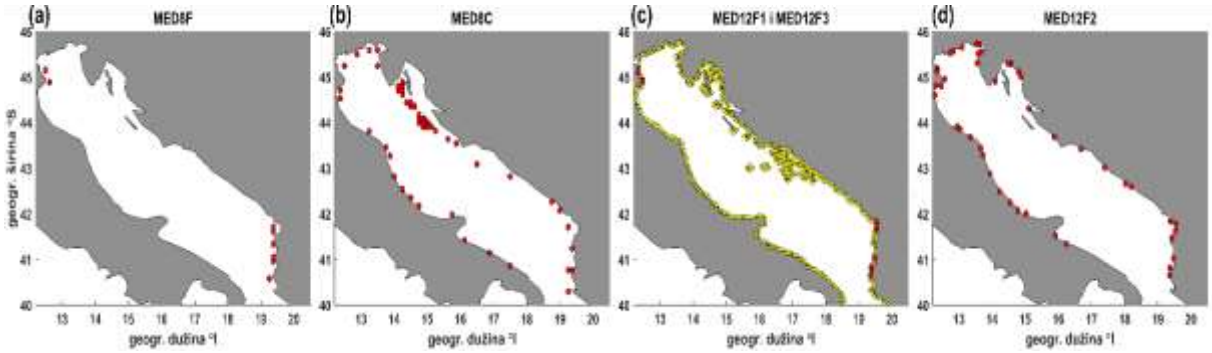
2.1.2. Opis konfiguracija modela NEMOMED i simulacija

Modeli NEMOMED su regionalni oceanski modeli koji se temelje na modelu NEMO (verzija 3.4, Madec, 2012), posebno prilagođeni za Sredozemno more (Sevault i sur., 2009, 2014). Domena modela prekriva čitavo Sredozemno more uz isključenje Crnog mora, pri čemu se posebno tretira njegova granica s Atlantskim oceanom. Zapadno od Gibraltarskih vrata do 11 ^{o}W se vrši trodimenzionalno gušenje varijabilnosti temperature i saliniteta, i dvodimenzionalno gušenje varijabilnosti razine mora, da se postigne realističniji transport Atlantskih voda kroz Gibraltar (Bryden i sur., 1994). Dodatno, s istočne strane Gibraltarskih vrata, mreža je nagnuta i razvučena tako da prati realni tok morske vode u smjeru jugozapad-sjeveroistok (Beuvier i sur., 2010; Sevault i i sur., 2014). Izmjena voda s Crnim morem je parametrizirana točkastim izvorom slatke vode prema Egejskom moru, s protocima temeljenim na klimatologijama Stanev i sur. (2000), te Stanev i Peneva (2002). Batimetrija modela NEMOMED je temeljena na bazi podataka ETOPO, rezolucije 5' × 5' (Smith i Sandwell, 1997), pri čemu je z-vertikalna mreža definirana metodom djelomičnih ćelija na dnu mora. Na takav način, posljednja razina z-mreže (dno) ima varijabilnu debljinu s ciljem da batimetrija modela što je moguće bolje odgovara stvarnoj. Debljina pojedinih slojeva varira ovisno o broju definiranih vertikalnih ćelija. Trenutno postoje simulacije s dvije definirane z-mreže, jedna s

43, a druga sa 75 neravnomjernih slojeva. Debljina vertikalnih slojeva raste prema dnu, počevši od ~ 6 m, odnosno od ~ 1 m na površini mora.

Početni uvjeti su preuzeti iz baze podataka MEDAR/MedAtlas II (MEDAR/MEDATLAS, 2002), dok se rubni uvjeti razlikuju između pojedinih simulacija. Vertikalno miješanje je parametrizirano prema shemi turbulentne kinetičke energije preuzete od Blanke i Delecluse (1993), s pojačanim koeficijentom vertikalne difuzije od 10 m^2/s za konvektivnu prilagodbu, i 10^{-5} m^2/s za unutarnju pozadinsku difuziju (engl. *interior background diffusivity*). Model NEMOMED postoji u dva oblika: nespregnutom i spregnutom. Nespregnutom obliku se definiraju atmosferska (vjetar, protok topline, i bilanca vode definirana evaporacijom i oborinama) i riječna forsiranja. Spregnuti oblik dozvoljava modelu NEMOMED da izmjenjuje površinske protoke s atmosferskim modelom (najčešće ALADIN-Climate) putem sprežnika OASIS (engl. *coupler*, Valcke, 2013).

Modelarska grupa CNRM (Centre National de Recherches Météorologiques) danas ima nemali broj načinjenih simulacija (https://www.medcordex.eu), od kojih je, za potrebe ovog rada, analizirano 7 različitih simulacija NEMOMED u jadransko-jonskom bazenu. Glavne razlike odabranih modela su horizontalna i vertikalna rezolucija, prostorna i vremenska rezolucija atmosferskog forsiranja, uključivanje ili ne trenda aerosola, klimatologija riječnog forsiranja, te uključivanje ili ne spregnutog sustava more-atmosfera. Detaljnije razlike pojedinih postavki simulacija se nalaze u tablici 1. Simulacije su označene nazivima MED8F, MED8C1 - C3 te MED12F1 - F3, gdje oznake 8 i 12 označavaju horizontalnu rezoluciju (1/8° i 1/12°), a F i C nespregnuti (engl. *forced*), odnosno spregnuti (engl. *coupled*) oblik simulacije. Simulacija MED12F3 sadrži ugniježđeni model visoke rezolucije u jadransko-jonskom području (1/36°). Sve odabrane simulacije pokrivaju razdoblje od 1980. do 2012. godine, osim MED8F u kojem razdoblje simulacije ide od 1960. do 2012. godine. Vertikalna z-mreža simulacije MED8 ima 43, a MED12 ima 75 neravnomjerno raspoređenih pravilnih slojeva. Kod nespregnutih simulacija, atmosfersko forsiranje se zadaje u obliku polja količine gibanja (engl. *momentum*) te protoka topline i vlage, uz dodatak relaksacije površinske temperature mora (kod svih nespregnutih simulacija, relaksacijski koeficijent iznosi -40 Wm^2/K). Simulacija MED8F je forsirana s atmosferskim poljima ARPERAv2 (~ 50 km horizontalne rezolucije, dnevni srednjaci polja, Herrmann i sur., 2010), dok su simulacije modela MED12F forsirane atmosferskim forsiranjem ALDERA (~ 12 km horizontalne rezolucije, 3-satni srednjaci polja, Hamon i sur., 2016). Kod svih nespregnutih simulacija, dotoci svježih voda su predstavljeni u



Slika 5. Položaji točkastih izvora riječnog forsiranja u Jadranskom moru za simulacije (a) MED8F, (b) MED8C, (c) MED12F1 i MED12F3, te (d) MED12F2. Detaljniji opis se nalazi u tekstu.

obliku točkastih izvora na površini mora, na mjestima stvarnih ušća rijeka (slika 5). Riječna forsiranja su napravljena kombiniranjem mjerenja iz baze podataka RivDiS (Vörösmarty i sur., 1996) i klimatologije preuzete iz Ludwig i sur. (2009), uz pojedine preinake kod nekih simulacija. Simulacija MED8F sadrži ukupno 33 rijeke koje se ulijevaju u Sredozemno more, od kojih se njih 8 nalazi u Jadranskom moru (dva riječna ušća ispred delte rijeke Po, i šest albanskih rijeka, Vjosa, Seman, Shkumbini, Erzen, Mat i Drin, crvene točkice na slici 5a). Iste rijeke su uzete i za simulacije MED12F1 i MED12F3, uz dodatak tzv. „obalnog dotoka“ kojim je ostatak dotoka svježe vode, procijenjen temeljem klimatologije dane u Ludwig i sur. (2009), usrednjen i raspodijeljen na sve točke mreže koje graniče s kopnom unutar domene modela (žute točkice na slici 5c; Beuvier i sur., 2012). Jedina razlika između simulacija MED12F1 i F2 je u riječnom forsiranju Jadranskog mora. Umjesto „obalnog dotoka“ kao u MED12F1, u MED12F2 je predstavljena nova klimatologija protoka rijeka temeljena na sezonskoj varijabilnosti preuzetoj od Vilibić i sur. (2016). Ukupan broj jadranskih riječnih ušća u MED12F2 je 44 (crvene točkice na slici 5d).

Simulacije MED8C1 - C3 su simulacije potpuno spregnutog klimatskog modela koji uključuje atmosferski model ALADIN-Climate (fran. *Aire Limitée Adaptation dynamique Développement InterNational*, Radu i sur., 2008), oceanski model NEMOMED8 (Beuvier i sur., 2010), riječni model TRIP (engl. *Total Runoff Integrating Pathways*, Oki i Sud, 1998), te shemu kopna i hidroloških parametara ISBA (engl. *Interactions between the Soil Biosphere and Atmosphere*, Noilhan i Mahfouf, 1996). Površinski protoci između atmosferskog, oceanskog i

riječnog modela se izmjenjuju putem sprežnika OASIS3[7] (Valcke, 2013). Detaljan opis rada potpuno spregnutog sustava se nalazi u Sevault i sur. (2014).

Sve simulacije imaju uračunatu klimatologiju aerosola (tablica 1), od kojih se recentna nalazi u MED8C2 i MED8C3. U simulacijama MED8F i MED8C3 je dodatno uključen padajući trend dubine prodiranja aerosola (engl. *Aerosol Optical Depth*) procijenjen za razdoblje od 1980. - 2012. godine, za kojeg se pokazalo da poboljšava reprodukciju klimatskog trenda zračenja nad Europom, standardnu temperaturu zraka kao i površinsku temperaturu mora (Nabat i sur., 2014). Simulacija MED8C1 dodatno sadrži i spektralnu prilagodbu (engl. *spectral nudging*) primijenjenu na atmosfersko forsiranje.

Periodi prilagodbe (engl. *spin up*, vrijeme potrebno da se model dovede u ravnotežno stanje) se razlikuju među pojedinim simulacijama, ovisno o dostupnosti računalnih resursa za vrijeme izvođenja simulacija i potrebama istraživanja (tablica 1).

[7] Sprežnik OASIS je programska podrška koja vrši sinkronizirane izmjene spregnutih informacija između numeričkih kodova koji predstavljaju različite komponente klimatskog sustava.

Tablica 1. Karakteristike modela NEMOMED korištenih u analizama

MODEL	MED8F	MED8C1	MED8C2	MED8C3	MED12F1	MED12F2	MED12F3
RAZDOBLJE	1960. – 2012.	1980. – 2012.	1980. – 2012.	1980. – 2012.	1980. – 2012.	1980. – 2012.	1980. 2012.
HORIZONTALNA (usrednjena za Jadran) I VERTIKALNA REZOLUCIJA	10.2 km 43 z-razina	10.2 km 43 z-razina	10.2 km 43 z-razina	10.2 km 43 z-razina	6.4 km 75 z-razina	6.4 km 75 z-razina	~2 km 75 z-razina
RUBNI UVJETI NA ATLANTIKU	Reynaud i sur. (1998) i Daget i sur. (2008)	NEMOVAR-COMBINE	NEMOVAR-COMBINE	NEMOVAR-COMBINE	ORAS4	ORAS4	ORAS4
POČETNI UVJETI	MedAtlas II 1960	MedAtlas II 1960	MedAtlas II 1960	MedAtlas II 1960	MedAtlas II 1960	MedAtlas II 1960	MedAtlas II 1979
ATMOSFERSKO FORSIRANJE (rezolucija)	ARPERA (~50 km, dnevno)	dvosmjerna spregnutost s ALADIN-Climate (50 km, dnevno)	dvosmjerna spregnutost s ALADIN-Climate (50 km, dnevno)	dvosmjerna spregnutost s ALADIN-Climate (50 km, dnevno)	ALDERA (~ 13 km, 3-satno)	ALDERA (~ 13 km, 3-satno)	ALDERA (~ 13 km, 3-satno)
FORSIRANJE RIJEKAMA (broj riječnih izvora u Jadranu)	kombinacija RivDis baze podataka i Ludwig i sur. (2009) klimatologije (8)	TRIP model (49)	TRIP model (49)	TRIP model (49)	kombinacija RivDis baze podataka i Ludwig i sur. (2009) klimatologije (8 glavnih izvora + dodatni obalni dotok na svim rubnim točkama mreže)	kombinacija RivDis baze podataka i Ludwig i sur. (2009) klimatologije. Nova klimatologija rijeka u Jadranu (44)	kombinacija RivDis baze podataka i Ludwig i sur. (2009) klimatologije (8 glavnih izvora + dodatni obalni dotok na svim rubnim točkama mreže)
KLIMATOLOGIJA AEROSOLA	Tegen i sur. (1997); Boucher i Pham (2002)	Tegen i sur. (1997)	Nabat i sur. (2014)	Nabat i sur. (2014)	Tegen i sur. (1997)	Tegen i sur. (1997)	Tegen i sur. (1997)
TREND AEROSOLA	uključen	nije uključen	nije uključen	uključen	nije uključen	nije uključen	nije uključen
PERIOD PRILAGODBE	15 godina	26 godina	48 godina	48 godina	43 godine	43 godine	6 godina
LITERATURA	Beuvier i sur. (2010)	Sevault i sur. (2014)	Nabat i sur. (2014)	Nabat i sur. (2014)	Beuvier i sur. (2012); Hamon i sur. (2016)	Beuvier i sur. (2012); Hamon i sur. (2016)	Pennel i sur. (2016)

2.2. Spregnuti atmosfersko-oceanski model buduće klime

U ovom radu su se, također, istražila tri moguća scenarija buduće klime Jadrana, ovisno o budućoj stopi zračenja. Analize su napravljene pomoću izlaznih polja potpuno spregnutog modela mora, atmosfere, kopna i rijeka, koji se naziva CNRM-RCSM4 (Sevault i sur., 2014, Nabat i sur., 2015). Analizirani su parametri: površinska temperatura mora, površinski salinitet, razina mora, te maksimalna dubina miješanja jadransko-jonskog sustava.

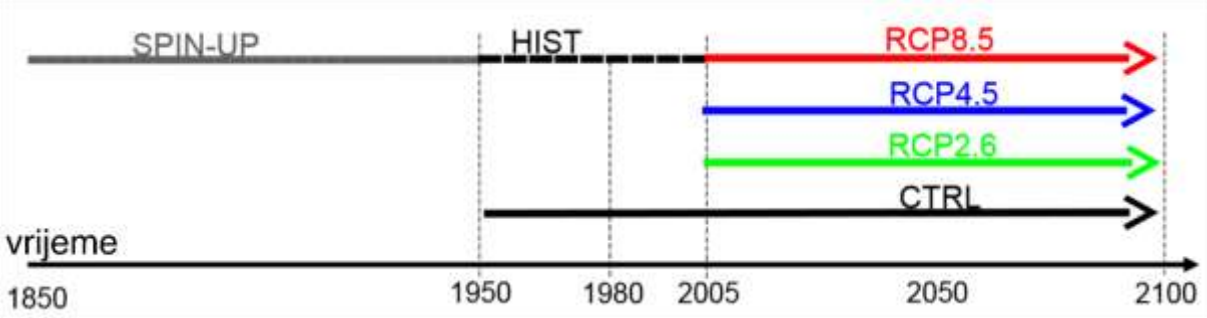
2.2.1. Osnovne značajke modela CNRM-RCSM4

Postavke modela CNRM-RCSM4 su iste kao i kod simulacije MED8C1 (Sevault i sur., 2014; Nabat i sur., 2015), pri čemu je potpuna spregnutost uspostavljena između oceanskog modela NEMOMED8, rezolucije 9 - 12 km i atmosferskog modela ALADIN-Climate, rezolucije 50 km (V5, Colin i sur., 2010). Izmjena energije između mora i atmosfere je slobodna. Atmosferski i oceanski rubni uvjeti su preuzeti s nisko-rezolucijskog globalnog klimatskog modela CNRM-CM5 (Voldoire i sur., 2013). Koncentracije stakleničkih plinova i aerosola su zadane od strane IPCC-a. Početni uvjeti su zadani klimatologijom preuzete iz baze podataka MEDATLAS 1960 (Rixen i sur., 2005).

2.2.2. Opis konfiguracije kontrolne, povijesne i projekcijske simulacije

Tri simulacije modela CNRM-RCSM4 za razdoblje od 2005. do 2100. godine su temeljene na tzv. reprezentativnim putevima koncentracija (engl. *Representative Concentration Pathways*, RCP, IPCC, 2013), koji su definirani vrijednostima ukupnog radijacijskog forsiranja (antropogene emisije stakleničkih plinova i solarnog zračenja izraženih u W/m^2):

1. simulacija RCP2.6 - predstavlja tzv. nisko-emisijski scenarij, s dodatnim porastom energije od 2.6 W/m^2 do 2100. godine,
2. simulacija RCP4.5 - predstavlja tzv. umjereno-emisijski scenarij, s dodatnim porastom energije od 4.5 W/m^2 do 2100. godine, te
3. simulacija RCP8.5 - predstavlja tzv. visoko-emisijski scenarij, s dodatnim porastom energije od 8.5 W/m^2 do 2100. godine.



Slika 6. Shematski prikaz trajanja pojedinih simulacija spregnutog atmosfersko-oceanskog modela buduće klime CNRM-RCSM4.

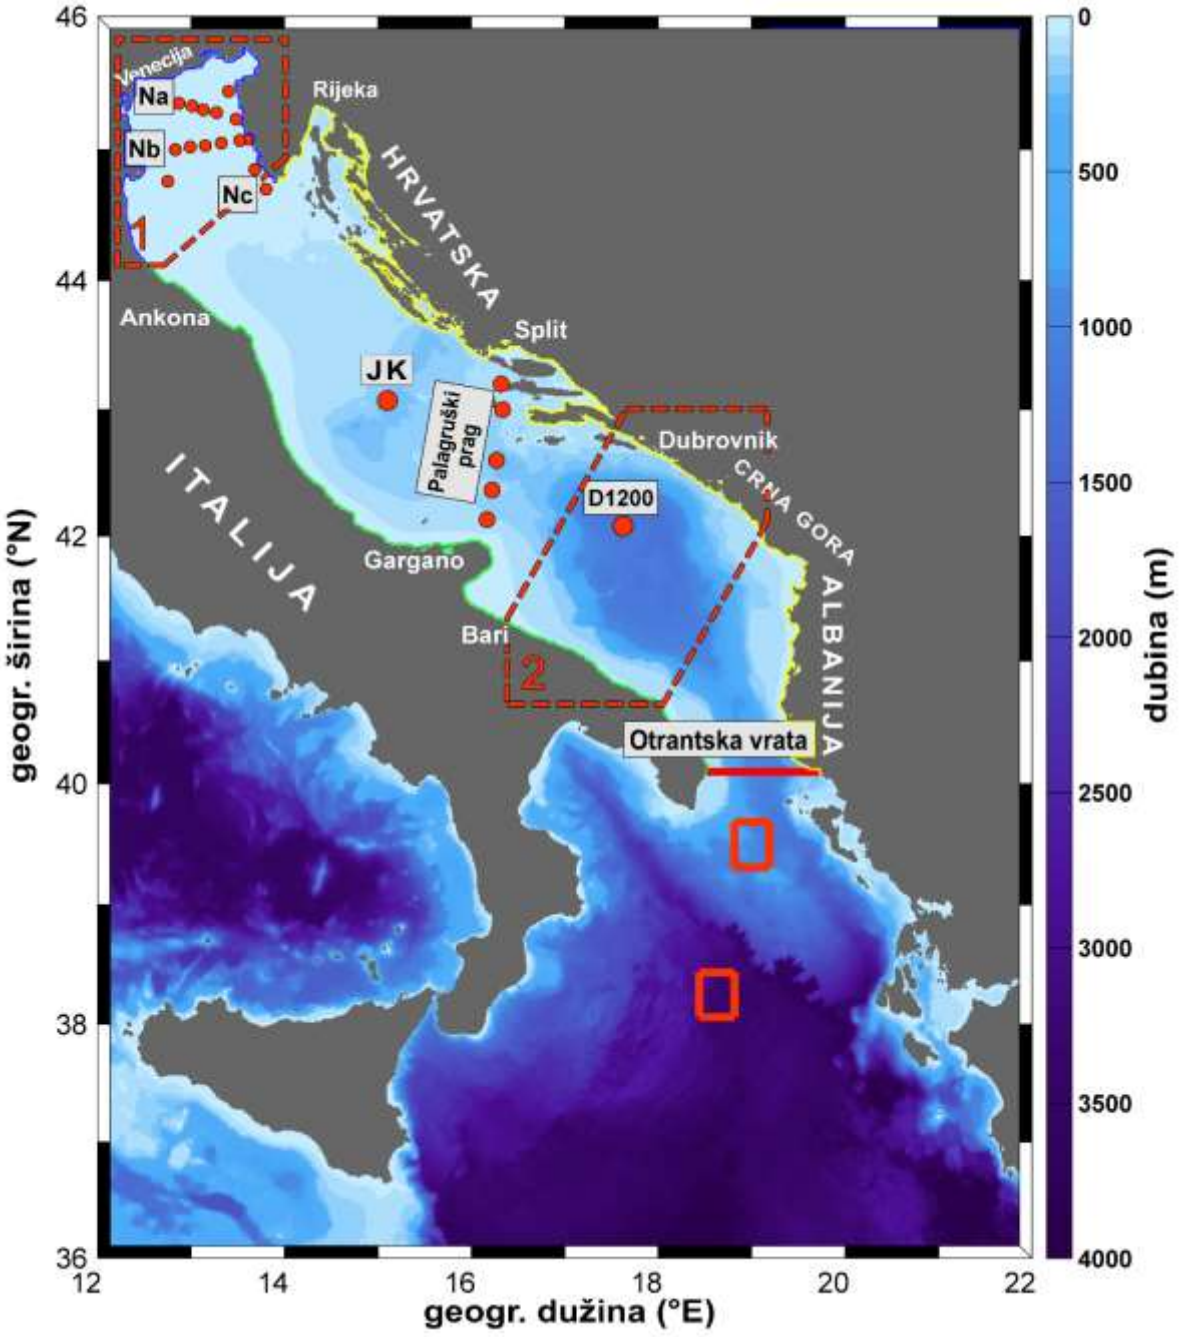
Osim projekcija modela CNRM-RCSM4, napravljene su još tri simulacije, uobičajene kod izvođenja klimatskih projekcija (slika 6), od kojih su se za potrebe ovog rada analizirale samo dvije. Period prilagodbe je trajao 100 godina (od 1850. do 1950. godine) u potpuno spregnutom sustavu, s time da su se rubni uvjeti nasumično zadavali unutar 30-godišnjeg intervala, preuzeti iz razdoblja 1949. - 1979. Povijesna (HIST) simulacija je trajala 55 godina (1950. - 2005.). Za razdoblje od 1950. do 2100. godine, napravljena je i kontrolna simulacija (CTRL) u kojoj je zadano konstantno radijacijsko forsiranje (promjene u koncentracijama stakleničkih plinova, solarno zračenje, i dr.), uzeto iz predindustrijskog doba, a jedine promjene u kontrolnoj simulaciji su prirodnog karaktera. Ta simulacija služi za analizu prirodne varijabilnosti sustava, te za usporedbu sa simulacijama koje imaju uključene antropogene klimatske promjene u radijacijskom forsiranju. Osim toga, kontrolna simulacija služi i za procjenu stabilnosti samog modela. Ukoliko se u kontrolnoj simulaciji pojave neobjašnjiva dugoročna odstupanja u odnosu na povijesnu simulaciju, a koja se ne mogu pripisati prirodnoj međugodišnjoj i dekadskoj varijabilnosti, npr. trend, projekcije modela će također sadržavati ta odstupanja.

Treba napomenuti da su nedavno otkrivene greške u globalnom klimatskom modelu CNRM-CM5 koji je služio za definiranje rubnih uvjeta u atmosferskom modelu CNRM-RCSM4, međutim, te greške nemaju utjecaj na dugoročni signal klimatskih promjena (https://www.umr-cnrm.fr/cmip5/spip.php?article24).

2.3. Područja jadransko-jonskog bazena nad kojima su se vršile analize

Da bi se osigurala konzistentnost analiza, a time i mogućnost usporedbi rezultata, izdvojena su određena područja Jadrana, ovisno o tipu analiza (slika 7):

- za analizu prostornih srednjaka oceanografskih parametara, termohalinu varijabilnost i stvaranje guste vode, izdvojena su područja 1 i 2 koja predstavljaju sjeverni i južni Jadran,
- za analizu promjene cirkulacije u sjevernom Jonskom moru povezane s mehanizmom BiOS-a, definirali su se kvadratići u sjevernom Jonskom moru koji predstavljaju središnji i rubni dio područja cirkulacijske ćelije, kako je sugerirano u radovima Gačić i sur. (2010) i Gačić i sur. (2014),
- za analizu protoka rijeka, izdvojena su tri područja Jadrana koja predstavljaju istočni (ISTOK), sjeverni (SJEVER) i zapadni (ZAPAD) dio,
- za analizu transporta gustih vodenih masa, određena su dva transekta: palagruški i otrantski te
- za evaluaciju simulacija korišteni su dugoročni hidrološki *in situ* podaci mjereni na više jadranskih postaja.



Slika 7. Batimetrija jadransko-jonskog područja. Crvene točkice označavaju položaje postaja nad kojima su obavljana dugoročna hidrološka *in situ* mjerenja (tri sjevernojadranska transekta: Na, Nb i Nc, Palagruški prag s postajama PS1 - PS5 u smjeru S - J, Jabučka kotlina - JK, i duboka južnojadranska postaja - D1200). Crvena uokvirena područja 1 i 2 označavaju područja sjevernog i južnog Jadrana u kojima su analizirani srednjaci oceanografskih parametara, termohalina varijabilnost i stvaranje guste vode. Žuta, plava i zelena linija označavaju istočnu, sjevernu i zapadnu obalu na kojima su napravljene procjene protoka rijeka. Otrantska vrata, koja su služila za procjenu transporta Južnojadranske vode, su označena crvenom linijom. Sjeverni i južni crveni kvadratići u sjevernom Jonskom moru označavaju rubni i središnji dio sjevernojonskog vrtloga, pomoću kojih je napravljena procjena BiOS indeksa.

2.4. Podaci korišteni za analizu simulacija

2.4.1. *In situ* podaci temperature i saliniteta

In situ podaci temperature i saliniteta koji se koriste u ovom istraživanju su prikupljeni putem programa praćenja oceanografskih svojstava Jadranskog mora, koje redovito izvode Institut za oceanografiju i ribarstvo u Splitu, te Centar za istraživanje mora, Rovinj. Slika 7 prikazuje položaje postaja u kojima su se prikupljali podaci: pet postaja koje čine Palagruški prag (PS1 - PS5), smještenih uzduž transekta Split - Mt. Gargano koji odvaja plići sjeverni i srednji Jadran od dubokog južnog Jadrana; postaja Jabučka kotlina (JK), smještena na najdubljem dijelu Jabučke kotline; postaja Južnojadranska kotlina (D1200), smještena u dubokom dijelu južnog Jadrana te 15 postaja u sjevernom Jadranu koje čine 3 transekta (Na, Nb i Nc).

Na sjevernom Jadranu podaci su se uglavnom prikupljali mjesečno, na standardnim oceanografskim dubinama (0, 5, 10, 20 m i dno). U razdoblju od 1980. do 2012. godine, na transektima Na, Nb i Nc je bilo ukupno 144, 507 i 435 krstarenja. Temperatura se određivala obrtnim termometrima, a salinitet Mohr i Knudsenovom metodom (Supić i sur., 2012). Do 1998. godine u srednjem i južnom Jadranu temperatura se određivala obrtnim termometrima, a salinitet RS-10 indukcijskim salinometrima. Nakon toga, u upotrebi su bile CTD sonde[8] IDRONAUT-36 i Seabird-25. Prije upotrebe novih uređaja, vršila se interkalibracija. Mjerenja su se vršila na standardnim oceanografskim dubinama (0 m, 10 m, 20 m, 30 m, 50 m, 75 m, 100 m, 150 m, 200 m, 300 m, 400 m, 500 m, 600 m, 800 m, 1000 m i dno), ovisno o dubini postaje. Ukupno 528, 579, 216, 206 i 199 profila je prikupljeno na postajama Palagruškog praga (PS1 - PS5) u razdoblju od 1960. do 2012. godine. Na postajama PS1 i PS2 podaci su se uglavnom prikupljali mjesečno, a na postajama PS3 - PS5 kvartalno. Do 1990. godine na postaji JK su se uglavnom vršila kvartalna mjerenja, a nakon toga su zabilježena tek poneka krstarenja, što čini ukupno 93 profila temperature i saliniteta. Na postaji D1200 podaci su se prikupljali povremeno tijekom cijele godine, te je sveukupno izmjereno 86 profila.

Svi prikupljeni podaci su se intenzivno koristili u prijašnjim oceanografskim istraživanjima Jadrana, te se upotrebom raznih algoritama nad njima već obavila provjera kvalitete (Supić i sur., 2012; Vilibić, 2003; Vilibić i sur., 2011, 2012, 2013; Mihanović i sur., 2015).

[8] CTD sonda (engl. *Conductivity, Temperature, Depth*) je skup elektroničkih instrumenata koji služe za mjerenje promjena vodljivosti, temperature i dubine u vertikalnom morskom stupcu.

Osim *in situ* podataka prikupljenih u Jadranu, za analizu ponašanja modela koristile su se i dvije postojeće klimatologije: klimatologija srednje dinamičke topografije (engl. *Mean Dynamic Topography*, *MDT*) za Sredozemno more procijenjena temeljem brzine driftera, altimetrijskih i *in situ* podataka te modeliranih vrijednosti za razdoblje od 1993. do 2012. godine (Rio i sur., 2014), te klimatska polja površinske temperature mora izmjerene satelitima AVHRR (Marullo i sur., 2007), za razdoblje od 1985. do 2007. godine. Iz spomenutih klimatologija koristili su se mjesečni srednjaci svih vrijednosti.

2.4.2. Satelitski podaci razine mora

Nagib površine mora u odnosu na geoid u sebi sadrži informaciju o površinskoj cirkulaciji mora. Stoga su se za analizu BiOS-a koristila dvodimenzionalna polja Apsolutne Dinamičke Topografije (engl. *Absolute Dynamical Topography, ADT*) za Sredozemno more, koji su dostupni na web stranici AVISO[9] (http://www.aviso.altimetry.fr, SMDT-MED-2014, Duacs 2014 v15.0). Apsolutna dinamička topografija je definirana sljedećim izrazom:

$$ADT = SLA + MDT,$$

pri čemu je *SLA* odstupanje razine mora (engl. *Sea Level Anomaly*), a *MDT* srednja dinamička topografija. Srednja dinamička topografija je jednaka srednjoj razini površine mora umanjenoj za vrijednost geoid-a (ekvipotencijalna ploha). Procjena srednje dinamičke topografije za Sredozemno more se temelji na najnovijoj procjeni srednjeg polja geoida (GOCE DIR-R4) i *in situ* podataka. Detalji metode obrade podataka se mogu naći u Rio i sur., (2014). Apsolutna dinamička topografija za Sredozemno more se odredila iz specifične regionalne srednje dinamičke topografije za Sredozemlje procijenjene za razdoblje od 20 godina. Polje *ADT*-a je zadano u obliku pravilne mreže rezolucije $1/8^o \times 1/8^o$, te pokriva razdoblje od 1993. do 2012. godine. Za potrebe analiza koristili su se mjesečni srednjaci polja *ADT*-a.

Apsolutna dinamička topografija AVISO+ se opsežna upotrebljavala u prijašnjim oceanografskim istraživanjima BiOS-a (Borzelli i sur., 2009; Bessieres i sur., 2013).

[9] Aviso (engl. *Archiving, Validation and Interpretation of Satellite Oceanographic data*) je služba koju je uspostavio CNES (fran. *Centre National d'Etudes Spatiales*), a čija je svrha da izvrši obradu, arhivu i raspodjelu podataka dobivenih altimetrijskim mjerenjima

2.5. Metode analiza

Modelirane vrijednosti oceanografskih parametara su uspoređivane s *in situ* i altimetrijskim podacima. Budući da su se mjerenja vršila nasumično u vremenu, iz simulacija su izdvojene dnevne vrijednosti temperature i saliniteta za dane kad su vršena mjerenja, u čvorovima mreže koje su odgovarale najbližoj točki mjerenja određene s (λ, φ) koordinatama. Kako je vertikalna rezolucija modela grublja nego li kod mjerenja, simulirane vrijednosti su uspoređivane s mjerenjima na odgovarajućem z-sloju modela koji je obuhvatio dubinu mjerenja.

Anomalija potencijalne gustoće (engl. *Potential Density Anomaly*, *PDA*), s definiranim referentnim tlakom od 0 Pa, je određena za mjerene i simulirane vrijednosti temperature i saliniteta koristeći se TEOS-10 algoritmima (https://www.teos-10.org).

Sezonske oscilacije su veoma izražene u Jadranskom moru (Buljan i Zore-Armanda, 1976). Stoga se, prije svake usporedbe, sezonski ciklus izdvajao iz simuliranih i mjerenih vrijednosti. Godišnje (12 mjeseci) i polugodišnje (6 mjeseci) sinusne funkcije su oduzete od izmjerenih i simuliranih vrijednosti, pri čemu su se amplitude i faze funkcija određivale harmonijskom analizom, koristeći metodu najmanjih kvadrata (Emery i Thomson, 2001). Metoda uklanjanja sezonskog signala je primijenjena pojedinačno za svaki parametar, postaju i točku mreže, te dubinu. Isti postupak je napravljen u Vilibić i sur. (2011).

Verifikacija modela u ovom radu je napravljena statističkim mjerama pristranosti (engl. *bias*) i korijenom srednje kvadratne pogreške (eng, *root-mean-square-error*, *RMSE*) normiranim standardnom devijacijom (engl. *standard deviation*, *STD*). Razdoblja procjenjivanja pogrešaka simulacija su određena ovisno o razdobljima kada su obavljana *in situ* mjerenja.

2.5.1. Određivanje horizontalnog transporta i volumena gustih voda

Procjena simulirane termohaline varijabilnosti Jadrana je napravljena analizama horizontalnog transporta i volumena jadranskih gustih voda procijenjenih iz mjesečnih srednjaka hidroloških polja. Meridionalni transport simuliranih jadranskih gustih voda se određivao na dva transekta (slika 7):

- transport Sjevernojadranske vode kroz Palagruški prag, te
- transport Južnojadranske vode kroz Otrantska vrata.

Transport se određivao sljedećim izrazom:

$$transport = \sum_n v \cdot A,$$

pri čemu je v normalna komponenta morske struje na transekt u smjeru toka gustih jadranskih voda, A površina ćelije mreže modela, a n broj vertikalnih ćelija na transektu za koje je gustoća bila iznad određenog praga. Prag gustoće se zadavao ili ručno temeljem preporučenih vrijednosti iz literature, ili se procjenjivao 95-tim percentilom simuliranih gustoća promatranog područja.

Volumen guste vode u Jadranu se određivao na dva područja (slika 7):

- područje 1 koje predstavlja sjeverni Jadran, te
- područje 2 koje predstavlja južni Jadran.

Slično kao i kod transporta, prilikom sumacije volumena pojedinih ćelija, uzete su obzir samo ćelije u kojima je gustoća bila iznad određenog praga.

2.5.2. Određivanje dubine miješanja i indeksa stratifikacije

Jedan od izlaznih parametara simulacija je i dubina miješanja (engl. *Mixed Layer Depth*, *MLD*) koja se odredila iz dnevnih vrijednosti gustoće temeljem kriterija za turboklinu (engl. *turbocline criterion*, Brodeau i Koenigk, 2015). Dubina turbokline je ona dubina na kojoj je koeficijent difuzije vertikalne vrtložnosti (engl. *vertical eddy diffusivity coefficient*) ispod određene vrijednosti (za modele NEMOMED iznosi 5 cm/s^2). Maksimalna dubina miješanja se određivala iz dnevnih vrijednosti dubine miješanja.

Stratifikacijski indeks (engl. *Stratification Index*, *SI*) se određivao numeričkim putem prema izrazima danima u Turner (1973):

$$SI(H,t) = \int_0^H N^2(z,t) \cdot z \cdot dz$$

$$N^2 = -\frac{g}{\rho_0}\frac{\partial \rho(z,t)}{\partial z},$$

pri čemu je N Brunt-Väisälä frekvencija, ρ_0 referentna gustoća, z dubina, a g akceleracija sile teže ($g = 9.81\ m/s^2$). Stratifikacijski indeks se odredio temeljem mjesečnih srednjaka polja gustoće. Ista metodologija određivanja maksimalne dubine miješanja i stratifikacijskog indeksa se može naći u radu Somot i sur. (2018).

2.5.3. Određivanje BiOS indeksa

Vremenske promjene cirkulacije u sjevernom Jonskom moru, pod utjecajem mehanizma BiOS-a, su se procjenjivale izračunom tzv. BiOS indeksa, prateći metodologiju opisanu u radovima Gačić i sur. (2014) i Mihanović i sur. (2015). BiOS indeks je definiran razlikom prosječne razine mora (engl. *Sea Surface Height*, *SSH*) u sjevernom Jonskom moru, između srednjeg i sjevernog rubnog dijela područja vrtloga (južni odnosno sjeverni kvadratić na slici 7):

$$BiOS\ indeks = SSH_{centar} - SSH_{rub}$$

Tako definiran BiOS indeks dobro opisuje jačinu cirkulacije uzrokovanu mehanizmom BiOS-a, pri čemu negativna vrijednost BiOS indeksa ukazuje na ciklonalni, a pozitivna na anticiklonalni tip cirkulacije (Gačić i sur., 2010, 2014; Mihanović i sur., 2015). BiOS indeks se do sad uspješno povezao s opaženom dekadskom varijabilnošću termohalinih, biogeokemijskih i bioloških svojstava Jadrana (Gačić i sur, 2014; Mihanović i sur., 2015; Peharda i sur., 2016, 2018).

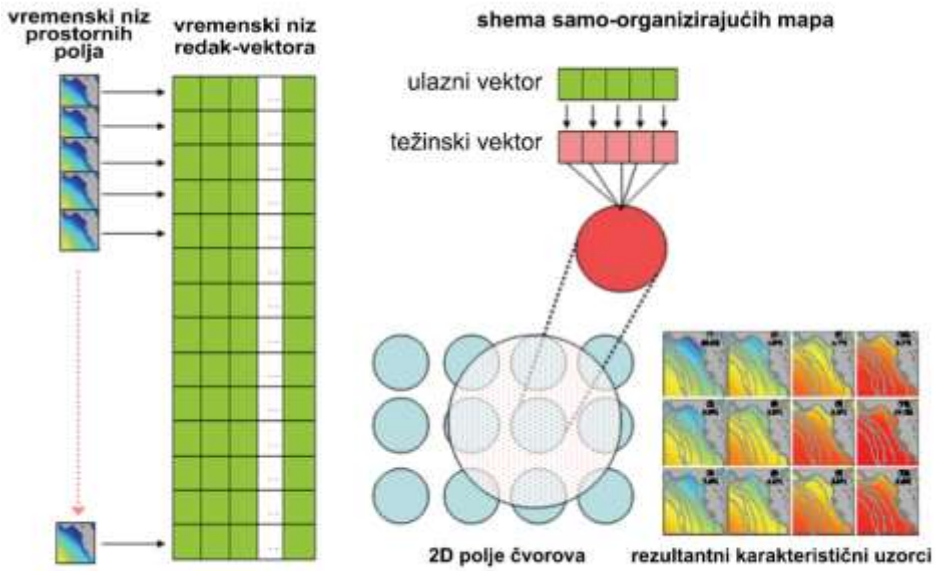
BiOS indeks se računao iz mjesečnih srednjaka polja razine mora. Da bi se što zornije prikazala međugodišnja i dekadska varijabilnost BiOS indeksa, iz vremenskih nizova razine mora, metodom najmanjih kvadrata je uklonjen sezonski signal.

2.5.4. Metoda samo-organizirajućih polja (SOM)

Prostorne promjene cirkulacije u sjevernom Jonskom moru uzrokovane BiOS-om su se analizirale metodom samo-organizirajućih polja (engl. *Self Organizing Maps*, SOM) - tehnika neuronskih mreža koja objedinjuje svojstva klasterizacije i uglađivanja podataka (engl. *data smoothing*), a čije su karakteristike nenadziran (engl. *unsupervised*) algoritam konkurentnog učenja (engl. *competitive learning*). Metodu je prvu razvio finski profesor Tuevo Kohonen, te se ponekad u literaturi može naći pod nazivom Kohonenove mape (Kohonen, 1982, 2001). Metoda SOM se sastoji od unaprijed zadanog broja čvorova (neurona) smještenih u dvodimenzionalnom polju (slika 8), tzv. SOM-polju (engl. *SOM array*). Svaki čvor u SOM-polju je predstavljen jednim vektorom koji ima istu veličinu i uređenost informacija kao i vektor ulaznih podataka. U ovom radu vektor ulaznih podataka se sastoji od prostorne slike jednog trenutka u vremenu danog oceanografskog parametra. Osnovna ideja SOM-a je prilagodba neuronske mreže ulaznim podacima na način da se očuva topologija mreže. Tijekom

iteracijskog postupka svaki skup ulaznih podataka iznova modificira neuronsku mrežu, pri čemu se odabire onaj čvor (jedan vektor u SOM-polju) koji mu najbolje odgovara.

Svaki čvor je definiran svojim težinskim vektorom koji je u našem slučaju nasumično inicijaliziran. Susjedne jedinice čvorova su međusobno povezane funkcijom prostor-vremena, koja definira strukturu polja i određuje područje utjecaja pojedinih čvorova. Struktura polja se može odabrati u obliku lokalnog ili globalnog oblika polja. U procesu učenja metode, zbog iterativnih tehnika, algoritam nasumično bira jedan ulazni vektor kojem se određuje odaljenost od njegovog težinskog vektora pomoću tzv. aktivacijske funkcije. Najčešće je to euklidska udaljenost između ta dva vektora. U svakom idućem koraku, početna funkcija prostor-vremena se minimizira, i na kraju se odabire čvor kojem je težinski vektor najbliži ulaznom vektoru. Taj čvor se naziva najbolja odgovarajuća jedinica (engl. *Best Matching Unit*, BMU) koja predstavlja karakterističnu prostornu sliku jednog trenutka u vremenu. Detalji konstrukcije i princip rada metode samo-organizirajućih polja se mogu naći u Liu i sur. (2006), te u Liu i Weisberg (2011).



Slika 8. Shema rada metode SOM preuzeta iz rada Liu i sur. (2011). Vremenski niz prostornih polja je transformiran u 2D matricu, pri čemu jedan redak vektor odgovara jednom vremenskom koraku. Taj se vektor u svakom vremenskom koraku koristi za ažuriranje težina čvorova u SOM-polju, pri čemu se koristi algoritam nenadziranog učenja. Iterativni proces se naziva samo-organizirajući. Izlazni čvorovi SOM-polja su preoblikovani nazad u rezultantne karakteristične uzorke.

U zadnje vrijeme metoda SOM je vrlo popularna u oceanografiji zbog svoje mogućnosti odvajanja međusobno nelinearnih uzoraka, a do sad se uspješno primijenila na razne skupove podataka, kao što su altimetrijska, radarska i *in situ* mjerenja te na rezultate numeričkih modela (Liu i Weisberg, 2005, 2007, 2011; Leloup i sur., 2007, Vilibić i sur, 2011., Mihanović i sur., 2011, 2015; Kovač i sur., 2014, Liu i sur., 2016). U usporedbi s metodom EOF (engl. *empirical orthogonal function*, EOF), SOM ne zahtijeva kontinuiran vremenski niz, a nije niti osjetljiva na postojanje ekstremnih vrijednosti i izdvojenih podataka (engl. *outliers*). Štoviše, metoda omogućuje otkrivanje klimatskih skokova i režima te opis prijelaznih stanja (Matić i sur., 2018).

U ovom radu, za mapiranje prostornih obilježja se koristio paket MATLAB[10] SOM Toolbox vs. 2.0 (Vesanto i sur., 2000). koji omogućuje uporabu tri vrste algoritma, čime se odabire struktura polja: sekvencijska (engl. *sequential*), serijska (engl. *batch*) i „*sompak*“. Odgovarajući paket se može slobodno preuzeti s web stranice Tehničkog sveučilišta u Helsinkiju, Finska (http://www.cis.hut.fi/projects/somtoolbox/). Obzirom na veličinu skupova podataka i prateći savjete iz prijašnje literature (Liu i sur., 2006), za mapiranje vertikalnih i horizontalnih profila temperatura, saliniteta, te razine mora, odabran je serijski oblik algoritma s pravokutnom neuronskom mrežom oblika „*sheet*“, te funkcijom prostor-vremena „*ep*“ koja djeluje između susjednih vektora. Vremenski nizovi ulaznih polja su dani u obliku dvodimenzionalnih matrica, tako da je svaki red matrice predstavljao jedan vremenski trenutak danog niza. Da bi se osiguralo što objektivnije dodjeljivanje težinskih vektora unutar algoritma, svi ulazni podaci su normalizirani vlastitim srednjacima i standardnom devijacijom. Izlazna polja su definirana u obliku 2 × 3 SOM matrice, što daje 6 različitih čvorova, tzv. karakterističnih uzoraka (BMU1 - 6) oceanografskih parametara temperature, saliniteta i razine mora koji predstavljaju prostorne slike parametra jednog trenutka u vremenu. Vrijednosti temperature, saliniteta i razine mora su se prethodno usrednjili na mjesečnoj skali.

[10] MATLAB je interpretorski programski jezik s interaktivnim sučeljem koji se koristi za numeričke izračune, vizualizaciju i programiranje. Velika prednost programa MATLAB su već postojeći algoritmi, modeli i aplikacije koje se mogu koristiti pri analizama.

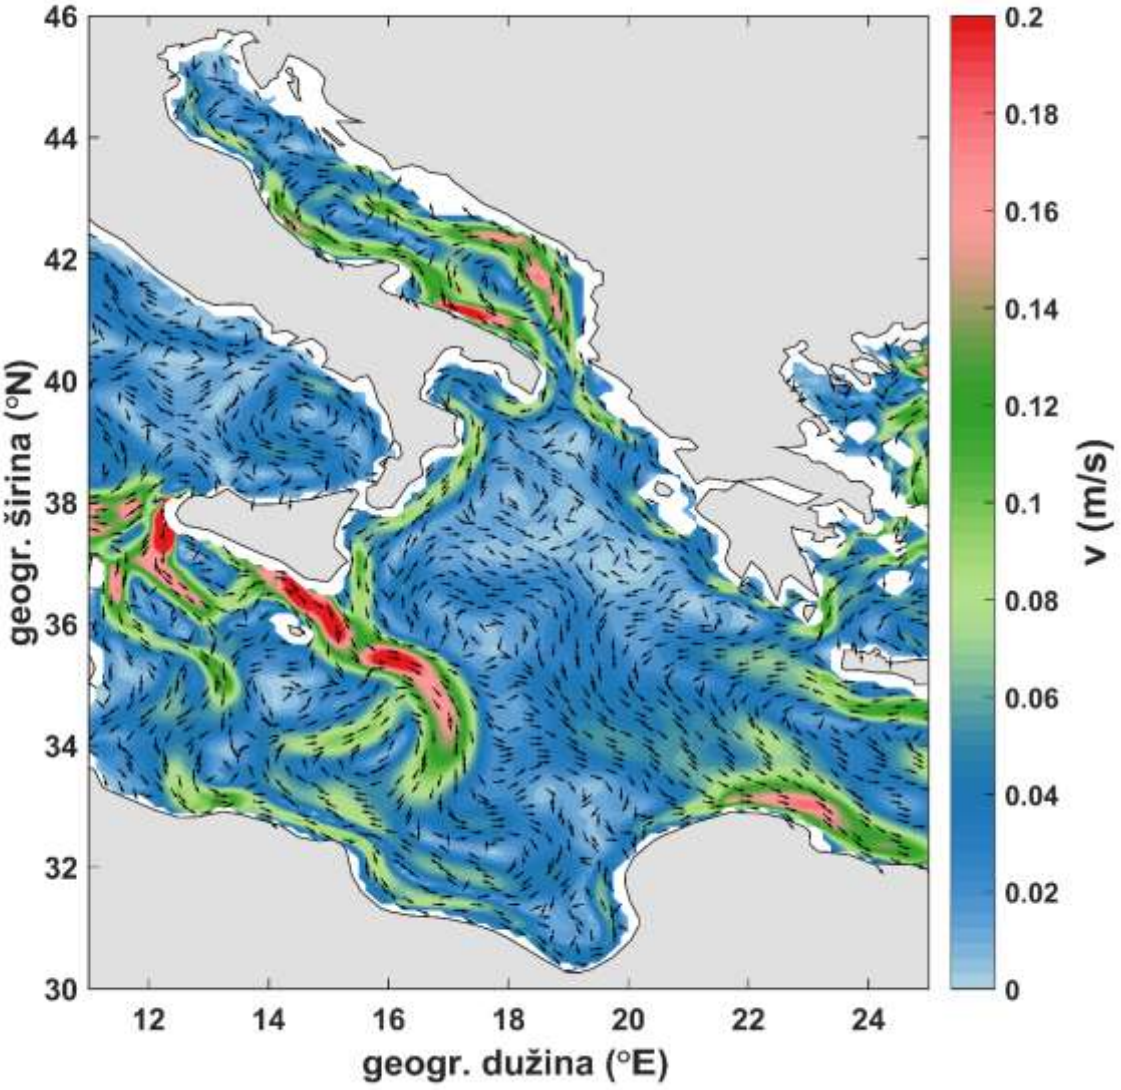
3. ANALIZA SIMULACIJE MED8F U RAZDOBLJU 1961. - 2012.

Nespregnuta simulacija MED8F je jedina od analiziranih simulacija koja pokriva razdoblje od 1960. do 2012. godine. Ovo poglavlje pokriva iscrpnu analizu MED8F-a, fokusirajući se na termohaline procese Jadranskog mora. Pri tome je napravljena:

1. validacija simulacije pomoću dugoročnih *in situ* mjerenja temperature i saliniteta u Jadranu,
2. analiza simulirane varijabilnosti termohalinih svojstava u Jadranu te
3. istraživanje sposobnosti simulacije na reproduciranje dva važna procesa koji su zaslužni za termohalinu cirkulaciju Jadrana, a to su: stvaranje jadranskih gustih voda – pokretač duboke termohaline cirkulacije Jadrana te mehanizam BiOS-a čiji se utjecaj osjeća na čitavom području istočnog Sredozemnog mora (Gačić i sur., 2011, 2013).

3.1. Analiza srednjih polja modela

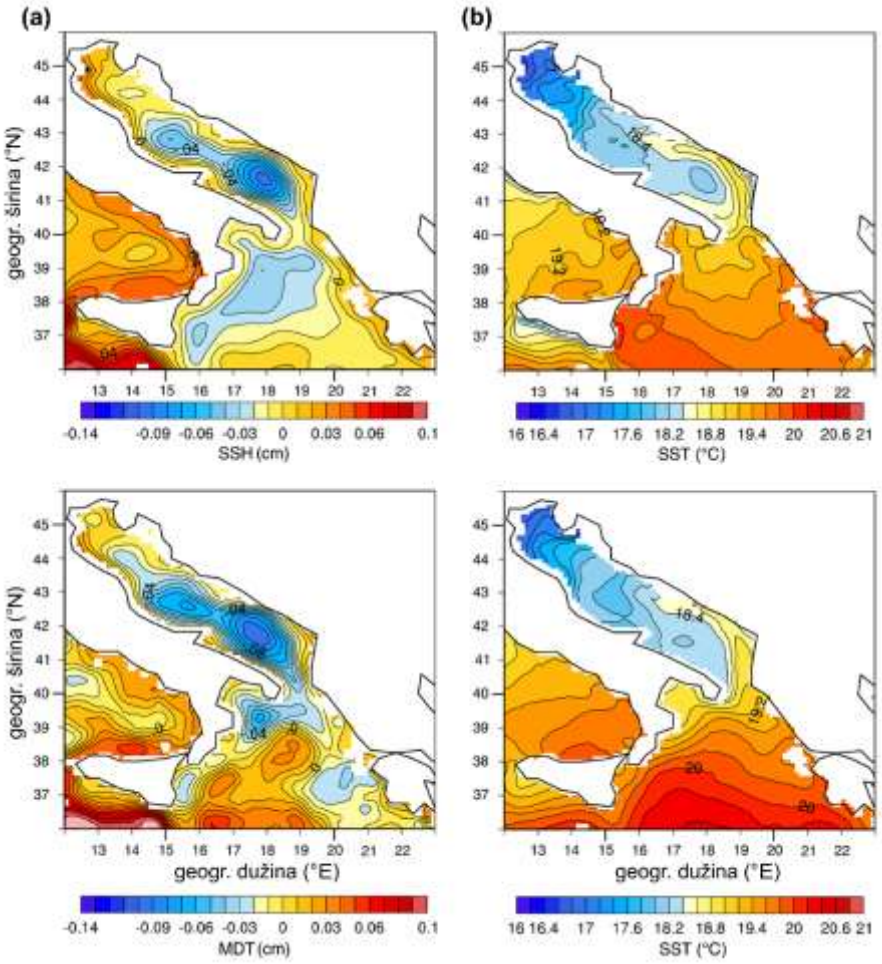
Srednje polje površinskih struja, usrednjeno u razdoblju 1960. - 2012., pokazuje da simulacija MED8F kvalitativno reproducira opću cirkulaciju u središnjem dijelu Sredozemnog mora (slika 9). U Jadranu se ističu istočnojadranska i zapadnojadranska struja, te dva ciklonalna vrtloga u Južnojadranskoj i Jabučkoj kotlini (Orlić i sur., 1992; Artegiani i sur., 1997b). Primjetan je i zapadni izlazni i istočni ulazni tok površinskih voda na Otrantskim vratima. Simulacija također kvalitativno reproducira izražen tok atlantskih vodenih masa iz zapadnog prema istočnom Sredozemlju kroz Sicilijska vrata, dominantno u smjeru istok - jugoistok, prema južnom Jonskom moru. Međutim, simulacija ne reproducira tok atlantskih voda usmjeren prema sjevernom Jonskom i Jadranskom moru, što ukazuje na vremenski dominantnu ciklonalnu cirkulaciju sjevernog Jonskog mora karakteriziranu dotokom Levantinske intermedijarne vode u Jadran (Gačić i sur., 2010).



Slika 9. Vremenski usrednjena površinska cirkulacija središnjeg Sredozemnog mora u razdoblju od 1961. do 2012. godine, simulirana MED8F-om.

Vremenski usrednjena polja razine mora (*SSH*) i površinske temperature mora (*SST*) su se uspoređivala s postojećim klimatologijama temeljenim na stvarnim mjerenjima dinamičke topografije, pri čemu su se polja razine mora usrednjavala u vremenskom razdoblju od 1993. do 2012. godine, a polja površinske temperature mora u razdoblju od 1985. do 2007. godine, ovisno o vremenskim domenama klimatologija. Općenito, MED8F kvalitativno dobro reproducira prostornu razdiobu razine mora i površinske temperature mora u Jadranu (slika 10, gornji red) u usporedbi s postojećim klimatologijama (slika 10, donji red; Rio i sur., 2014; Marullo i sur., 2007). No, s druge strane i u skladu s prijašnjom analizom (slika 9), u

simuliranim poljima u sjevernom Jonskom moru dominira ciklonalna cirkulacija koja se odlikuje nižom razinom mora u središnjem dijelu i višom na rubovima, dok je stvarna slika karakterizirana prevladavajućom anticiklonalnom cirkulacijom s višom razinom mora u središnjem dijelu i nižom na rubovima. To dovodi do drugačije prostorne razdiobe simulirane površinske temperature mora u sjevernom Jonskom moru u odnosu na mjerenu, pa su izoterme suprotne zakrivljenosti od mjerene.



Slika 10. (a) Usporedba simulirane (gore) razine mora usrednjene za razdoblje 1993. - 2012., s razinom mora (dolje) temeljenoj na klimatologiji Rio i sur. (2014), te (b) usporedba simulirane (gore) površinske temperature mora usrednjene za razdoblje 1985. - 2007., s površinskom temperaturom mora (dolje) temeljenoj na klimatologiji Marullo i sur. (2007).

3.2. Validacija pomoću *in situ* mjerenja temperature i saliniteta

Validacija simulacije MED8F u Jadranskom moru se vršila pomoću *in situ* mjerenja temperature i saliniteta prikupljenih na 7 postaja smještenih u Jadranskom moru (5 postaja Palagruškog praga, te postaje JK i D1200, slika 7). Metode validacije su opisane u poglavlju 2.5.

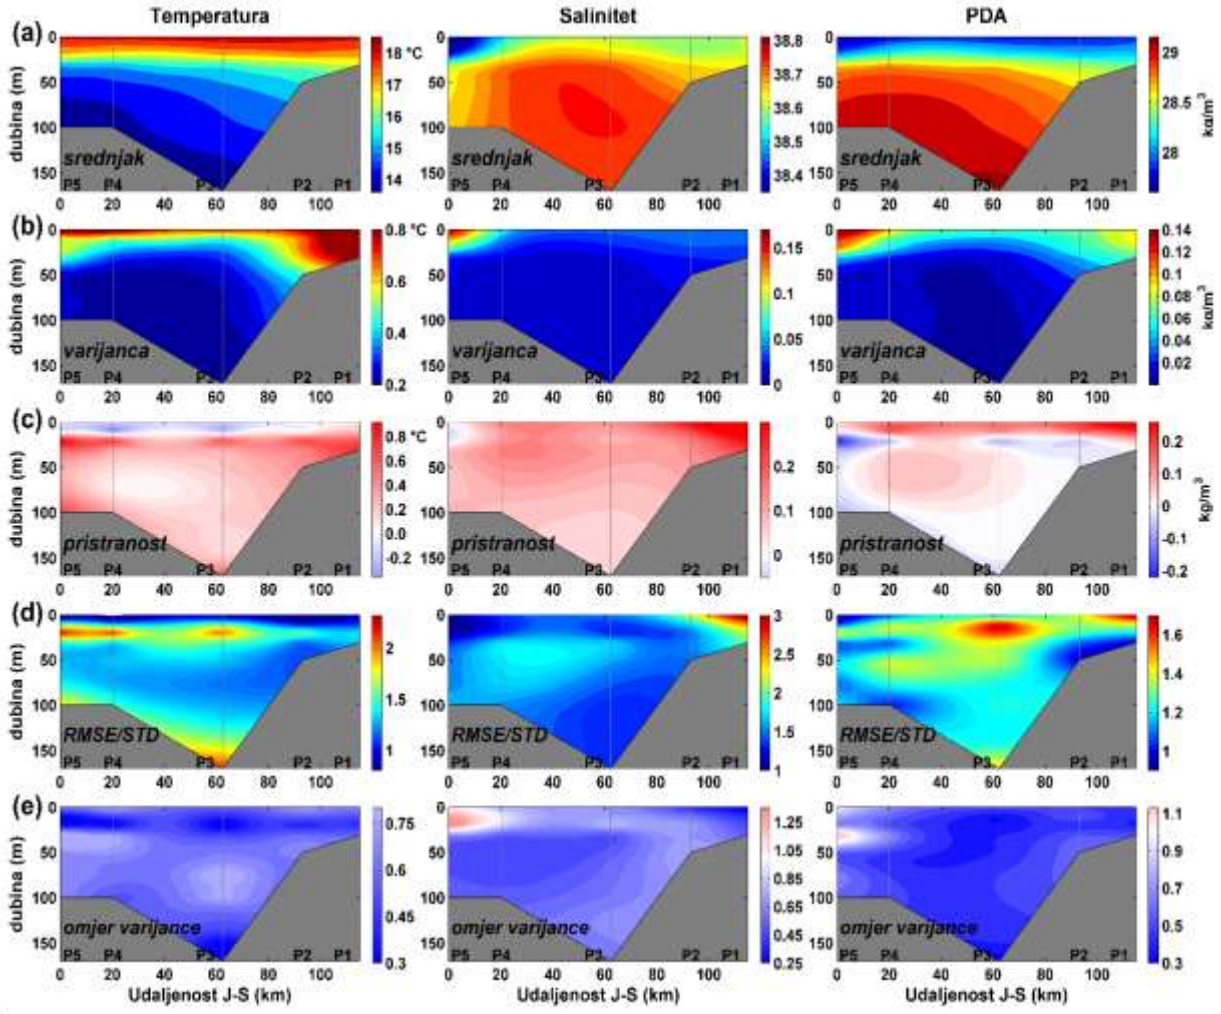
Općenito, srednja polja modeliranih temperatura, saliniteta i anomalije potencijalne gustoće na profilu Palagruškog praga su konzistentna s prijašnjim istraživanjima (slika 11a, Vilibić i sur., 2004, 2013; Mihanović i sur., 2015), odnosno:

1. „otisak“ hladne i guste Sjevernojadranske vode u pridnenim slojevima južnog (bliže talijanskoj obali) i srednjeg dijela transekta je karakteriziran minimumom temperature i maksimumom gustoće (Vilibić i sur., 2004),
2. „otisak“ slane intermedijarne Levantinske vode u srednjem sloju transekta je karakteriziran maksimumom saliniteta (Vilibić i sur., 2013) te
3. opaža se minimum saliniteta u površinskom sloju na južnom kraju transekta zbog prisustva manje slanih površinskih voda koje su pod jakim utjecajem dotoka najveće jadranske rijeke Po (Artegiani et al., 1997a; Lipizer et al., 2014).

Međutim, simulacija ne reproducira minimum saliniteta na sjevernom kraju transekta (bliže hrvatskoj obali) koji se inače javlja zbog utjecaja istočnojadranskih rijeka (Grbec i sur., 2007; Vilibić i sur., 2015).

Očekivano, najveća međugodišnja varijabilnost u simuliranim poljima se javlja u površinskim slojevima (slika 11b); veća varijabilnost temperature na sjevernom kraju transekta zbog atmosferskog utjecaja, dok se na južnom kraju, pod utjecajem rijeke Po, javlja veća varijabilnost saliniteta.

Da bi se testirala kvaliteta simulacije, procijenjene su tri statističke vrijednosti: odstupanje srednjaka modela od srednjaka mjerenja, tj. pristranost (engl. *bias*), omjer korijena srednjeg kvadratnog odstupanja (engl. *root-mean-square-error*) i standardne devijacije mjerenja te omjer varijanci modeliranih i mjerenih polja.



Slika 11. Vertikalni presjeci temperature (lijevi stupac), saliniteta (srednji stupac) i anomalije potencijalne gustoće (desni stupac) na Palagruškom pragu: (a) srednja polja simuliranih vrijednosti, (b) varijanca simuliranih polja, (c) pristranost simulacije MED8F, (d) omjer korijena srednjeg kvadratnog odstupanja i standardne devijacije mjerenja (*RMSE/STD*), i (e) omjer varijanci simuliranih i mjerenih vrijednosti.

Precjenjivanja temperature u MED8F-u su najveća u podpovršinskom (sloj između 10 i 40 m dubine, gdje se inače uočava termoklina, Buljan i Zore-Armanda, 1976) i u pridnenom sloju (slika 11c), oko 0.6 ^{o}C blizu sjevernog kraja do 1.0 ^{o}C na južnom kraju transekta. Na samoj površini južnog i središnjeg dijela transekta simulirane temperature su blago podcijenjene. Ovakva vertikalna razdioba pristranosti ukazuje na prejako vertikalno miješanje u simulaciji MED8F. Salinitet je generalno precijenjen na cijelom transektu, ponajviše na sjevernom dijelu (pristranost ide do 0.3) zbog odsutnosti riječnih dotoka na istočnoj obali Jadrana. Naime, tri velike istočnojadranske rijeke, Neretva, Bojana i Drin, zbog nedostupnosti i/ili nedostataka mjerenih podataka u vrijeme izvođenja simulacije, nisu uključene u simulaciju

MED8F. Procijenjeni prosječni protok slatke vode navedenih rijeka je 669 m^3/s, što čini oko 40% protoka rijeke Po (Janeković i sur., 2014; Vilibić i sur., 2016). Nedostatak istočnojadranskih rijeka bitno utječe na cirkulaciju mora uz istočnu obalu Jadrana, a njihov trag na postajama P1 i P2 Palagruškog praga se zamjećuje u vidu smanjenog saliniteta (Grbec i sur., 2007). Najniže odstupanje saliniteta s vrijednostima nešto višim od nule je zabilježeno na najdubljim dijelovima transekta (postaja P3) i u podpovršinskom sloju gdje teče Zapadnojadranska obalna struja.

Da bismo što preciznije procijenili odstupanja simulacije od mjerenja, korijen kvadratnog odstupanja je normiran standardnom devijacijom mjerenja (*RMSE/STD*), pri čemu niža vrijednost omjera *RMSE/STD* označava bolje ponašanje simulacije (Legates i McCabe, 1999; slika 11d). Kod temperature, razdioba *RMSE/STD* nalikuje razdiobi pristranosti, gdje su veće pogreške simulacije pronađene u podpovršinskom i pridnenom sloju (iznad 2.2 u južnom i središnjem dijelu transekta). U intermedijarnom sloju, vrijednosti *RMSE/STD* se kreću od 0.5 do 1.3, dok su najmanje vrijednosti zabilježene uz samu površinu, što ukazuje na bolje ponašanje simulacije podalje od sloja termokline i dna. Pogreške simulacije su veće kod saliniteta; *RMSE/STD* iznosi do 3.0 na površini sjevernog dijela, te do 0.8 u intermedijarnom sloju bliže južnom dijelu transekta. Najmanje vrijednosti su zabilježene na površini južnog dijela (nešto iznad 1.0), u podpovršinskom sloju, te u najdubljim slojevima transekta (~ 1.4).

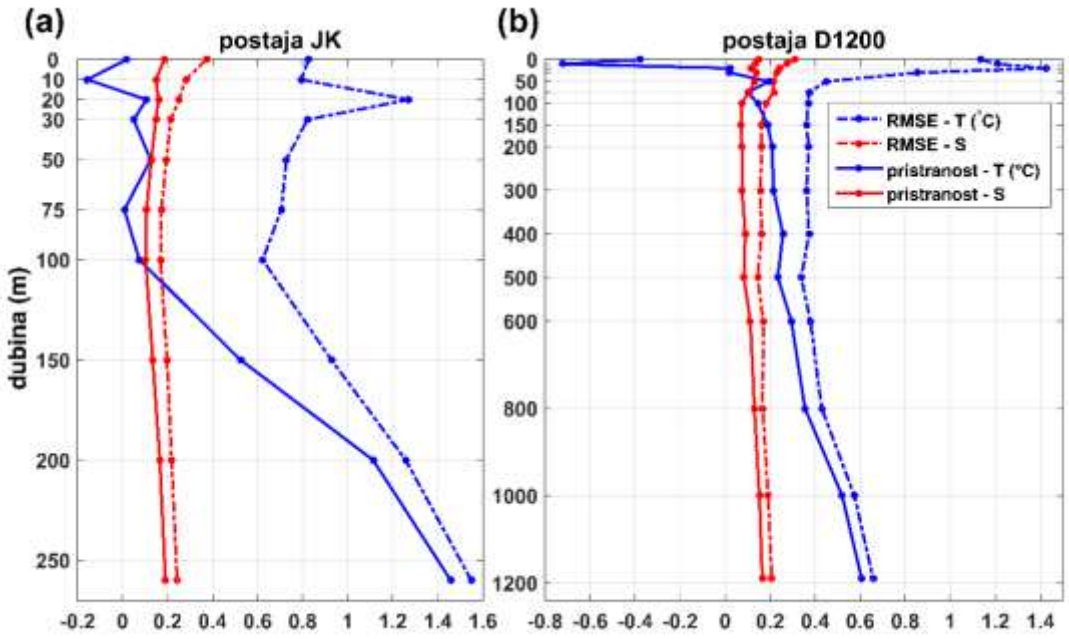
Posljedično, simulacija MED8F rezultira precijenjenom anomalijom potencijalne gustoće u površinskom sloju zbog podcijenjene temperature, posebice na sjevernoj strani transekta (do ~ 0.3 kg/m^3) te u podpovršinskom sloju središnjeg dijela transekta, gdje nalazimo najveći omjer *RMSE/STD* (iznad 1.6). Nešto niže, ali uočljiva odstupanja, su zabilježena i u najdubljim slojevima Palagruškog transekta. Najmanje pristranosti i omjeri *RMSE/STD* su zabilježeni u priobalnim područjima, zbog nižih odstupanja simuliranih temperatura i saliniteta od izmjerenih.

Glavna karakteristika simuliranih parametara temperature, saliniteta i anomalije potencijalne gustoće je izraženo podcjenjivanje njihove varijabilnosti (izuzev sezonskih ciklusa), osim u području Zapadnojadranske obalne struje, gdje simulacija precjenjuje varijabilnost saliniteta (slika 11e). Najniži omjeri varijanci temperature su zabilježeni u području termokline (10 - 40 m), te u najdubljim dijelovima transekta, tj. području otjecanja Sjevernojadranske vode, gdje je simulirana varijanca temperature podcijenjena za više od 70% u odnosu na izmjerenu (postaja P3). Simulirana varijanca saliniteta je najviše podcijenjena u

području utjecaja istočnojadranskih rijeka (iznad 70%), dok se na suprotnoj strani transekta, zbog utjecaja rijeke Po, omjer kreće od od 0.9 do 1.3. Na drugim dijelovima transekta simulacija reproducira od 25% do 70% izmjerene varijance. Slična razdioba i iznosi omjera varijanci su zabilježeni i kod anomalije potencijalne gustoće.

Druge dvije postaje, JK i D1200, smještene u dubokim depresijama Jadrana (Jabučka i Južnojadranska kotlina), su također korištene za validaciju simulacije MED8F. Slika 12 prikazuje vertikalne presjeke pristranosti te korijena srednjeg kvadratnog odstupanja simulacije od mjerenja (*RMSE*), za temperaturu i salinitet. Pogreške za postaju JK su procijenjene za razdoblje 1961. - 1989., a za postaju D1200 za razdoblje 1966. - 2009.. Kao što je slučaj na Palagruškom pragu (slika 11), kod obje postaje (JK i D1200) izrazita podcjenjivanja temperature su zabilježena u površinskom sloju (0 - 10 m dubine, do 0.2 ^{o}C na postaji JK i do 0.7 ^{o}C na postaji D1200), a najveće pogreške su nađene u podpovršinskom sloju (na oko 20 m dubine), i to veće od 1.2 ^{o}C na postaji JK, te veće od 1.4 ^{o}C na postaji D1200. U dubljim slojevima pristranost temperature raste, te mijenja predznak nakon 100 m dubine na obje postaje. Na samom dnu postaja JK i D1200, simulirane temperature su u prosjeku za 1.4 ^{o}C i 0.6 ^{o}C više od mjerenih. Kako su dvije jadranske depresije, u kojima su smještene postaje JK i D1200, poznate po akumulacijama jadranskih gustih voda (Vilibić i sur., 2004; Vilibić i Šantić, 2008), velika odstupanja temperatura ukazuju na ili niži volumen simuliranih jadranskih gustih voda, ili na to da simuliranu gustu vodu generiranu u sjevernom Jadranu karakteriziraju više vrijednosti temperature nego li je to u stvarnosti.

Na obje postaje salinitet je precijenjen, a pristranost je manje varijabilna s dubinom, s prosječnim vrijednostima od 0.1 na postaji JK i 0.2 na postaji D1200. Najviše vrijednosti pristranosti su oko 0.2, a javljaju se na površini i dnu.

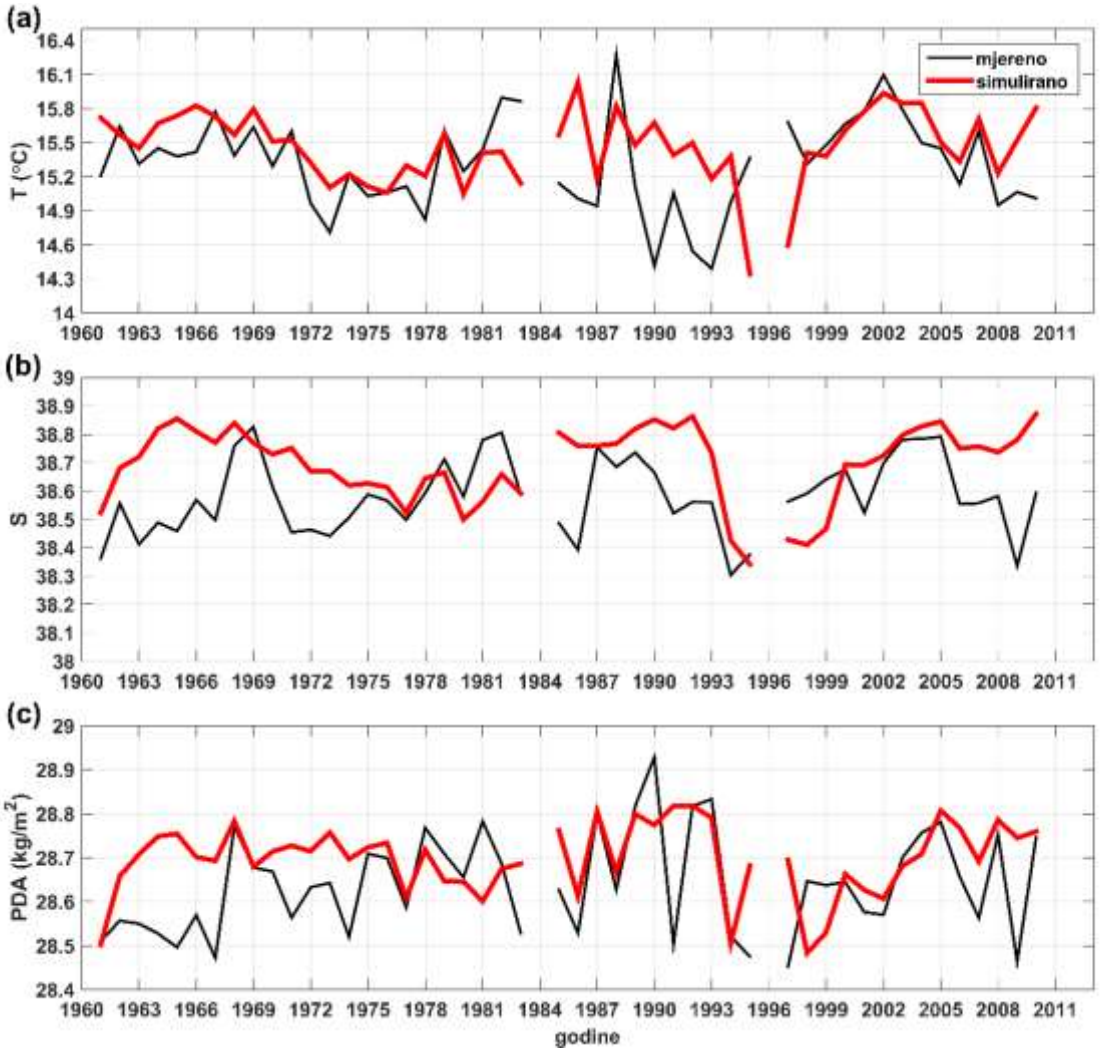


Slika 12. Vertikalni presjeci pristranosti i korijena srednjeg kvadratnog odstupanja (*RMSE*) za temperaturu i salinitet na postajama (a) JK za razdoblje 1961. - 1989., te (b) D1200 za razdoblje 1966. - 2009.

3.3. Međugodišnja i dekadska varijabilnost

Da bi se procijenila sposobnost reproduciranja međugodišnje i dekadske varijabilnosti simulacije MED8F, načinjena je usporedba vremenskih nizova vertikalno usrednjenih simuliranih te mjerenih vrijednosti temperature, saliniteta i anomalije potencijalne gustoće na najdubljoj postaji Palagruškog praga, P3. Mjesečne vrijednosti su usrednjene na godišnjoj skali čime je izdvojena međugodišnja i dekadska varijabilnost unutar vremenskog niza (slika 13). Simulacija MED8F kvalitativno reproducira međugodišnje promjene temperature, posebice u razdoblju prije 1980. godine, u kojem simulirana varijabilnost temperature gotovo odgovara mjerenoj (slika 13a). Nakon 1980. godine zamjetna su veća odstupanja vertikalno usrednjenih temperatura. Prvi izraženi maksimum temperature u simulaciji se pojavljuje 1986. godine, kasneći oko 3 - 4 godine za mjerenim (1982. - 1983.). Isto vrijedi i za prvi izraženi minimum temperature: simulirani minimum se pojavljuje u 1995. godini, dok ga mjerenja bilježe u 1990. godini. Međugodišnja varijabilnost saliniteta u MED8F je gotovo nezamjetna, dok je dekadska nešto bolje reproducirana, iako razdoblja karakterizirani povišenim i sniženim salinitetom ne odgovaraju mjerenjima (slika 13b). Tako je opaženo razdoblje povišenog saliniteta od 1967. do 1970. godine simuliran između 1960. i 1975. godine. Isto tako, opažena razdoblja nižeg saliniteta traju svega nekoliko godina, dok su simulirana duža, što je rezultat podcjenjivanja

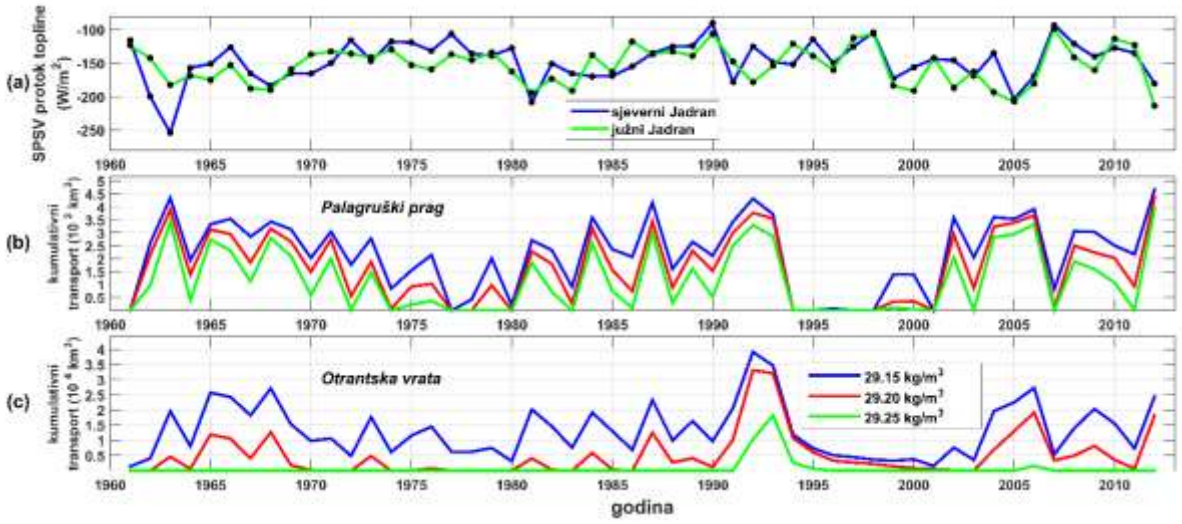
međugodišnje varijabilnosti. Posljedično, MED8F reproducira samo dva duga razdoblja sniženog saliniteta, između 1975. i 1984. godine, te između 1993. i 1999. godine. Razdoblje sniženog saliniteta, koji se vjerojatno javilo kao posljedica Istočnosredozemnog tranzijenta (Klein i sur., 1999), je povezano s naglim snižavanjem temperature u cijelom vodenom stupcu (slika 13a). Međutim, u stvarnosti, utjecaj Istočnosredozemnog tranzijenta na Palagruškom pragu je zabilježen između 1991. i 1998. godine (Vilibić i sur., 2012), dok u simuliranim nizovima razdoblje sniženog saliniteta i temperature počinje 1994. godine, tj. kasni za opaženim 2 - 3 godine.



Slika 13. Vremenski nizovi simuliranih i mjerenih vertikalno usrednjenih godišnjih vrijednosti (a) temperature, (b) saliniteta i (c) anomalije potencijalne gustoće na postaji P3. Prekidi u vremenskim nizovima se javljaju zbog nedostatka mjerenja u tim razdobljima.

3.4. Stvaranje guste vode

Stvaranje guste vode u Jadranu je pod jakim utjecajem površinskog hlađenja mora, tj. gubitaka topline. Stoga, da bi se kvantificirali atmosferski uvjeti koji pogoduju tom procesu, potrebno je procijeniti ukupan protok topline na površini mora. Srednje vrijednosti ukupnog protoka topline zimskog kvartala (studeni-prosinac-siječanj-veljača, SPSV) su procijenjene za dva područja stvaranja gustih vodenih masa, sjeverni Jadran (područje 1 na slici 7), te južni Jadran (područje 2 na slici 7). Razdoblje SPSV za određenu godinu obuhvaća studeni i prosinac prethodne godine te siječanj i veljaču tekuće godine. Tako su obuhvaćena dva razdoblja: tzv. razdoblje stvaranje preduvjeta te razdoblje odvijanja samog procesa. Kako je sjeverni Jadran pod većim utjecajem hladnih prodora bure nego južni Jadran (Cavaleri i sur., 1997; Heimann, 2001), prosječni gubici topline su očekivano viši u sjevernom Jadranu. U simulaciji MED8F prosječni površinski protoci topline u sjevernom Jadranu u razdoblju SPSV variraju od -254 W/m^2 u 1963. godini do -90 W/m^2 u 1990. godini, dok u južnom Jadranu variraju od -214 W/m^2 u 2012. godini do -99 W/m^2 u 2007. godini (slika 14a). Interval vrijednosti je sukladan klimatologiji površinskih protoka topline (Artegiani i sur., 1997a). Protoci topline u dva područja su međusobno korelirani (s koeficijentom korelacije 0.63, na razini statističke značajnosti od 99%). Iako se većinu vremena protoci topline mijenjaju istovremeno, to nije uvijek slučaj. Npr. 1992. godine simulirani gubici topline su bili povišeni u južnom Jadranu, dok je sjeverni Jadran imao blažu zimu. Upravo je ta godina bila prva godina Istočnosredozemnog tranzijenta (Klein i sur., 1999; Roether i sur., 2007), tj. „premještanja“ područja stvaranja gustih voda u Egejsko more. Visoki gubici topline površine mora se javljaju u zimama 1963., 1967., 1968., 1981., 1983.,1991. (samo u sjevernom Jadranu), 1992. (samo u južnom Jadranu), 1999., 2000., 2002., 2003., 2004. (samo u južnom Jadranu), 2005., 2006., i 2012. godine. Blaže zime se javljaju 1972., 1977., 1990., 1998., i 2007. godine.

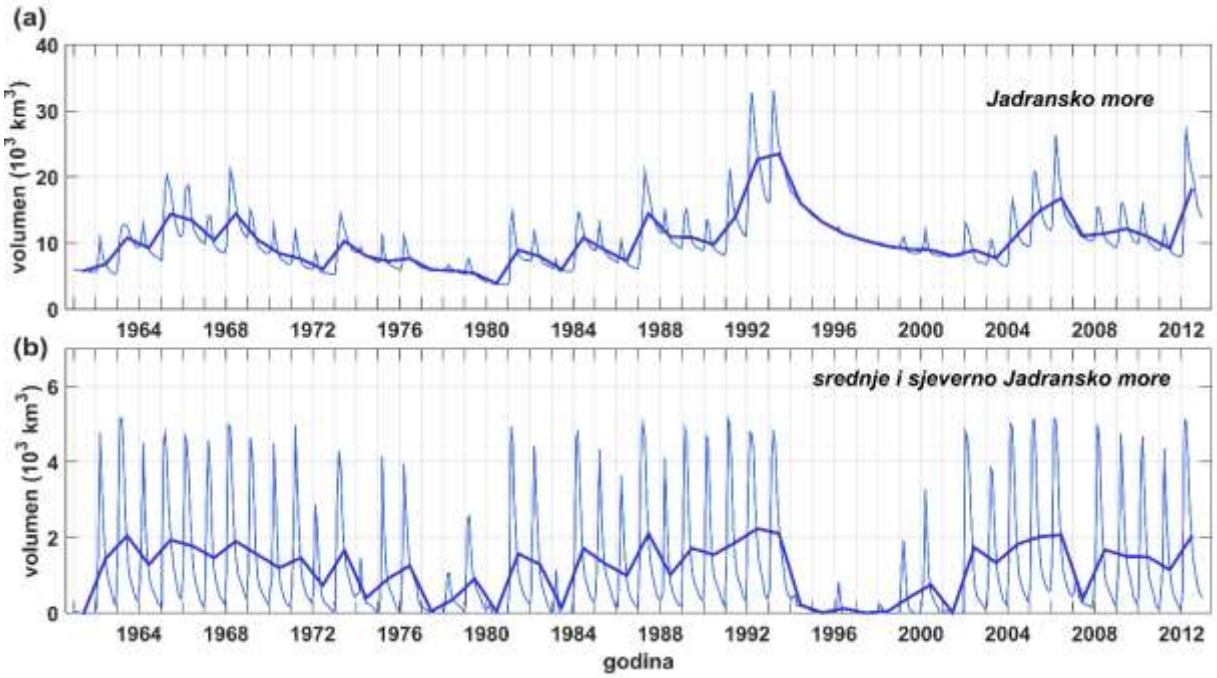


Slika 14. Vremenski nizovi (a) ukupnih površinskih protoka topline za sjeverni i južni Jadran (područja 1 i 2 na slici 7) usrednjenih za razdoblje SPSV i godišnji kumulativni transporti gustih voda kroz (b) Palagruški prag, te (c) Otrantska vrata, simulirani MED8F-om.

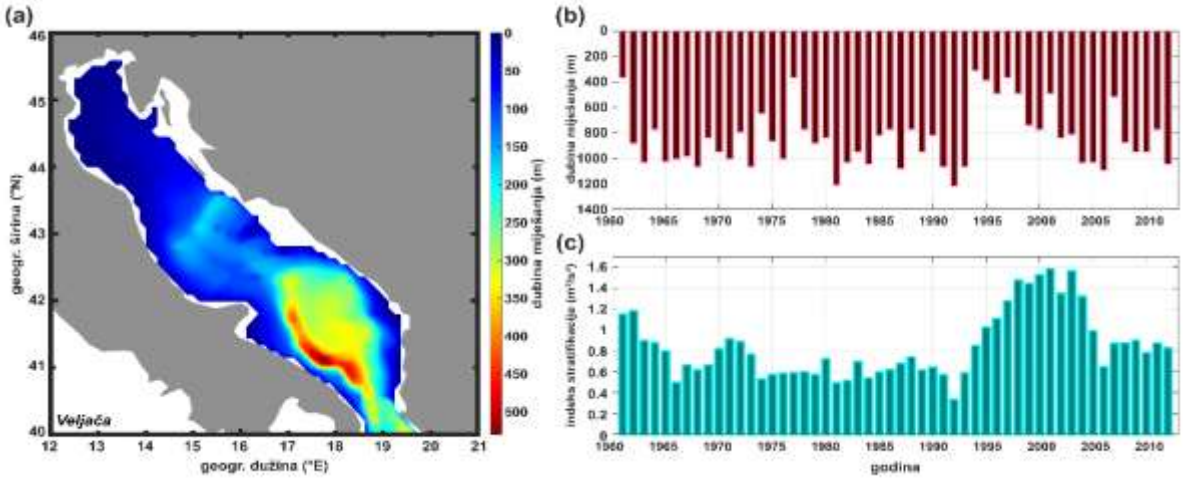
Tijekom razdoblja SPSV, površinski protoci topline su korelirani s procesima stvaranja guste vode u svim dijelovima Sredozemnog mora (Josey, 2003), pa tako i u sjevernom (Vilibić i Supić, 2005) i južnom (Gačić i sur., 2002; Bensi i sur., 2013) Jadranu. U sjevernom Jadranu, simulacija MED8F daje jake površinske gubitke topline praćene snažnim procesima stvaranja guste vode u godinama 1963., 1982., 1991., 2005., 2006. i 2012., međutim to nije uvijek slučaj (slika 14b). Kumulativni godišnji volumeni transporta Sjevernojadranske vode na Palagruškom pragu s anomalijama potencijalne gustoće višim ili jednakim 29.25 kg/m^3, koji nadmašuju vrijednosti 2000 km^3, su također zabilježeni u godinama 1965., 1968., 1971., 1981., 1984., 1987., 1992., 1993., 2002., 2004., 2005. i 2008. Slično se ponašaju i južnojadranski procesi stvaranja gustih voda, gdje se površinski gubici topline u 1968., 1992., 2006. i 2012. godini podudaraju sa snažnim procesima stvaranja guste vode (slika 14c), ali se i u godinama 1965., 1966., 1987., 1991. i 1993. javljaju kumulativni transporti guste vode iznad 2000 km^3 (vrijednosti anomalije potencijalne gustoće iznad 29.2 kg/m^3), iako su zime u južnom Jadranu bile blaže. Koeficijent korelacije između površinskih protoka topline (slika 14a) i navedenih kumulativnih transporta (slika 14b i c) za sjeverni Jadran iznosi 0.47 (na razini statističke značajnosti od 99%), a za južni Jadran 0.31 (na razini statističke značajnosti od 95%). Relativno mali iznosi koeficijenata ukazuju da je varijabilnost stvaranja guste vode samo djelomično uvjetovana varijabilnošću atmosferskih procesa. Zaista, ona je karakterizirana i s dekadskom varijabilnošću (Gunduz i sur., 2013) koja je najvjerojatnije usko povezana s mehanizmom

BiOS-a i promjenama cirkulacije u sjevernom Jonskom moru (Gačić i sur., 2010), a čiji se utjecaj zamjećuje na oba transekta (slika 14b i c).

Naime, tri razdoblja povišenih kumulativnih transporta guste vode na Palagruškom transektu - prvi od sredine do kraja 1960-tih godina, drugi od sredine 1980-tih do početka 1990-tih godina, i treći od 2000-tih godina do početka 2010. godine - podudaraju se s razdobljima povišenog saliniteta (slika 13b) odražavajući ciklonalnu fazu mehanizma BiOS-a. Maksimum transporta jadranskih gustih vodenih masa, uz povećane volumene Sjevernojadranske i Južnojadranske vode (slika 15) su simulirani u razdoblju 1991. - 1993., istovremeno s pojavom Istočnosredozemnog tranzijenta. Idućih godina (1994. - 2001.) simulacija daje pad saliniteta u Jadranu (slika 13b) praćen niskim transportima i volumenima gustih vodenih masa, što ukazuje na izostanak ili tek slabo stvaranje guste vode u Jadranu (slika 14b i c). Pad je konzistentan s dinamikom Jadrana opaženom tijekom 1990-tih, kad je iznimno stvaranje guste vodene mase u Egejskom moru rezultiralo izraženim dotokom manje slanih vodenih masa iz zapadnog Sredozemlja u Jonsko i Jadransko more (Roether i sur., 2007.; Vilibić i sur., 2012.). Promatra li se Jadran kao cjelina, međugodišnje i sezonske promjene su približno istih amplituda (slika 15a), osim u razdoblju nakon Istočnosredozemnog tranzijenta. Sezonska varijabilnost volumena gustih vodenih masa je prevladavajuća u sjevernom i srednjem Jadranu (slika 15b), gdje zimi, nakon stvaranja, Sjevernojadranska voda relativno brzo istječe prema jugoistoku. Pri tome, njezin manji udio ostaje u dubokim slojevima srednjeg Jadrana (Jabučka kotlina) tokom cijele godine, a ostatak nastavlja svoj put i tone u Južnojadransku kotlinu.



Slika 15. Vremenski nizovi mjesečnih vrijednosti simuliranih volumena jadranskih gustih vodenih masa za zadani prag *PDA*>29.20 kg/m^3, usrednjenih preko područja (a) čitavog Jadrana (sjeverno od Otrantskih vrata) i (b) zapadno od Palagruškog praga. Debela plava linija prikazuje 1-godišnji klizni srednjak.



Slika 16. (a) Prostorna razdioba srednjih vrijednosti maksimalne dubine miješanja u veljači, (b) vremenski niz godišnje maksimalne dubine miješanja i (c) vremenski niz indeksa stratifikacije, dobiveni usrednjavanjem preko područja s dubinama većim od 1000 m u južnom Jadranu.

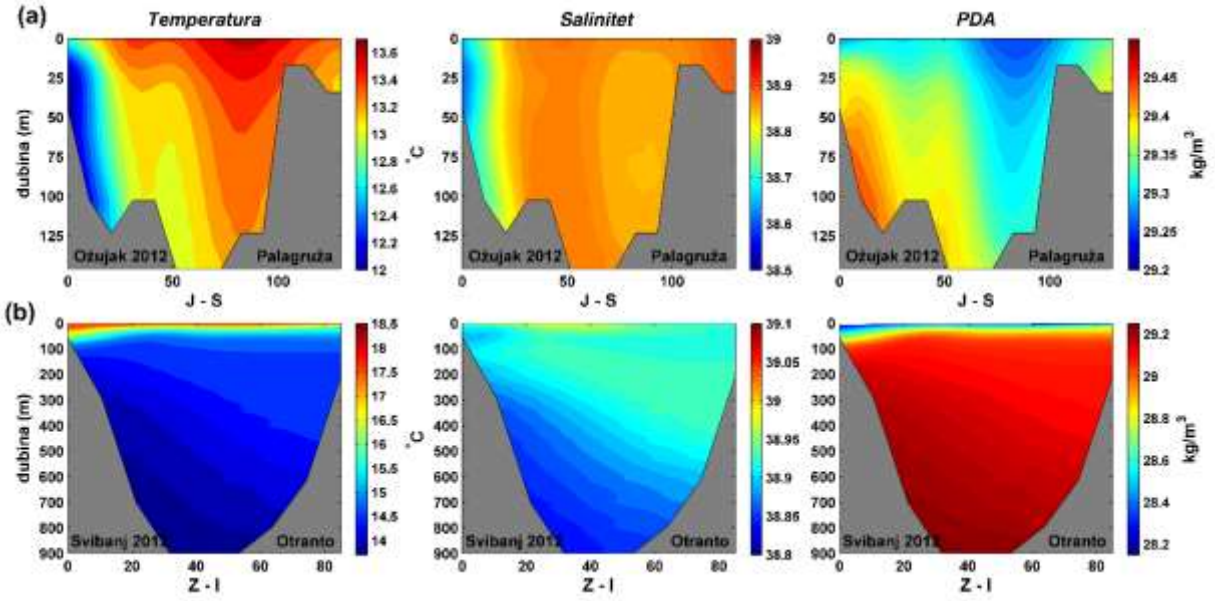
Prostorni obuhvat duboke konvekcije u južnom Jadranu se može predočiti pomoću maksimalnih vrijednosti dubine miješanja (*MLD*). U simulaciji MED8F, maksimalne vrijednosti dubine miješanja su redovito reproducirane tijekom veljače, što je u skladu s opažanjima (Gačić i sur., 2002; Josey, 2003). Prostorna razdioba (slika 16a) ukazuje da je jugozapadni dio Južnojadranske kotline (ispred kanjona Barija) područje najjače duboke konvekcije, s prosječnom dubinom miješanja od 400 do 500 m. Nadalje, dubina miješanja doseže samo dno Južnojadranske kotline (1200 m) tijekom 1981. i 1992. godine (slika 16b). Tako visoke modelirane vrijednosti nisu u skladu s opažanjima, koja ne bilježe dubinu miješanja veću od 900 m (Gačić i sur., 2002). Razlog tome je obitavanje Sjevernojadranske vode na dnu Južnojadranske kotline (Bensi i sur., 2013) koja ima dovoljno visoku gustoću da spriječi miješanje vodenog stupca do samog dna. Izraženija duboka konvekcija je reproducirana simulacijom MED8F u godinama 1980. i 1981. te 1986. i 1987., što je u skladu s prijašnjim istraživanjima temeljenim na numeričkim simulacijama Jadrana (Castellari i sur., 2000; Mantziafou i Lascaratos, 2008). S druge strane, jake konvektivne zime 1998. i 1999. godine (Mantziafou i Lascaratos, 2008) su karakterizirane slabijom dubokom konvekcijom u MED8F-u, pri čemu je reproducirana dubina miješanja iznosila oko 500 m (slika 16b).

Maksimalna dubina miješanja je korelirana s površinskim protocima topline u južnom Jadranu (koeficijent korelacije 0.54, značajan na razini pouzdanosti od 99%, slika 14a). No, slično kao i kod transporta jadranskih gustih vodenih masa, vremenski niz maksimalne dubine miješanja sadrži i dekadsku varijabilnost. Opet se ističe razdoblje u simulaciji pod utjecajem Istočnosredozemnog tranzijenta (1995. - 2004.), kad je visoka stratifikacija, zbog advekcije manje slanih manje gustih voda u površinskom i intermedijarnom sloju, smanjila intenzitet stvaranja gustih vodenih masa i dubinu miješanja. Shodno tome, stratifikacijski indeks (slika 16c) se udvostručio u tom razdoblju. Nakon 2004. godine stratifikacijski indeks se smanjio, što je omogućilo povećanje intenziteta konvektivnih procesa i stvaranja Južnojadranske vode.

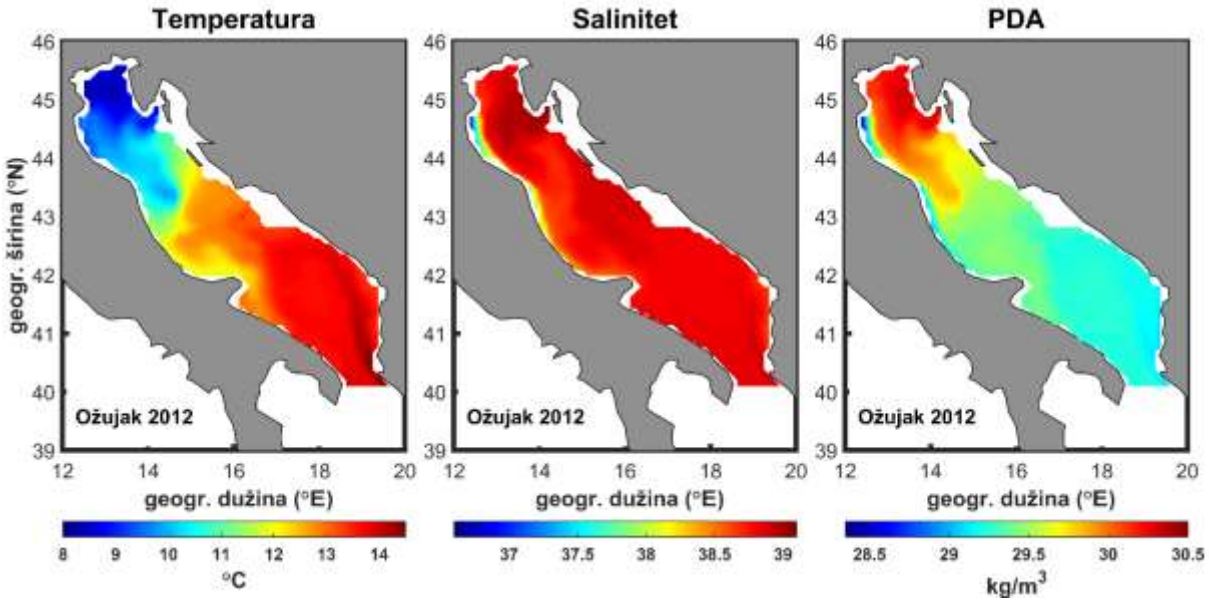
Da bismo bolje razumjeli sposobnost MED8F-a da reproducira stvaranje gustih vodenih masa u Jadranu, detaljnije je istražena izražena zimska epizoda 2012. godine. Te su godine u sjevernom Jadranu zabilježene vrijednosti anomalija potencijalne gustoće premašile 30.0 kg/m^3, a epizoda je dobro zabilježena *in situ* mjerenjima (Mihanović i sur., 2013) te reproducirana numeričkim simulacijama (Janeković i sur., 2014). Simulacija MED8F kvalitativno reproducira istjecanje Sjevernojadranske vode na južnom dijelu Palagruškog praga u ožujku 2012. godine (slika 17a). No, simulirane vrijednosti temperature na Palagruškom pragu su za gotovo 2 ^{o}C više od opaženih vrijednosti (10.5 ^{o}C, Mihanović i sur., 2013; Chiggiato

i sur., 2016). Nadalje,simulacija ne reproducira istjecanje Sjevernojadranske vode u središnjem dijelu Palagruškog praga, sjeverno od otoka Palagruže, gdje je također uočeno istjecanje te vode (Vilibić i sur., 2004; Janeković i sur., 2014). Simulirani pridneni salinitet u južnom dijelu Palagruškog praga je oko 38.7, a anomalije gustoće su iznad 29.4 kg/m^3, pri čemu su obje vrijednosti niže od opaženih (Mihanović et al., 2013).

Visoki salinitet površinskog i srednjeg sloja u središnjem i sjevernom dijelu Palagruškog transekta ukazuje na advekciju Levantinske intermedijarne vode Istočnojadranskom strujom prema srednjem i sjevernom Jadranu. Slika 18 prikazuje simulirane pridnene vrijednosti temperature, saliniteta i anomalije potencijalne gustoće u ožujku 2012. godine. Najviše vrijednosti gustoće su simulirane u području zapadno i južno od rta Premantura (poluotok Istra), s vrijednostima iznad 30.0 kg/m^3, koje su opažene tijekom zime 2012. godine (Mihanović i sur., 2013). Međutim, vrijednosti simuliranih temperatura su precijenjene, a iznimno visoka gustoća je posljedica precijenjenih vrijednosti saliniteta u području sjevernog Jadrana.



Slika 17. Vertikalni profili mjesečnih srednjaka temperatura, saliniteta i anomalije potencijalne gustoće na (a) Palagruškom pragu u ožujku 2012. godine i (b) Otrantskim vratima u svibnju 2012. godine, simulirani MED8F-om.



Slika 18. Mjesečni srednjaci pridnene temperature, saliniteta i anomalije gustoće u ožujku 2012. godine, simulirani MED8F-om.

U simulaciji MED8F, Sjevernojadranska voda se na svom putu miješa s okolnim vodama te u ožujku 2012. godine stiže do kanjona Barija s gustoćom nešto iznad 29.3 kg/m^3. U svibnju iste godine, pomiješana s Južnojadranskom vodom, Sjevernojadranska voda istječe u Jonsko more poglavito u pridnenom sloju zapadnog dijela Otrantskih vrata (slika 17b), u području koje je zabilježeno mjerenjima (Gačić i sur., 1996). Na Otrantskim vratima, simulirane temperature izlazne struje su nešto niže od 14.5 ^{o}C, a salinitet malo ispod 38.85 (slika 17b), što je za oko 1 ^{o}C toplije i za oko 1 slanije od vrijednosti zabilježenih u literaturi (Gačić i sur., 1996; Manca i sur., 2002; Ursella i sur., 2011; Bensi i sur., 2013).

Analizirana simulacija MED8F ima nekoliko strukturnih nedostataka, zbog čega simulirano nastajanje i dinamika Sjevernojadranske vode ne slijedi u potpunosti opažena svojstva. Sekundarno područje stvaranja gustih vodenih masa u sjevernom Jadranu je zabilježeno u području Kvarnerskog zaljeva, s doprinosom ukupnom volumenu Sjevernojadranske vode od oko 40% u 2012. godini (Janeković i sur., 2014). Zbog grube razlučivosti modela, to područje nažalost nije pravilno definirano u modelima MED8 (npr. slika 18), odnosno definirano je kao kopno. Nadalje, modeli MED8, zbog nedovoljno fine horizontalne i vertikalne rezolucije, nisu u mogućnosti reproducirati mezoskalnu dinamiku koja karakterizira područje plitkog sjevernojadranskog šelfa, kao što je stvaranje Sjevernojadranske vode. Tijekom stvaranja guste vode, pod utjecajem bure koja je karakterizirana izrazitom prostornom i vremenskom

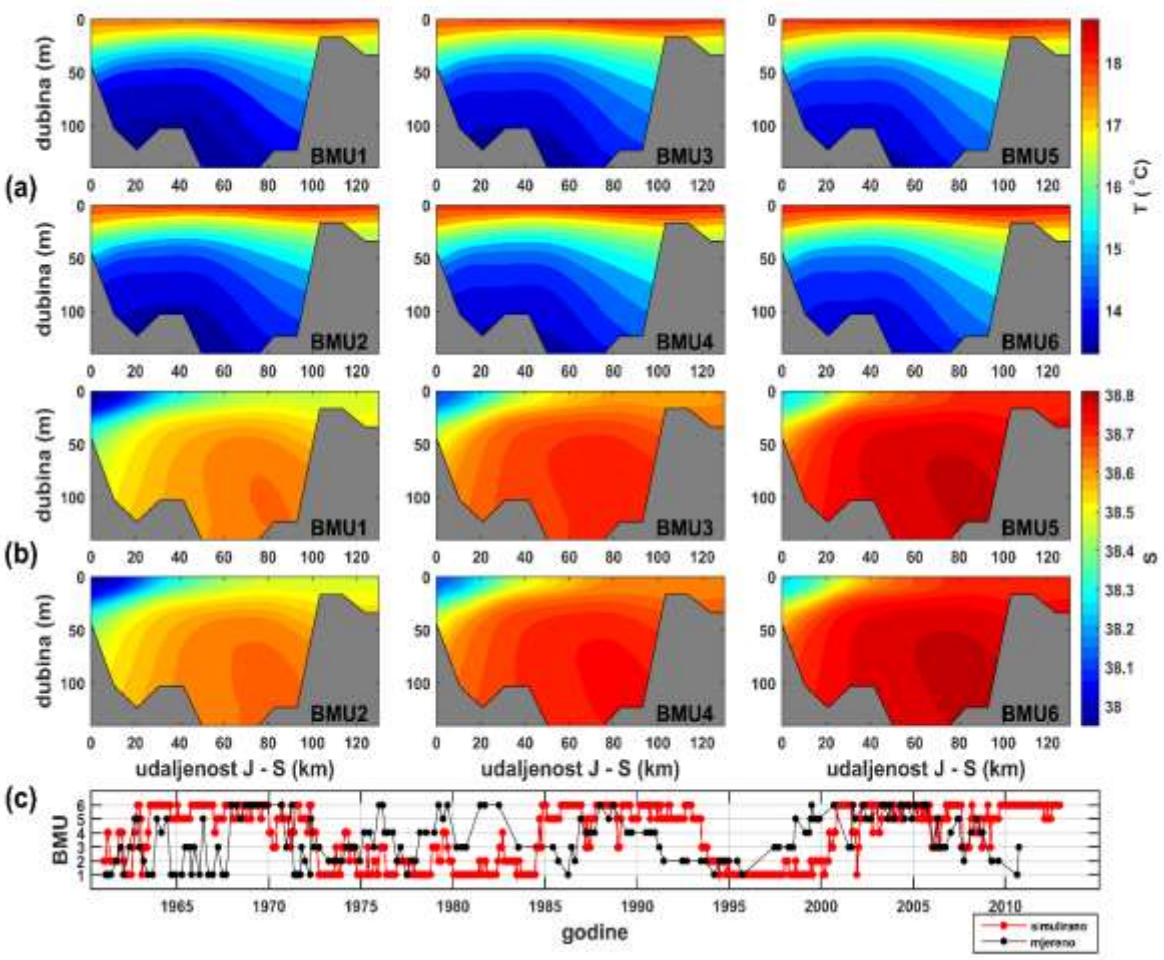
varijabilnošću, u sjevernom Jadranu se javlja kompleksna cirkulacija sastavljena od niza ciklonalnih i anticiklonalnih vrtloga (Zore-Armanda i Gačić, 1987; Orlić i sur., 1994; Kuzmić i sur., 2006). U prosjeku, područje stvaranja Sjevernojadranske vode je smješteno bliže zapadnoj obali, unutar ciklonalnog vrtloga ispred delte rijeke Po (Beg-Paklar i sur., 2001), no ponekad se veća gustoća vode bilježila uz zapadnu obalu (Supić i Vilibić, 2006). Suprotno tome, MED8F reproducira nastanak voda najveće gustoće uz istočnu obalu sjevernog Jadrana, zbog povećanog saliniteta i većih gubitaka topline u tom dijelu bazena u odnosu na gubitke topline na zapadnoj strani (Dorman i sur., 2007; Janeković i sur., 2014). U stvarnosti, na tom području se stvara termohalina fronta pod utjecajem dotoka slatkih voda iz Kvarnera, a koja odvaja obalne vode nižeg saliniteta od voda otvorenog mora s višim salinitetom (Orlić i sur., 1992; Kokkini i sur., 2017). U simulaciji MED8F, koja ima samo 8 rijeka u Jadranu, ni jedan izvor slatke vode nije smješten na sjeveroistočnom dijelu obale, odnosno u Kvarneru.

3.5. Dekadska varijabilnost i mehanizam BiOS-a

Da bi se kvalitetnije procijenila pouzdanost simulacije MED8F pri reprodukciji međugodišnje i dekadske varijabilnosti termohaline cirkulacije u Jadranu, napravljene su procjene karakterističnih uzoraka vertikalnih profila temperature i saliniteta na Palagruškom pragu, upotrebom metode SOM (vidi poglavlje 2.5.4.). Obzirom na duljinu vremenskih nizova (Liu i sur., 2006), te u skladu s prethodnim istraživanjima (Mihanović i sur., 2015), odabrana je analiza SOM-om 2 × 3, čime je izdvojeno 6 karakterističnih uzoraka profila temperature i saliniteta reproduciranih MED8F-om (slika 19). Profili su poredani ovisno o vrijednostima srednjeg saliniteta, pri čemu su polja najnižeg saliniteta sadržani u uzorku BMU1 (slika 19b). Uzorci s profilima nižih saliniteta i temperatura (BMU1 i BMU2) se objašnjavaju pojačanim dotokom manje slanih i hladnijih atlantskih vodenih masa iz zapadnog Sredozemlja u Jadransko more (Mihanović i sur., 2015; Vilibić i sur., 2012) za vrijeme anticiklonalne cirkulacije u sjevernom Jonskom moru. S druge strane, uzorci BMU5 i BMU6 su karakterizirani višim vrijednostima saliniteta i temperature, što ukazuje na pojavu ingresijskih godina u razdobljima ciklonalne faze BiOS-a, kad toplija i slanija Levantinska intermedijarna voda značajno ulazi u Jadran (Zore-Armanda, 1969; Artegiani i sur., 1997a; Gačić i sur., 2010). Uzorci BMU3 i BMU4 predstavljaju prijelazna stanja između niskog i visokog saliniteta. Sveukupno, profili saliniteta pokazuju veću varijabilnost od profila temperature. U odnosu na identičnu analizu temeljenu na mjerenjima na Palagruškom pragu (Mihanović i sur., 2015), rezultati analize SOM-a na podacima MED8F-a ukazuju na to da MED8F relativno dobro reproducira

karakteristične uzorke vertikalnih profila temperature i saliniteta. Ipak, uočljivo je nekoliko razlika između simuliranih i mjerenih uzoraka na Palagruškom pragu. Jezgra Levantinske intermedijarne vode je u stvarnosti smještena u središnjem dijelu Palagruškog praga, dok je u simulaciji pomaknuta prema sjevernom kraju transekta. Nadalje, simulirani površinski salinitet je iznimno visok na sjevernom kraju zbog nedostatka istočnojadranskih rijeka u simulaciji MED8F.

Vremenske promjene profila temperature i saliniteta na Palagruškom pragu (slika 19c, crvena krivulja) ukazuju na snažnu dekadsku varijabilnost unutar MED8F-a, s izmjenama razdoblja niskog (BMU1 i BMU2) i visokog (BMU5 i BMU6) saliniteta. Mjerenja ukazuju na slično oscilatorno ponašanje (slika 19c, crna krivulja), s izraženom dekadskom varijabilnošću, naročito zadnja dva desetljeća (Mihanović i sur., 2015). Međutim, uzorci simulacije u tom razdoblju pokazuju na kašnjenje u odnosu na uzorke mjerenja, u prosjeku oko tri godine. Prije 1980. godine, izmjena uzoraka je učestalija u mjerenjima nego li u simulaciji, u kojoj je period dvostruko dulji nego u stvarnosti.

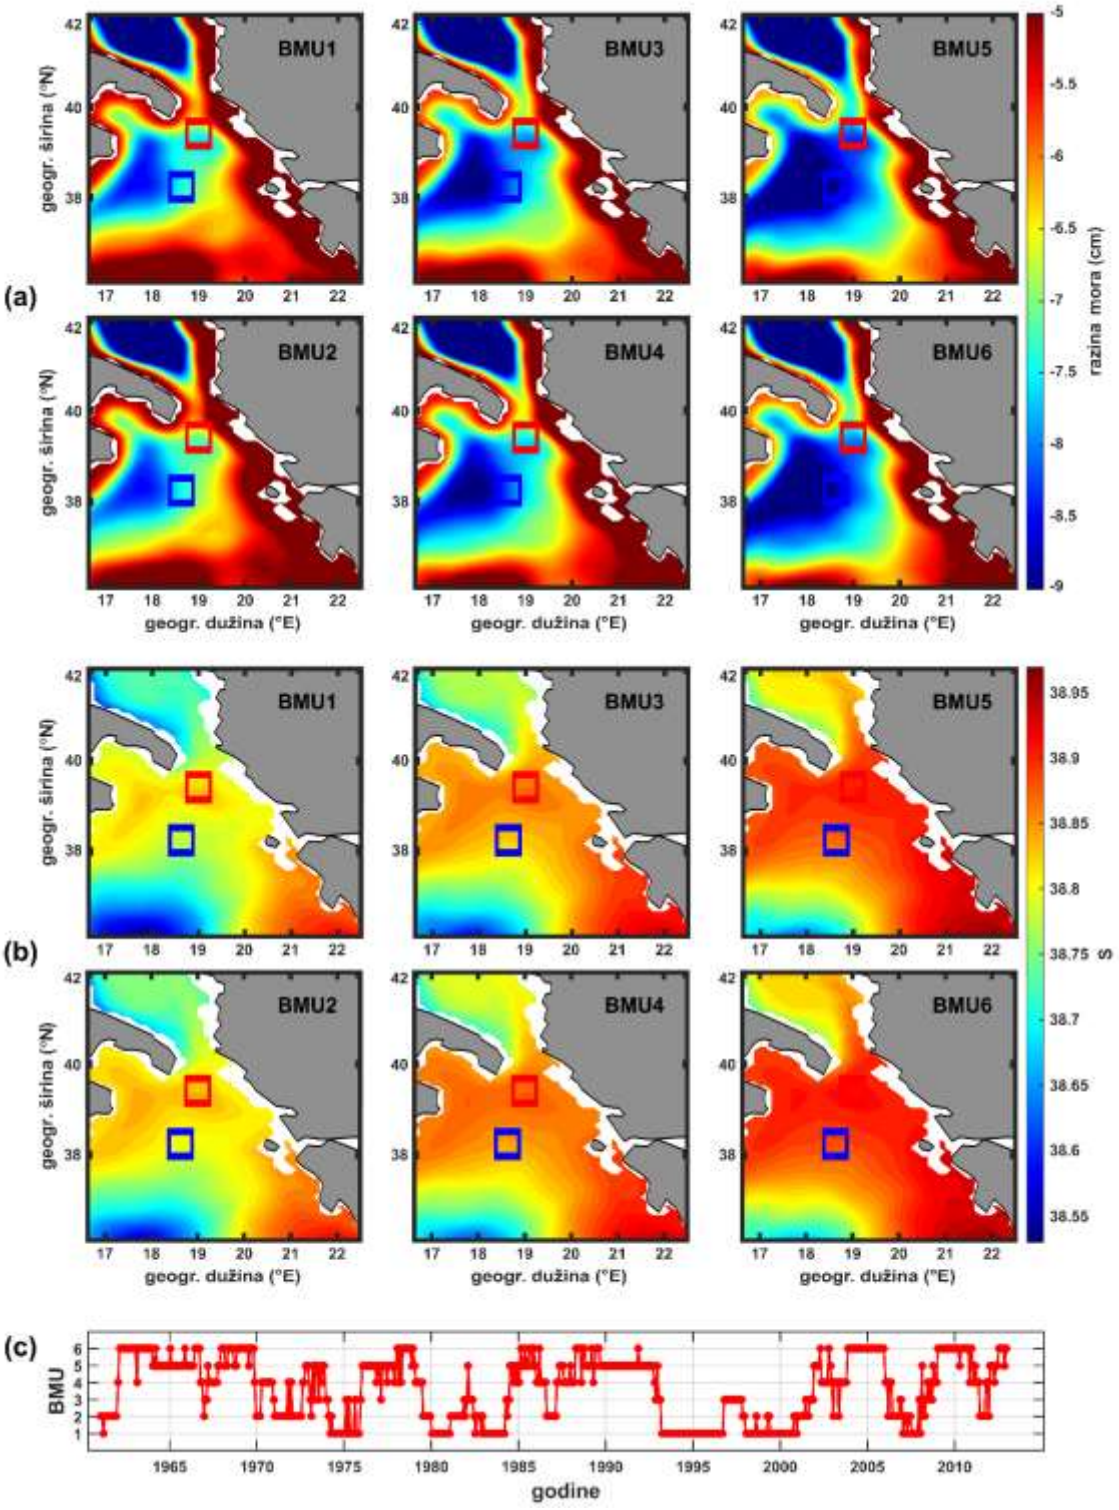


Slika 19. Karakteristični uzorci presjeka (a) temperature i (b) saliniteta na Palagruškom pragu simulirani MED8F-om te procijenjeni metodom SOM-a, te (c) vremenski niz uzoraka. Uzorci su poredani temeljem usrednjenog saliniteta na presjeku, pri čemu je uzorak BMU1 karakteriziran najnižim salinitetom, a uzorak BMU6 najvišim salinitetom. Vremenski niz BMU-ova procijenjenih iz mjerenja temperature i saliniteta je prikazan crnom krivuljom (preuzeto iz Mihanović i sur., 2015).

Kako je pokazano u više radova (Gačić i sur., 2010; Mihanović i sur., 2015), promjene cirkulacije u sjevernom Jonskom moru uzrokovane BiOS-om se mogu detektirati pomoću satelitskih mjerenja razine mora. Razini mora dobivenoj simulacijom MED8F je pridruženo simulirano polje saliniteta na 100 m dubine, kao indikator transporta Levantinske intermedijarne vode, te su skupa uvedeni u metodu SOM-a s istim postavkama kao i kod analize podataka s Palagruškog praga. Na takav način, simulirane promjene u cirkulaciji sjevernog Jonskog mora su povezane s prostornim promjenama saliniteta. Na slici 20a i b je prikazano šest karakterističnih uzoraka simuliranih prostornih polja razine mora i saliniteta na 100 m dubine. Umjesto očekivane promjene cirkulacije uzrokovane mehanizmom BiOS-a, simulacija daje isključivo ciklonalni tip cirkulacije za cijelo razdoblje. Međutim, simulirani ciklonalni

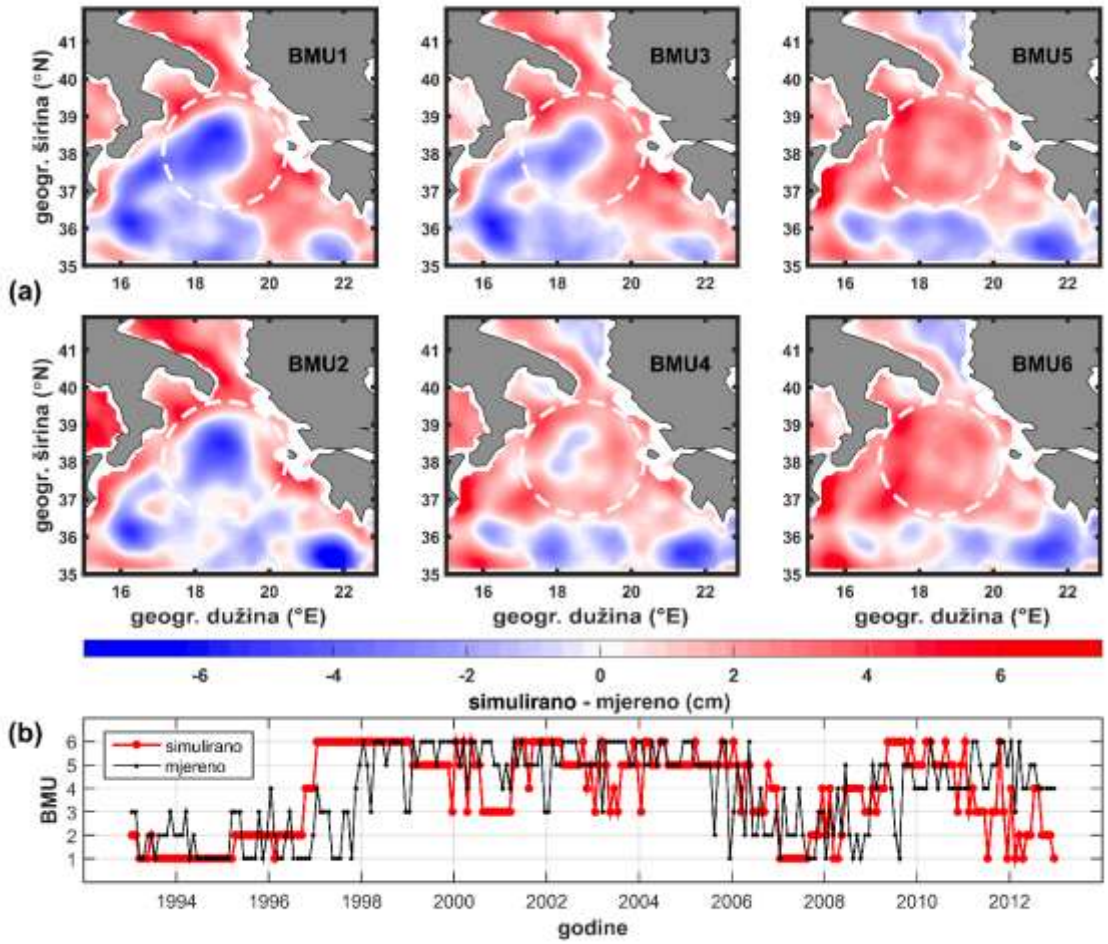
vrtlog, pomaknut na području sjeverozapadnog Jonskog mora, ima vremenski varijabilan prostorni domet i intenzitet koji je povezan s varijabilnošću saliniteta, odnosno s izmjenom razdoblja dotoka vode nižeg saliniteta iz zapadnog Sredozemlja i razdoblja dotoka slane Levantinske intermedijarne vode iz istočnog Sredozemlja u Jadran. Najslabija ciklonalna cirkulacija s najmanjim prostornim dometom vrtloga je povezana s prostorno nižim vrijednostima saliniteta (BMU1 i BMU2). Jačanjem ciklonalne cirkulacije, naročito uz istočnu obalu Jonskog mora, jača i advekcija Levantinske intermedijarne vode sjeveroistočnim rubnim dijelom Jonskog mora prema Jadranu (BMU5 i BMU6).

Oba parametara pokazuju dekadsku varijabilnost, pri čemu su 1970-tih godina izmjene karakterističnih uzoraka učestalije (slika 20c). U razdoblju od 1993. do 2001. godine dominira uzorak BMU1 karakteriziran niskim salinitetom, što odgovara razdoblju nakon Istočnosredozemnog tranzijenta (Klein i sur., 1999), kada su u Jadranu zabilježene najniže vrijednosti saliniteta u intermedijarnom sloju (Vilibić i sur., 2012).



Slika 20. Karakteristični uzorci polja (a) razine mora i (b) saliniteta na 100 m dubine u sjevernom Jonskom moru simulirani MED8F-om i procijenjeni metodom SOM-a te (c) vremenski niz karakterističnih uzoraka. Uzorci su poredani temeljem srednjih vrijednosti saliniteta, pri čemu je uzorak BMU1 karakteriziran najnižim salinitetom, a BMU6 najvišim salinitetom.

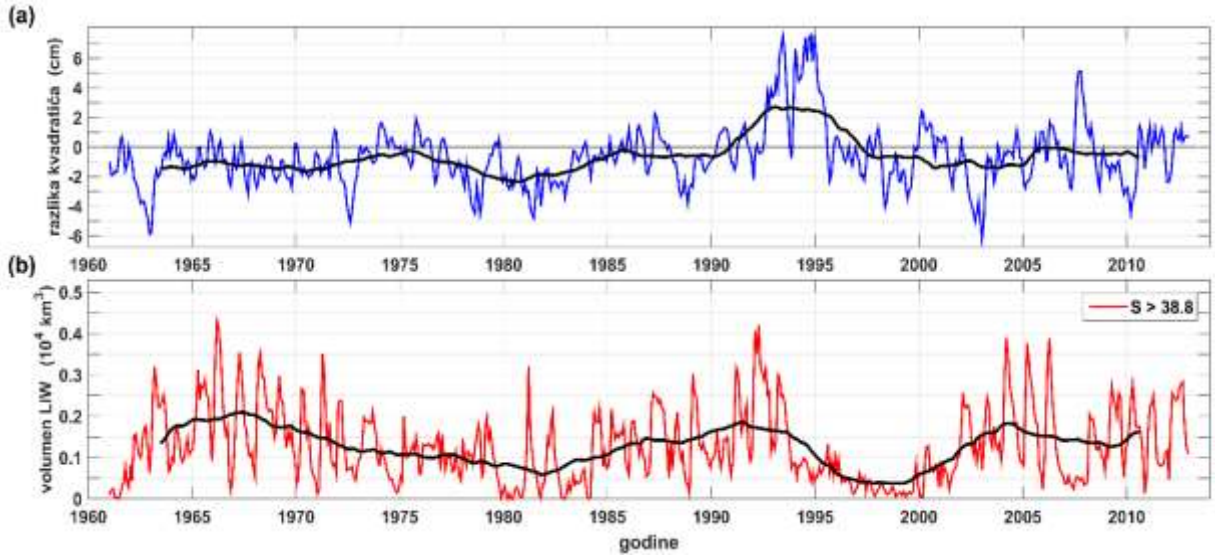
Uspoređujući karakteristične uzorke polja razine mora s onima dobivenih pomoću altimetrijskih mjerenja (Mihanović i sur., 2015), uočava se jako podcjenjivanje varijabilnosti površinske cirkulacije u MED8F-u. Da bismo bolje razumjeli odstupanje simulacije, napravljene su dodatne analize SOM-om, odvojeno za mjerene (*ADT*) i simulirane vrijednosti razine mora, za isto razdoblje (1993. - 2012.). Slika 21a prikazuje razlike karakterističnih uzoraka simulirane razine mora te uzoraka dobivenih altimetrijskim mjerenjima. Uzorci BMU1 i BMU2 dobiveni simulacijom MED8F izrazito podcjenjuju razinu mora upravo u središnjem dijelu vrtloga (isprekidana kružnica na slici 21a), stoga simulacija ne reproducira anticiklonalni režim BiOS-a. Nešto slabije, ali vidljivo podcjenjivanje je zamjetno i u „prijelaznim“ uzorcima (BMU3 i BMU4). S druge strane, simulirane ciklonalne faze BiOS-a, zabilježene u uzorcima BMU5 i BMU6, ne pokazuju promjene unutar vrtloga u odnosu na mjerene uzorke. Naime, podcjenjivanje razine mora je zamjetno u središtu i na rubnim dijelovima sjevernog Jonskog mora, stoga je geostrofička ravnoteža očuvana, a time i tip i intenzitet cirkulacije. Zanimljivo je da vremenske promjene karakterističnih uzoraka iz simulacije pokazuju sličnost s vremenskim promjenama *ADT*-a dobivenim altimetrijskim mjerenjima, što ukazuje na kvalitativnu sposobnost simulacije MED8F da reproducira mehanizam BiOS-a, iako prostorna svojstva cirkulacije u sjevernom Jonskom moru nisu pravilno reproducirana.



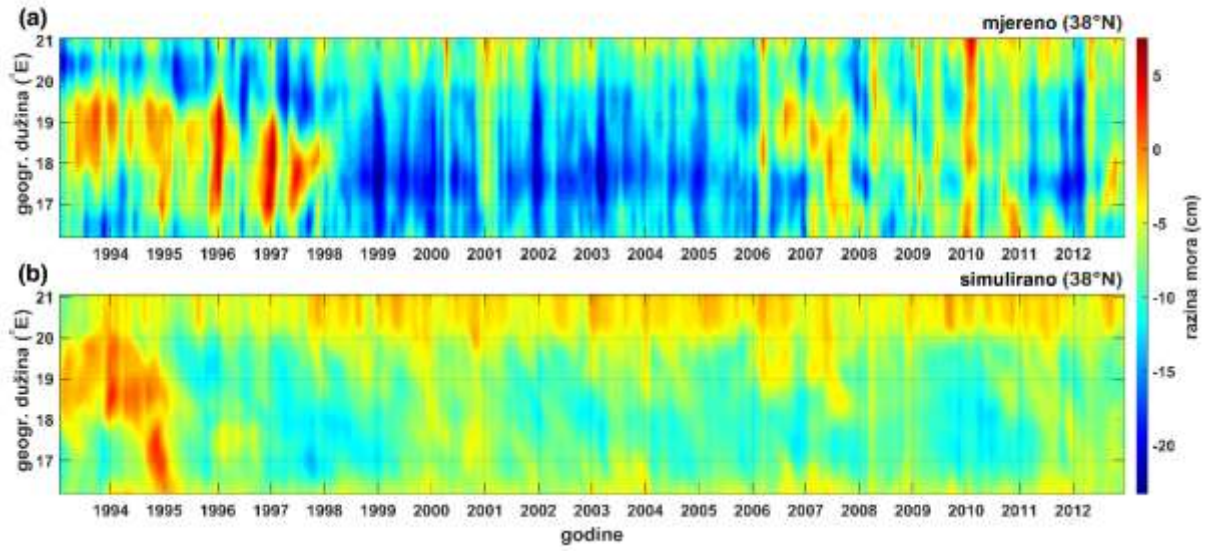
Slika 21. Razlike karakterističnih uzoraka polja razine mora izdvojenih iz MED8F-a pomoću metode SOM u odnosu na uzorke izdvojenih iz altimetrijskih mjerenja (AVISO+). Prije analize, srednja vrijednost polja je oduzeta iz oba skupa podataka. Položaj vrtloga u sjevernom Jonskom moru povezanog s mehanizmom BiOS-a je prikazan bijelom isprekidanom kružnicom.

Obzirom da je broj karakterističnih uzoraka dobivenih analizom SOM-a relativno malen, te pojedini uzorak predstavlja mnogostruka stanja mora, načinjena je dodatna analiza s ciljem dokumentiranja cirkulacije u sjevernom Jonskom moru. Sukladno analizama Gačić i sur. (2010) i Mihanović i sur. (2015), izračunate su vremenske promjene razlike razine mora simulirane u središnjem i sjevernom rubu vrtloga (plavi i crveni kvadratići na slici 20a i b). Vremenski niz razlika (tj. BiOS indeksa) otkriva dominantnu ciklonalnu cirkulaciju u sjevernom Jonskom moru u čitavom razdoblju trajanja simulacije (negativne vrijednosti razlike, slika 22a). Jedino razdoblje gdje BiOS indeks mijenja svoj predznak je između 1992. i 1995. godine, zbog utjecaja Istočnosredozemnog tranzijenta. Varijabilnost BiOS indeksa u simulaciji

je značajno niža nego u stvarnosti (Gačić i sur., 2014), a uz to ne pokazuje značajnu korelaciju s dotokom Levantinske intermedijarne vode u Jadran (slika 22b).



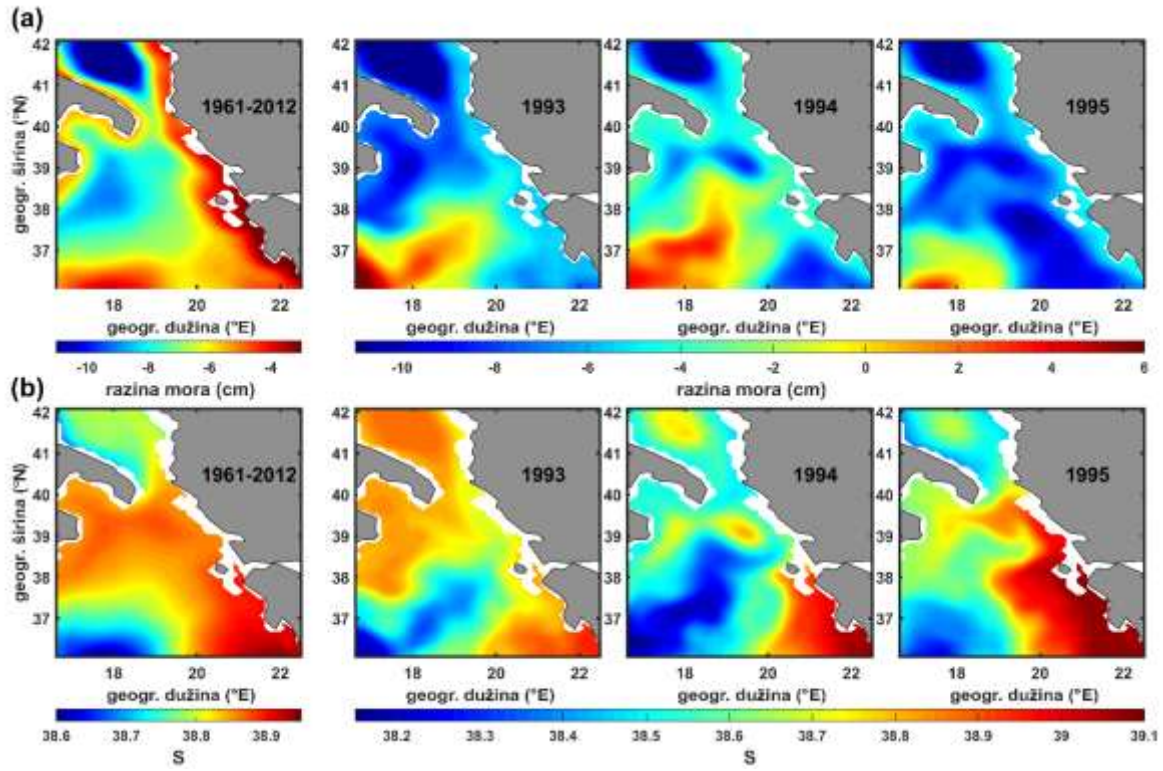
Slika 22. Vremenski nizovi (a) razlike razine mora između središnjeg i sjevernog ruba sjevernojonskog vrtloga (crveni i plavi kvadratići na slici 20a i b) koji se povezuju s BiOS-om te (b) volumena transporta Levantinske intermedijarne vode (S>38.8) na Otrantskim vratima prema Jadranu, simulirani MED8F-om.



Slika 23. Hovmöller dijagrami mjesečno usrednjenih razina mora na paraleli 38 °N u Jonskom moru (a) određenih satelitskim mjerenjima i (b) simulirani MED8F-om. Prije analize, iz oba skupa podataka je uklonjen sezonski signal.

Da bismo potvrdili pojavu anticiklonalne cirkulacije u razdoblju između 1993. i 1995. godine u simulaciji MED8F, napravljena je usporedba simuliranih i mjerenih vrijednosti razine mora na zonalnom transektu sjevernog Jonskog mora, na geografskoj širini 38.0 ^{o}N (slika 23). Prije analize, sezonski signal je uklonjen iz oba skupa podataka. Očekivano, u simulaciji MED8F prevladava veoma slaba vremenska i prostorna varijabilnost razine mora, ukazujući na dominantnu, ali i slabu ciklonalnu cirkulaciju. Jedino razdoblje pojave reproducirane anticiklonalne cirkulacije je od 1993. do 1995. godine. S druge strane, analize temeljene na mjerenjima otkrivaju dekadsku varijabilnost razine mora uzrokovanu BiOS-om (Mihanović i sur., 2015): anticiklonalna faza BiOS-a u razdoblju nakon 1993. godine, promjenu u ciklonalnu fazu 1998. godine koja traje do 2006., nakon čega cirkulacija opet poprima anticiklonalni oblik. Također je vidljiva i snažna međugodišnja varijabilnost, koja nije toliko prisutna u simulaciji MED8F.

Prostorna polja razine mora simulirana MED8F-om u području sjevernog Jonskog mora reproduciraju anticiklonalnu cirkulaciju u 1993., 1994. i 1995. godini (slika 24a), i s njome povezanu advekciju vodenih masa nižeg saliniteta iz zapadnog Sredozemnog mora (slika 24b). Međutim, prijelaz između dva cirkulacijska režima nije toliko izražen kao što je zabilježen u mjerenjima (Mihanović i sur., 2015). Simulirana anticiklonalna cirkulacija započinje krajem 1992. godine, te dosiže maksimum u smislu intenziteta i odmaka prema sjeveru tijekom 1994. godine. Nakon toga, tijekom 1995. godine, anticiklonalni vrlog se povlači prema jugu, dok ponovno uspostavljeni ciklonalni vrtlog povlači slanu Levantinsku intermedijarnu vodu prema Otrantskim vratima uz istočnu obalu sjevernog Jonskog mora.



Slika 24. Prostorna polja (a) razine mora i (b) saliniteta na 100 m dubine, usrednjena za razdoblje 1962. - 2012., te tijekom 1993., 1994. i 1995. godine, simulirana MED8F-om.

3.6. Diskusija

U ovom poglavlju po prvi puta je načinjena analiza termohalinih svojstava i pokretača termohaline cirkulacije Jadrana u razdoblju od nekoliko desetljeća, temeljena na simulaciji MED8F za Sredozemlje, u razdoblju od 1962. do 2012. godine. Naravno, prvo je postavljeno pitanje vjerodostojnosti i kvalitete same simulacije, obzirom na svojstva i postavke modela i korištenih rubnih uvjeta. Sama verifikacija simulacije je načinjena pomoću dugoročnih nizova temperature i saliniteta u južnom i srednjem Jadranu za koje postoje podaci tijekom cijelog razdoblja simulacije, a po prvi puta su korišteni za validaciju ovako dugačkih simulacija u Jadranu. Uz to, za verifikaciju su korišteni i altimetrijski podaci. Pronađeno je da simulacija reproducira sljedeća važna dinamička svojstva Jadranskog mora:

1. opću jadransku ciklonalnu cirkulaciju, uključujući i termohalinu cirkulaciju koja je uvjetovana dotocima rijeka i stvaranjima gustih voda u Jadranu,
2. tokove jadranskih gustih vodenih masa i Levantinske intermedijarne vode, te
3. dekadsku termohalinu varijabilnost u Jadranu, kao i promjene uzrokovane Istočnosredozemnim tranzijentom.

Međutim, kvantitativna analiza ukazuje na brojna odstupanja simulacije od mjerenja. Salinitet je generalno precijenjen, posebice uz istočnu obalu Jadrana, zbog nepostojanja riječnih dotoka u modelu u području od Crne Gore do Tršćanskog zaljeva. Usporedbom s najnovijom riječnom klimatologijom za Jadran (Vilibić i sur., 2016) temeljenom na mjerenjima protoka 43 rijeke u razdoblju od 2008. do 2012. godine, simulacija MED8F podcijenjenuje riječne protoke za više od 95% na istočnoj obali, te za više od 40% na sjevernom dijelu Jadrana. Dodatno, ni jedan izvor slatke vode u simulaciji nije postavljen na zapadnoj obali, južno od ušća Po-a. Treba napomenuti da je pozitivno odstupanje saliniteta na Palagruškom pragu bilo prisutno već pri inicijalizaciji simulacije MED8F, u klimatologiji MEDAR/MedAtlas-II (MEDAR/MEDATLAS, 2002). Međutim, period prilagodbe (15 godina) je smanjio odstupanje, stoga su početni uvjeti samo djelomično zaslužni za precjenjivanje saliniteta u Jadranu. S druge strane, poznato je da su halini uvjeti na rubnim dijelovima Palagruškog praga također pod utjecajem dotoka slatke vode (Grbec i sur., 2007; Vilibić i sur., 2015), pa simulacija dodatno precijenjuje salinitet u tom području.

Jaka podcjenjivanja temperature u najdubljim dijelovima Jadrana, na postajama JK i D1200 smještenim u Jabučkoj i Južnojadranskoj kotlini, ukazuju na to da je ili stvaranje Sjeverojadranske vode podcijenjeno u simulaciji MED8F, ili da simulirane jadranske guste vodene mase imaju višu temperaturu nego li je to u stvarnosti. Atmosfersko forsiranje modelom ARPERA, zbog svoje grublje rezolucije (~ 50 km), nije u mogućnosti raspoznati visoku prostornu i vremensku varijabilnost površinskih protoka topline i vlage (Herrmann i sur., 2011), posebice u sjevernom Jadranu za vrijeme zimskih bura čija se prostorna varijabilnost zapaža na skali od svega nekoliko kilometara i manje (Grubišić, 2006; Dorman i sur., 2007; Grisogono i Belušić 2009; Davolio i sur., 2015). Još jedan bitan nedostatak modela MED8 je nepostojanje „mokrih“ točaka domene na obalnom području Kvarnerskog zaljeva, zbog čega su dodatno smanjene kumulativne vrijednosti zimskih površinskih gubitaka topline iz mora. Na tom području površinski gubici topline su najveći, i do nekoliko puta veći nego na otvorenom dijelu sjevernog Jadrana (Janeković i sur., 2014).

Dodatni nedostatak simulacije je podcjenjivanje stratifikacije u Južnojadranskoj kotlini, što ima za posljedicu vertikalno miješanje cijelog stupca mora tijekom izraženih epizoda duboke konvekcije, što nije zabilježeno u mjerenjima. To se podcjenjivanje javlja i zbog slabijih riječnih dotoka i zbog smanjene pridnene stratifikacije koja nastaje zbog manjeg dotoka Sjevernojadranske vode na dno kotline.

Simulacija MED8F reproducira dekadsku varijabilnost termohalinih svojstava, s duljim periodima promjenjivog režima strujanja i vodenih masa od opaženih, ali i podcjenjuje njihove međugodišnje varijabilnosti. Međutim, glavni mehanizam koji pokreće dekadsku varijabilnost u Jadranu, BiOS (Gačić i sur., 2010, 2014; Mihanović i sur., 2015), nije pravilno reproduciran u MED8F-u. Umjesto opaženih izmjenjujućih ciklonalnih i anticiklonalnih cirkulacija u sjevernom Jonskom moru, u simulaciji je dominantna ciklonalna cirkulacija s varijabilnim intenzitetom. Razlog tome može biti podcijenjen dotok vodenih masa iz zapadnog Sredozemnog mora (slika 9) u Jonsko more, što rezultira smanjenjenjem vodenog stupca zapadnog dijela Jonskog mora, a time i drugačijom geostrofičkom prilagodbom (Gačić i sur., 2010). Jedino zabilježeno razdoblje u MED8F-u u kojem se pojavljuje promjena cirkulacije u anticiklonalnu je od 1993. do 1995. godine, vjerojatno kao posljedica Istočnosredozemnog tranzijenta, ali sa sporijim prijelazom nego li je to zabilježeno (Mihanović i sur., 2015). Osim toga, sam oblik i položaj ciklonalne cirkulacije u simulaciji MED8F je drugačiji nego u stvarnosti - pomaknut prema zapadu uz veći prostorni obuhvat, gotovo do ruba Sicilijskog praga.

4. USPOREDBA SIMULACIJA NEMOMED U RAZDOBLJU 1980. - 2012.

U ovom poglavlju je testirana osjetljivost pojedinih obilježja modela na simulaciju termohalinih svojstava i cirkulacije jadransko-jonskog bazena. U tu svrhu napravljene su analize sedam različitih simulacija modelom NEMOMED (MED8F, MED8C1, MED8C2, MED8C3, MED12F1, MED12F2 i MED12F3). Simulacije se međusobno razlikuju u horizontalnoj i vertikalnoj rezoluciji, atmosferskim i riječnim forsiranjima, te obliku modela (spregnuti/nespregnuti). Detaljan opis razlika simulacija se nalazi u poglavlju 2.1.2.

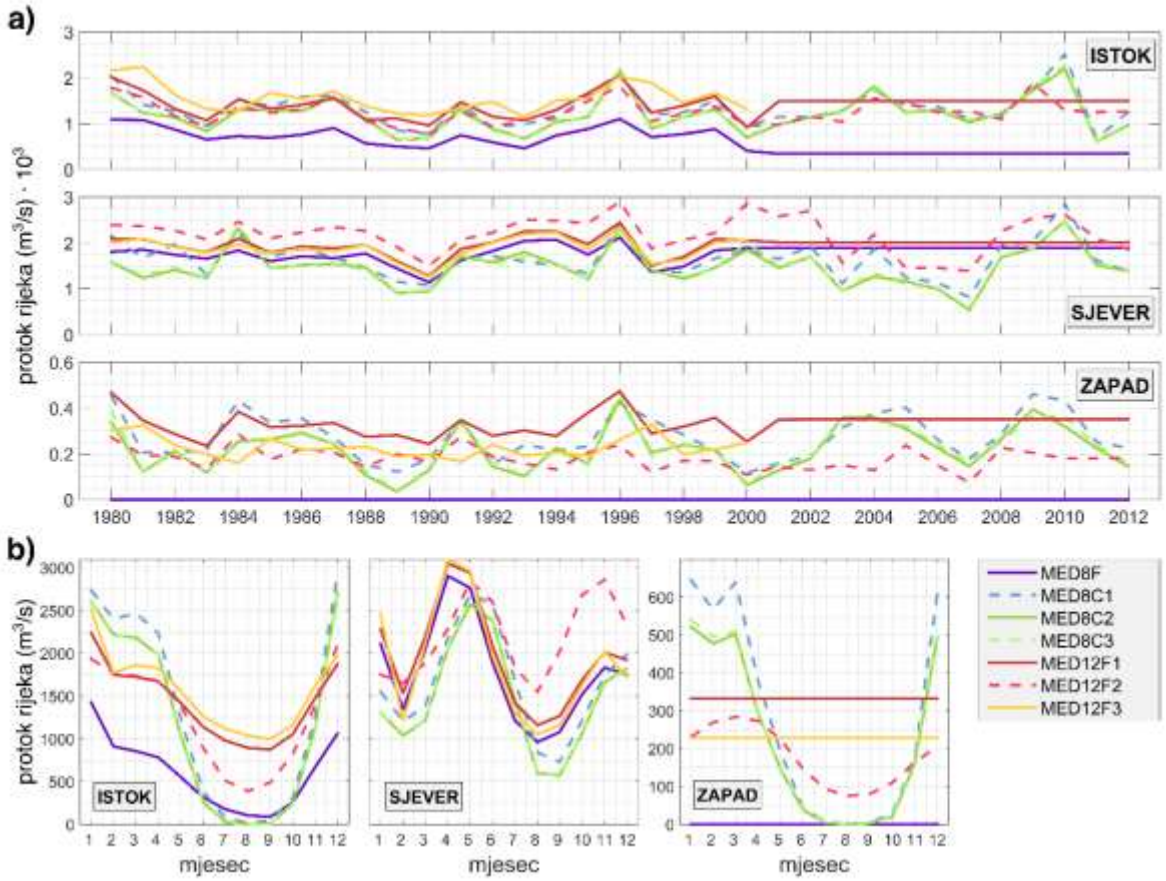
4.1. Analiza forsiranja riječnim dotocima

Dotok slatke vode putem rijeka značajno doprinosi ukupnoj bilanci vode u Jadranskom moru (Artegiani i sur., 1997a). Rijeke mijenjaju termohalina i dinamička svojstva Jadrana, što se posebice vidi u plitkom sjevernom dijelu (Kourafalou, 1999; Vilibić i sur., 2016). Raznolikost korištenih riječnih klimatologija je omogućila analizu utjecaja riječnih protoka na ponašanje modela u Jadranskom moru.

Dotok slatke vode u analiziranim simulacijama zasebno je procijenjen za tri područja Jadranskog mora (slika 7):

a) ISTOK – istočna obala označena žutom bojom,
b) SJEVER – sjeverna obala označena plavom bojom, te
c) ZAPAD – zapadna obala označena zelenom bojom.

Slika 25 prikazuje godišnje protoke rijeka u sedam simulacija, te njihove sezonske cikluse. Protoci rijeka se značajno razlikuju za pojedine modele, ovisno o dostupnosti podataka. Simulacija MED8F ima samo 8 riječnih ušća u Jadranskom moru uključenih u forsiranje, od kojih se 6 (Vjosa, Seman, Shkumbini, Erzen, Mat i Drin) nalaze na području ISTOK, te dvije (Adige i Po) na području SJEVER. Uz navedene rijeke, u riječnom forsiranju simulacija MED12F1 i MED12F3 je uključen i tzv. „obalni dotok“ (za dodatno objašnjenje vidi poglavlje 2.1.2.). S druge strane, podaci riječnog forsiranja u simulaciji MED12F2, posebno izrađeni za potrebe ovog rada, se temelje na najnovijoj klimatologiji riječnih protoka (Vilibić i sur., 2016). Sveukupno, u MED12F2-u na području ISTOK se nalazi 18, na području SJEVER 14, a na području ZAPAD 12 riječnih ušća.



Slika 25. Simulirane vrijednosti (a) srednjih godišnjih protoka rijeka i (b) njihov sezonski ciklus u tri područja u Jadranu, za sve analizirane simulacije.

U svim simulacijama, srednji godišnji protoci rijeka se kreću od 600 do 1560 m^3/s u području ISTOK, 1479 i 2192 m^3/s u području SJEVER, te između 0 i 333 m^3/s u području ZAPAD. Nakon 2001. godine, zbog nedostatka podataka, protoci rijeka u simulacijama MED8F, MED12F1 i MED12F3 nisu uključivali međugodišnju varijabilnost, već su zadani konstantnom vrijednošću iz 2001. godine, dok je sezonski ciklus procijenjen obzirom na srednji sezonski ciklus prijašnjih godina.

Gledajući zasebno tri područja (ISTOK, SJEVER i ZAPAD), međugodišnja varijabilnost i sezonski hod riječnih protoka u svim simulacijama su slični, dok se među pojedinim područjima razlikuju. Tako su na istočnom dijelu Jadrana (ISTOK) u svim simulacijama najniži protoci zabilježeni tijekom ljetnih mjeseci (lipanj, srpanj, kolovoz, rujan), dok se viši protoci odvijaju zimi (studeni, prosinac, siječanj, veljača). Najniže vrijednosti na istočnom dijelu (ISTOK) su nađene u MED8F-u, što je i očekivano, budući da ta simulacija broji svega 8 jadranskih rijeka (6 smještenih u području ISTOK). U usporedbi s najnovijom riječnom klimatologijom

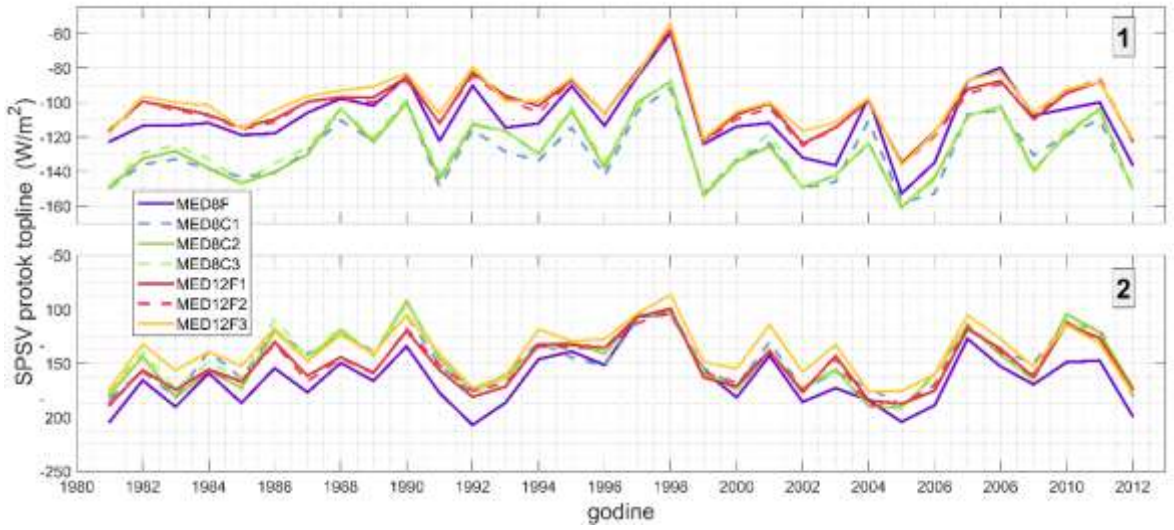
(simulacija MED12F2), simulacije spregnutih modela bilježe više vrijednosti protoka tijekom zimskih mjeseci (za oko 600 m^3/s) te niže u ljetnom periodu (riječni protoci su oko nule, što je za oko 500 m^3/s niže nego li u MED12F2).

Sezonski ciklus riječnih protoka na sjevernom Jadranu (područje SJEVER) se razlikuje od druga dva područja te je karakteriziran s dva minimuma i dva maksimuma tijekom godine. Prvi maksimum riječnih protoka na sjevernom Jadranu se pojavljuje u svibnju zbog otapanja snijega (Raicich, 1996; Vilibić i sur., 2016). Taj maksimum rani za oko jedan mjesec u simulacijama MED8F, MED12F1 i MED12F3 (slika 5), dok je u MED12F2 i simulacijama spregnutih modela pravovremeno reproduciran. Za ljetnog minimuma, sve simulacije znatno podcjenjuju riječne protoke u usporedbi s najnovijom klimatologijom (za oko 700 m^3/s). Isto vrijedi i za jesenski maksimum, koji se javlja zbog sezonskog maksimuma oborina (Raicich, 1996). Zimski minimum (veljača/ožujak) je viši za oko 400 m^3/s u svim simulacijama u odnosu na MED12F2. U prosjeku, godišnji protoci rijeka u sjevernom Jadranu su najviši u simulaciji MED12F2, dok su najniži protoci zabilježeni u simulacijama spregnutih modela. U svim simulacijama, najniži protoci rijeka su na zapadnoj strani Jadrana (ZAPAD). Simulacija MED8F ne bilježi dotok slatke vode, budući da u području ZAPAD nema riječnih ušća. S druge strane, MED12F1 i MED12F3 ne prikazuju sezonski ciklus, jer „obalni dotok“ predstavljen u tim simulacijama ima uključenu samo međugodišnju varijabilnost. U ostalim simulacijama, slično kao i u području ISTOK, pojačan dotok svježe vode je zabilježen tijekom zimskog perioda. U odnosu na MED12F2, simulacije spregnutih modela precjenjuju protoke za oko 250 m^3/s. U ljetnom periodu, riječni protoci u simulacijama spregnutih modela su blizu nule, što je za oko 100 m^3/s niže nego li je to slučaj kod MED12F2.

4.2. Analiza površinskih protoka topline u zimskom razdoblju

Izraženi zimski gubici topline s površine mora pokreću stvaranje jadranskih gustih voda, a time utječu i na jadransko-jonsku termohalinu cirkulaciju (Orlić i sur., 2006; Somot i sur., 2006). Stoga su protoci topline procijenjeni za dva područja Jadrana gdje se odvijaju ti procesi (područje 1 i 2 na slici 7), te usrednjeni za razdoblje SPSV, čime se za danu godinu obuhvatilo tzv. razdoblje stvaranje preduvjeta (studeni - prosinac) i razdbolje stvaranja guste vode (siječanj - veljača). Kao i prije, razdoblje SPSV za određenu godinu je definirano sa studenim i prosincem prethodne godine te siječnjom i veljačom tekuće godine.

Sve simulacije daju sličnu međugodišnju varijabilnost toplinskih protoka, posebice na južnom dijelu Jadrana (slika 26). Na jugu sve simulacije bilježe veće gubitke topline u odnosu na sjeverni dio, od kojih MED8F pokazuje najveće gubitke (u prosjeku 55.5 W/m^2 niže vrijednosti protoka topline). Razlog tome može biti veći kontrast temperature zraka i temperature površine mora u zimskom periodu (od prosinca do veljače) u južnom u odnosu na sjeverni Jadran (Artegiani i sur., 1997a). Na sjevernom dijelu Jadrana protoci topline su za oko 20 - 30% viši u simulacijama spregnutih modela u odnosu na simulacije nespregnutih modela.



Slika 26. Simulirani protoci topline na površini mora usrednjeni za zimsko razdoblje (SPSV) nad područjima 1 i 2 označenima na slici 7.

Prosječni zimski protoci topline nad cijelim Jadranom u razdoblju od 1980. do 2012. godine redom iznose -161, -155, -155, -154, -146, -146 i -130 W/m^2 za simulacije MED8F, MED8C1, MED8C2, MED8C3, MED12F1, MED12F2 i MED12F3, što je u skladu s dosadašnjim istraživanjima. Starija klimatologija daje procjenu zimskih protoka topline od -173 W/m^2 (May, 1982), dok novija istraživanja temeljena na reanalizi ERA-40 procjenjuju zimske gubitke topline od -133 do -165 W/m^2, ovisno o korištenoj metodologiji (Cardin i Gačić, 2003). Međutim, treba napomenuti da su navedene usporedbe ograničene, zbog različitosti skupova podataka, prostornih domena, metodologija i razdoblja u navedenim klimatologijama i analiziranim simulacijama. Bez obzira na to, možemo zaključiti da su simulirani protoci topline u intervalu prijašnjih procjena, pri čemu MED8F, forsirana modelom ARPERA, daje jače gubitke topline, a MED12F1-F3, forsirani modelom ALDERA, daju slabije gubitke topline.

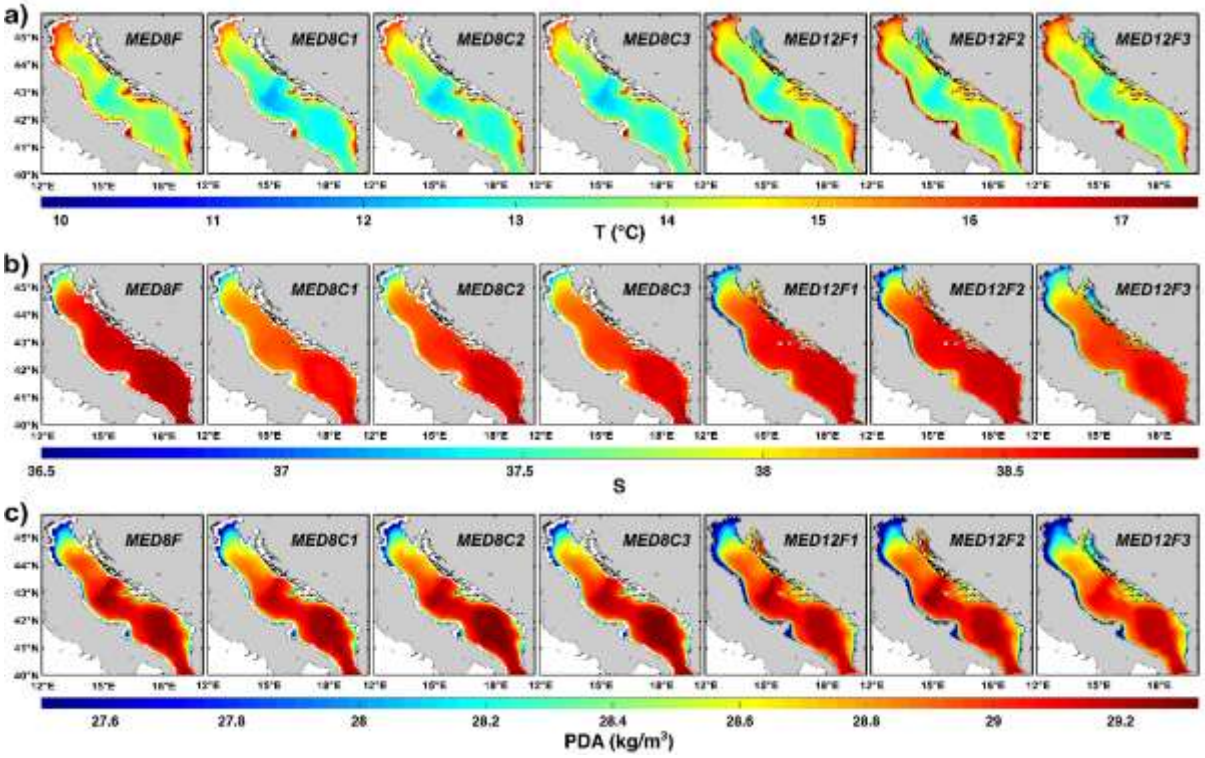
4.3. Analiza srednjih termohalinih polja

Prostorna razdioba polja pridnenih temperatura, saliniteta i gustoće u Jadranskom moru, usrednjenih u razdoblju 1980. - 2012., je slična kod svih analiziranih simulacija (slika 27). Niti jedna od analiziranih simulacija ne ukazuje na sjeverni Jadran kao područje stvaranja guste vode, budući da su srednje pridnene gustoće sjevernog Jadrana najniže u usporedbi s ostatkom Jadrana. To je i očekivano, obzirom na kratko vrijeme zadržavanja Sjevernojadranske vode na tom području. Naime, nakon stvaranja, Sjevernojadranska voda u samo nekoliko desetaka dana biva advektirana prema srednjem i južnom Jadranu (Mihanović i sur., 2013). Za precizniju predodžbu simuliranog stvaranja guste vode u sjevernom Jadranu, napravljene su detaljne analize (vidi poglavlje 4.5.1.1.), fokusirajući se na razdoblje samog događaja.

Najniže temperature praćene visokim gustoćama, se nalaze na dnu Jabučke kotline, što je posebno izraženo u simulacijama spregnutih modela (MED8C1 - C3), gdje su prosječne temperature 12.5 ^{o}C i gustoće 29.2 kg/m^3. Isto vrijedi i za Južnojadransku kotlinu, s nešto višim prosječnim temperaturama (14 ^{o}C) i nižim prosječnim gustoćama (28.9 kg/m^3) nego na dnu Jabučke kotline. Obje kotline predstavljaju kolektore jadranskih gustih (Artegiani i sur., 1997a; Vilibić i Supić, 2005), pa su stoga takve razdiobe i očekivane. Vodene mase u sjeveroistočnim obalnim područjima su reproducirane samo kod simulacija viših prostornih rezolucija (modeli MED12F). To je područje dublje od otvorenog sjevernog Jadranskog mora, i tek je nedavno prepoznato kao sekundarno područje stvaranja sjevernojadranskih gustih vodenih masa (Mihanović i sur., 2013). Tu se gusta vodena masa stvara pod utjecajem snažnih zimskih prodora bure koje uzrokuju iznimno visoke gubitke topline mora (do 2000 W/m^2, Janeković i sur., 2014). Simulirane pridnene temperature u trima simulacijama modela MED12F u sjeveroistočnom obalnom području su u prosjeku za 1 - 2 ^{o}C niže nego na otvorenom moru. Simulacija MED12F3 daje iznimno nizak pridneni salinitet (~ 37.3) u tom području, zbog previsokih dotoka slatkih riječnih voda, čime je onemogućeno stvaranje guste vode (pridnena gustoća je niža od 28.3 kg/m^3). S druge strane, MED12F1 - F2 obilježavaju sjeveroistočno obalno područje kao područje stvaranja iznimno gustih vodenih masa.

Razlike među simulacijama su vidljive i u prostorno usrednjenim vrijednostima pridnenih polja. Simulacija MED8F je karakterizirana najvećom pridnenom temperaturom (14.7 ^{o}C), ali i izrazito visokim salinitetom (38.5), u konačnici rezultirajući najvećom gustoćom (28.7 kg/m^3). Simulacije spregnutih modela rezultiraju sličnim vrijednostima gustoće, s temperaturama

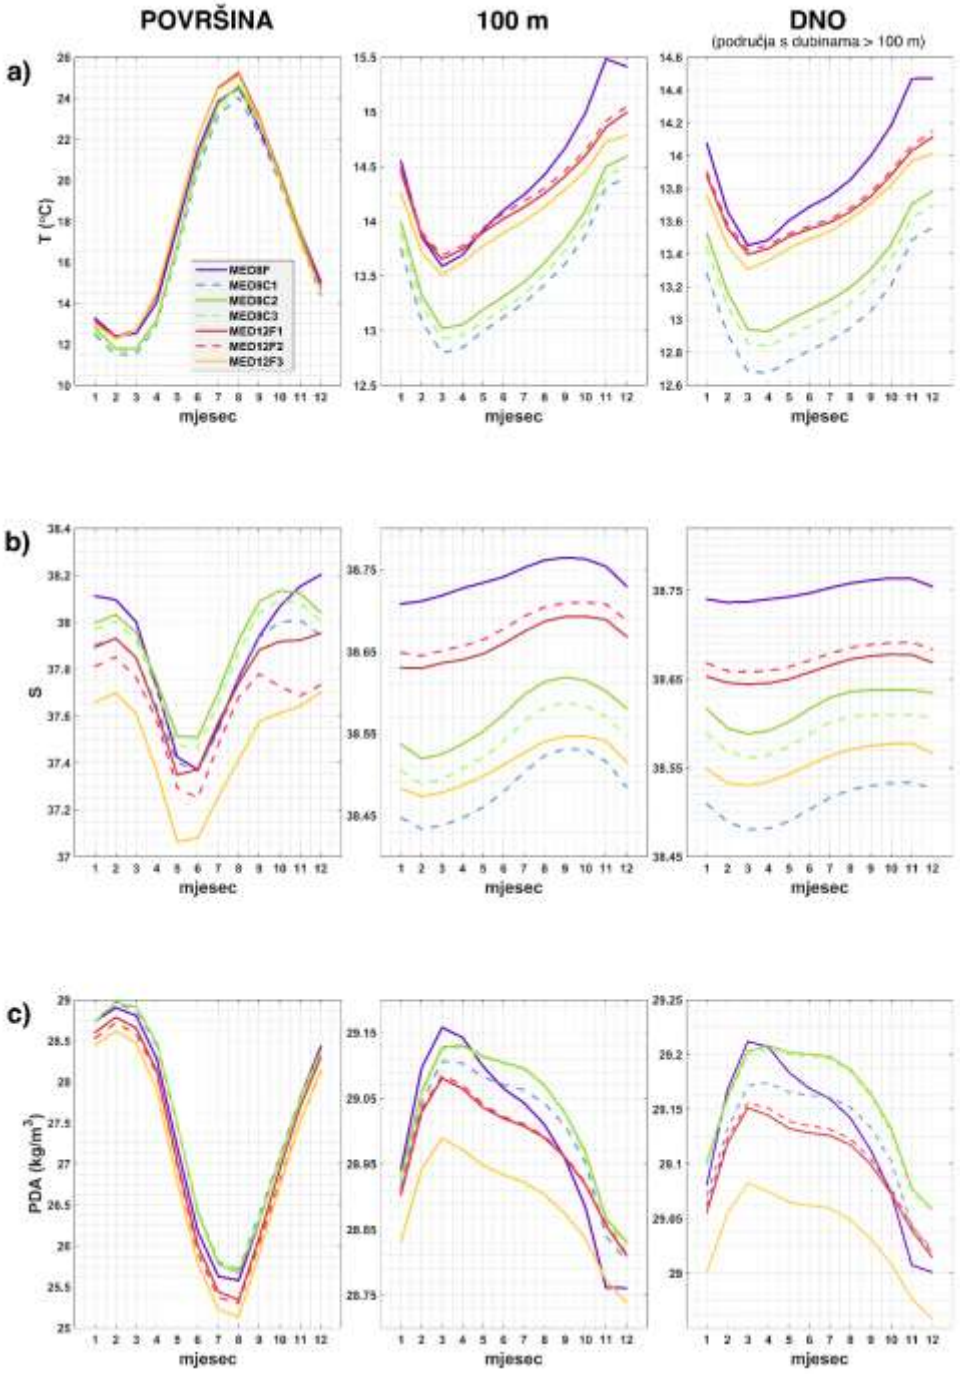
između 13.9 ºC i 14.2 ºC i salinitetom između 38.2 i 38.3. U usporedbi s MED8F, tri simulacije modela MED12 (MED12F1 - F3) reproduciraju niže temperature (14.5 ºC) od ostalih simulacija. Salinitet je nešto viši u MED12F1 - F2 u usporedbi sa simulacijama spregnutih modela (38.3). Najniži salinitet je nađen u MED12F3 (38.1), što rezultira najnižom prosječnom gustoćom pridnenih voda (28.5 kg/m^3). Prosječna pridnena gustoća u simulacijama MED12F1 - F2 iznosi 28.6 kg/m^3.



Slika 27. Usrednjena polja pridnenih (a) temperatura, (b) saliniteta i (c) anomalija potencijalnih gustoća u Jadranskom moru za razdoblje 1980. - 2012, za sve simulacije.

Nadalje, napravljena je analiza srednjeg godišnjeg hoda simuliranih temperatura, saliniteta i gustoće čitavog Jadranskog mora, posebno na površini, 100 m dubine, te na dnu mora (slika 28). Za procjenu vrijednosti na dnu mora su uzete samo one točke domene modela kojima je dubina veća od 100 m, čime su izbjegnuta plitka područja Jadrana. Amplituda godišnjeg hoda je slična u svim simulacijama te na svim slojevima, s vidljivim razlikama srednjih vrijednosti. Očekivano, temperaturni maksimum na površini mora se pojavljuje u ljetnom, dok su najniže vrijednosti zabilježene u zimskom razdoblju (slika 28a). U intermedijarnom sloju (100 m) maksimum temperature se javlja u kasnu jesen (studeni -

prosinac), ukazujući na to da je vertikalno miješanje dovoljno jako da dopre do te dubine. Kod simulacija spregnutih modela zamjećuju se niže temperature duž vodenog stupca tokom cijele godine (za 0.5 - 1.0 ^{o}C), najviše izražene u razdoblju veljača - travanj, dok su početkom zime razlike manje (listopad - prosinac). To je vjerojatno posljedica nižih vrijednosti kratkovalnog zračenja i prijenosa latentne topline na površinu mora, te stoga i nižih vrijednosti protoka topline u simulacijama spregnutih modela (Sevault i sur., 2014).

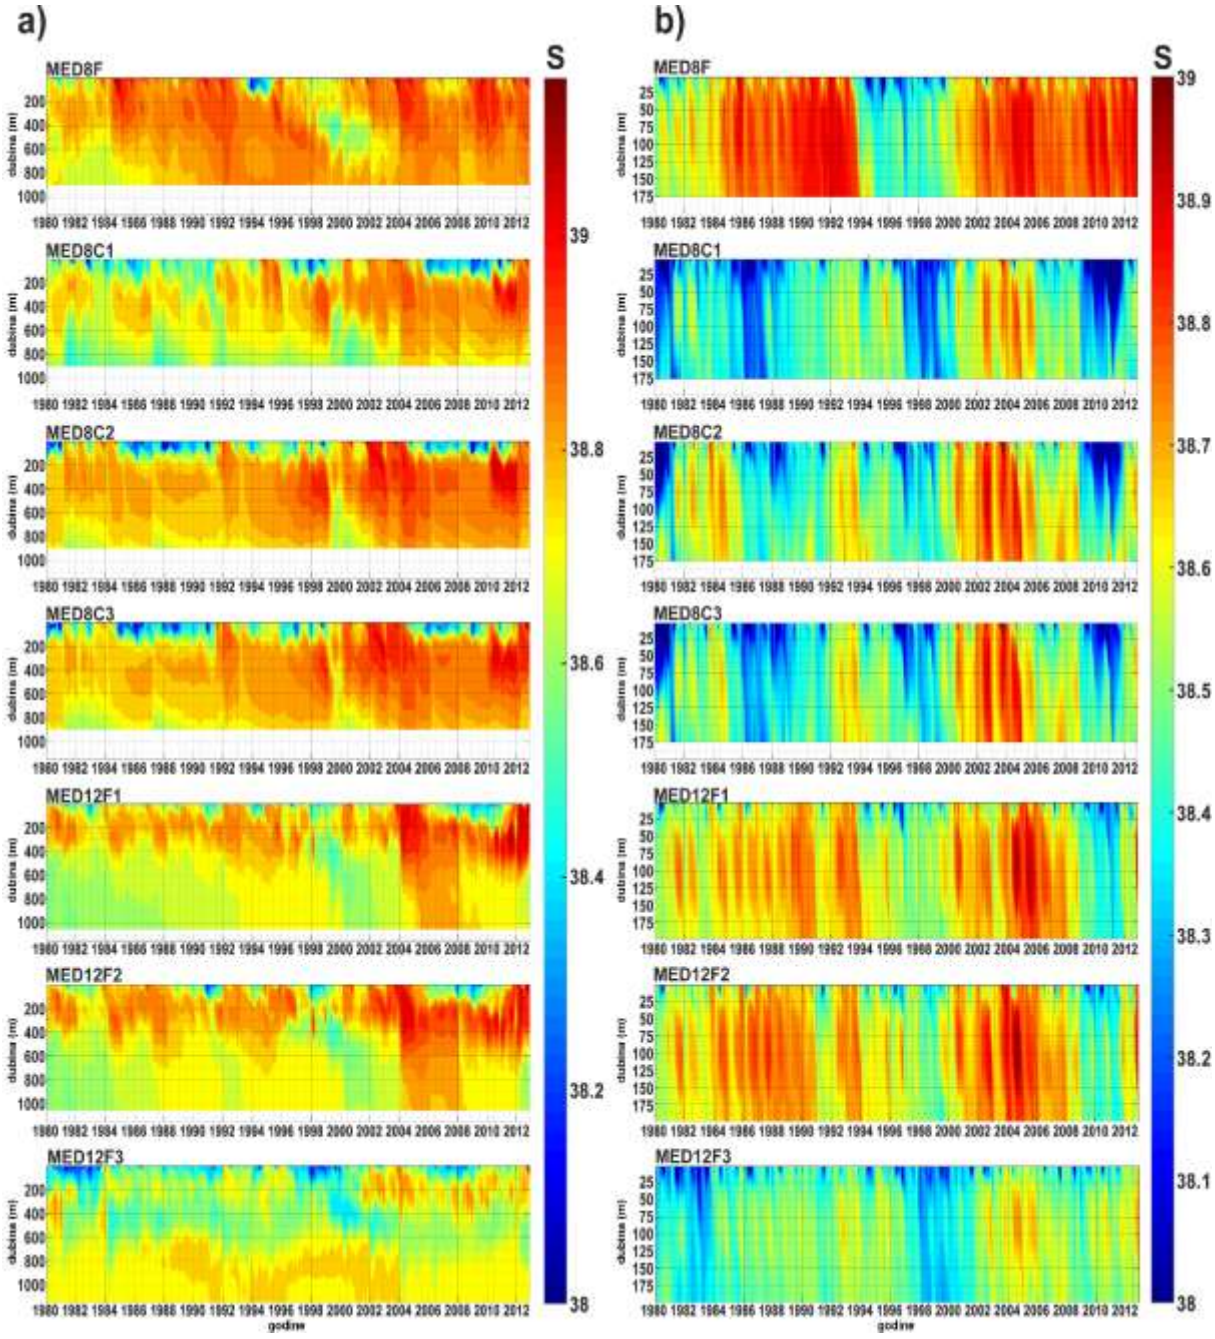


Slika 28. Sezonski hod (a) temperature, (b) saliniteta i (c) anomalije potencijalne gustoće u Jadranskom moru na površini, dubini od 100 m i dnu (usrednjen preko područja s dubinama > 100 m), za različite simulacije. Na y-osima su prikazane različite skale za pojedini parametar.

Kod saliniteta, razlike među simulacijama su izraženije, već na samoj površini (slika 28b). Najviše vrijednosti saliniteta se javljaju kod simulacije MED8F (prosječni raspon saliniteta između 37.9 na površini i 38.7 na 100 m). Suprotno, simulacija karakterizirana konzistentno niskim salinitetom je MED12F3 (prosječan salinitet na površini i na 100 m je oko

37.5). Simulacije spregnutih modela daju: (i) viši površinski salinitet (prosjek između 37.8 i 37.9) u odnosnu na MED12F1 - F2 (prosjek između 37.6 i 37.8), (ii) niži salinitet na 100 m dubine (prosjek između 38.5 i 38.6) u odnosu na MED12F1 - F2 (prosjek od 38.7), te (iii) slične vrijednosti pridnenog saliniteta kao i kod MED12F1 - F2. Promjene po vertikali su izraženije kod simulacija nespregnutih modela. Npr. promjena saliniteta u MED8C2 između površine mora i 100 m je nešto niža od 0.5, dok je kod MED12F2 ta promjena viša od 0.8. Kod svih simulacija najniži površinski salinitet se pojavljuje u proljetnom razdoblju (svibanj - lipanj), kasneći oko jedan mjesec nakon maksimuma protoka rijeka koji se najčešće pojavljuje u razdoblju travanj - svibanj (Raicich, 1996; Vilibić i sur., 2016). Tada se manje slana voda rasprostire iznad stratificiranog vodenog stupca, što je posebice uočeno u plitkom sjevernom Jadranu (Franco i Michelato, 1992; Supić i sur., 2004). Salinitet u srednjem sloju (100 m) počinje rasti u veljači - ožujku, sve do kolovoza - listopada kad doseže svoj vrhunac. U tom razdoblju je, zbog prethodnog stvaranja guste vode u Jadranu, jadranska termohalina cirkulacija osnažena čime je pojačana advekcija vode višeg saliniteta iz sjevernog Jonskog mora (Orlić i sur., 2006). Razlike između srednjih simuliranih saliniteta na dnu mora prate razlike onih na 100 m, s najvišom razlikom nađenom u simulacijama MED8F i MED12F3 (oko 0.4).

Kroz cijeli vodeni stupac, gustoće u Jadranskom moru su najveće u simulacijama spregnutih modela (MED8C1 - C3), te u MED8F (prosjek oko 28.4 kg/m^3). Modeli MED12F su karakterizirani nižim gustoćama, s najnižom vrijednosti nađenom u MED12F3 (prosjek od 28.1 kg/m^3). U svim simulacijama zimski period, relevantan za proces stvaranja jadranskih gustih voda, karakteriziraju najviše gustoće, od 28.3 kg/m^3 u MED12F3, do 29.2 kg/m^3 u MED8F i MED8C1 - C3. U svim slojevima sezonski ciklus gustoće zrcalno prati temperaturne promjene (slika 28c). Najgušća voda u srednjim i dubokim slojevima se javlja u ožujku, najviše uzrokovana temperaturnim minimumom, budući da tada duboka konvekcija nadmašuje 100 m dubine u većem dijelu Jadrana. Iako su sezonske promjene u gustoći najviše uzrokovane promjenama temperature, sveukupna promjena gustoće ovisi i o sezonskom ciklusu saliniteta.



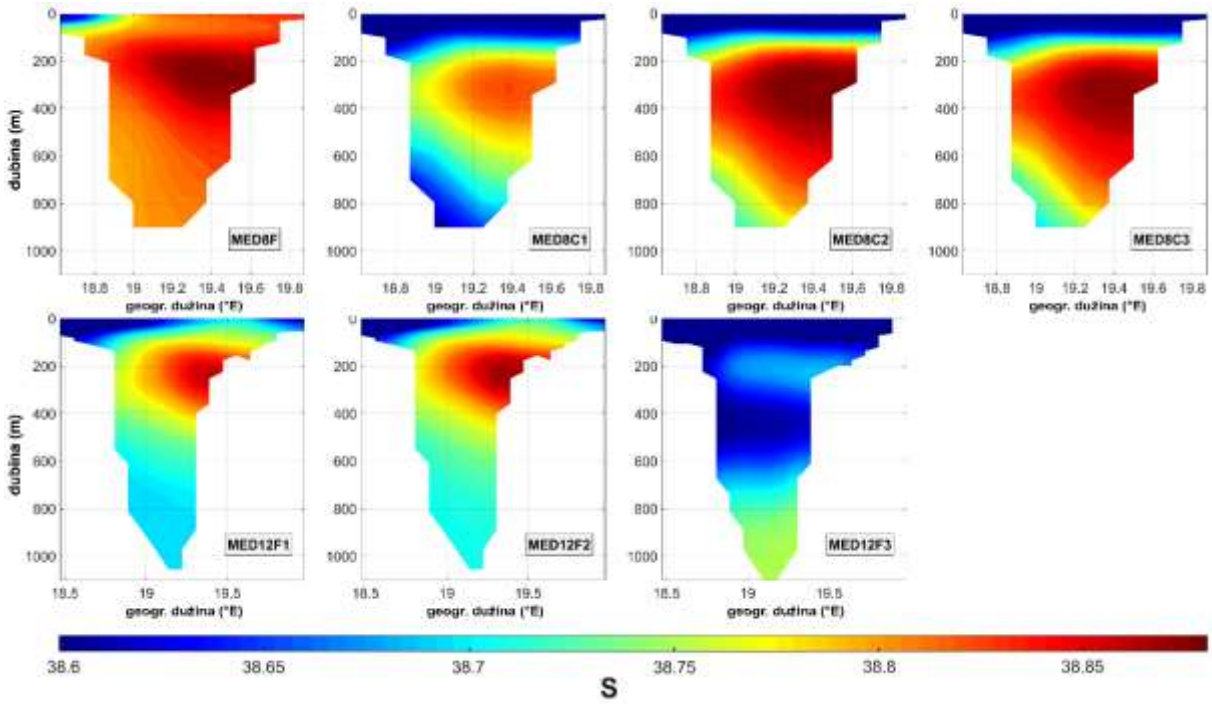
Slika 29. Hovmöller dijagrami (a) zonalno usrednjenog saliniteta na istočnoj strani Otrantskih vrata i (b) saliniteta na postaji PS3 (Palagruški prag), za različite simulacije. Na slici su prikazane mjesečne vrijednosti saliniteta.

Da bi se procijenila sposobnost pojedinih simulacija da reproduciraju advekciju Levantinske intermedijarne vode u Jadran, analizirani su vremenski nizovi saliniteta na istočnoj strani transekta u Otrantskim vratima (slika 29a). Pri tome je uzeta prosječna vrijednost saliniteta uzduž 40 ^{o}N, između 19.1 ^{o}E i 19.9 ^{o}E. Hovmöller dijagrami posebno ističu simulacije MED8F i MED12F3, gdje prva reproducira izrazito visoki (prosjek od 38.9), a druga izrazito niski salinitet (prosjek od 38.6) na istočnoj strani Otranta. Simulacije spregnutih modela, posebice MED8C2 i MED8C3, općenito reproduciraju viši salinitet od simulacija nespregnutih modela (osim MED8F). Većina simulacija daje razdoblja povećanog saliniteta u gotovo cijelom vodenom stupcu. Simulacija MED8F reproducira dva duža razdoblja povećanog saliniteta, tijekom razdoblja 1984. - 1993. te između 2002. - 2012. U spregnutim modelima pojačan dotok vode visokog saliniteta se javlja između 1996. i 2000., te između 2002. i 2012. godine. Simulacije MED12F1 - F2 prikazuju gotovo identičnu međugodišnju varijabilnost, sa samo jednim razdobljem povećanog saliniteta, između 2005. i 2008. godine. Naposljetku, MED12F3 ne bilježi ni jedno razdoblje izraženijeg dotoka Levantinske intermedijarne vodene mase kroz čitavi vodeni stupac.

Prijašnja istraživanja temeljena na mjerenjima opažaju jezgru utjecanja Levantinske intermedijarne vode između 150 i 400 m (Gačić i sur., 1996; Malanotte-Rizzoli i sur., 1997; Kršinić i Grbec, 2002; Manca i sur., 2002), dok je u numeričkim analizama utjecanje procijenjeno nešto dublje, između 150 i 600 m (Oddo i Guarnieri, 2011; Gunduz i sur., 2013; Mantziafou i Lascaratos, 2004). Ovdje, utjecanje Levantinske intermedijarne vode se javlja na većim dubinama u modelu MED8 (u prosjeku između 200 i 600 m dubine, s vrijednostima saliniteta višim od 38.7), dok je kod modela MED12 jezgra utjecanja plića (u prosjeku između 50 i 400 m dubine, sa salinitetom višim od 38.8). Iznimka je MED12F3, u kojoj se veoma slabo utjecanje Levantinske intermedijarne vode uočava na 200 m dubine. Zanimljivo je zamijetiti maksimum saliniteta koji se javlja u dubokim slojevima transekta (ispod 700 m) u MED12F3, koji nije zabilježen u ni jednoj od ostalih analiziranih simulacija.

Palagruški prag je područje kroz koji Levantinska intermedijarna voda prolazi prema srednjem i sjevernom Jadranu (Buljan i Zore-Armanda, 1976; Martin i sur., 2009). Slika 29b prikazuje Hovmöllerov dijagram najdubljeg dijela palagruškog transekta (postaja PS3 s dubinom iznad 175 m), na kojem se uočava utjecanje Levantinske intermedijarne vode u vidu povećanog saliniteta. Sve simulacije bilježe jaku međugodišnju i dekadsku varijabilnost saliniteta. Kao i prije, simulacija MED8F je karakterizirana najvišim salinitetom (prosjek od 38.7), a MED12F3 s najnižim salinitetom (prosjek od 38.4). Simulacije nespregnutih modela

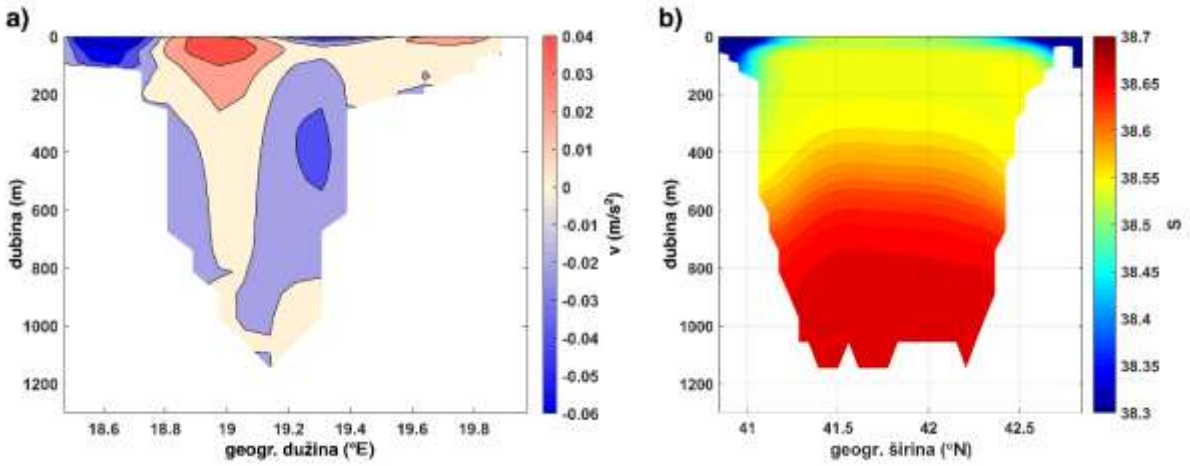
(MED12F1 - F2) reproduciraju nešto više salinitete (prosjek od 38.6) od simulacija spregnutih modela (prosjek između 38.4 - 38.5). Sukladno promjenama opaženim u Otrantskim vratima, i ovdje većina simulacija otkriva razdbolje povišenog saliniteta, i to: (i) u MED8F se javljaju dva duga razdoblja visokog saliniteta na Palagruškom pragu, jedan između 1984. i 1992. godine, a drugi između 2002. i 2012. godine, (ii) kod simulacija spregnutih modela povećani salinitet se javlja tijekom 1984., između 1992. - 1994. te u razdoblju 2000. - 2006., i (iii) MED12F1 - F2 bilježe dva razdoblja visokog saliniteta, između 1984. - 1994., te od 2000. do 2008. godine.



Slika 30. Vertikalni presjeci saliniteta u Otrantskim vratima (40 °N), usrednjenih za razdoblje 1980. - 2012., za sve simulacije.

Da bi se bolje razumjelo ponašanje simulacija u smislu reproduciranja ingresija Levantinske intermedijarne vode, a posebice ponašanje simulacije MED12F3 koja daje izrazito niske vrijednosti saliniteta u cijelom Jadranu, izračunata je vremenski usrednjena razdioba saliniteta uzduž transekta u Otrantskim vratima, smještenog na 40 °N (slika 30). Simulacije s nižom prostornom rezolucijom modela (MED8F, MED8C1 - C3) reproduciraju jezgru utjecanja Levantinske intermedijarne vode u dubljim slojevima (300 - 350 m) nego li simulacije s višom prostornom rezolucijom (MED12F1 - F3, 200 - 250 m). Nadalje, ulaz Levantinske intermedijarne vode se odvija u širem sloju (do 800 m dubine) u simulacijama modelom MED8,

dok se u simulacijama modelom MED12 taj sloj prostire samo do oko 400 m. Sve simulacije daju maksimum saliniteta na istočnoj strani transekta, što je u skladu s mjerenjima. Na zapadnoj strani u dubokom dijelu transekta vidljivo je područje nižeg saliniteta koje ukazuje na istjecanje jadranskih dubokih vodenih masa, poglavito Južnoadranske vode. Jedina simulacija koja se vidljivo razlikuje od ostalih je MED12F3, čiji se maksimum saliniteta nalazi u dubokim dijelovima cijelog transekta. Ta simulacija reproducira i izuzetno slabo utjecanje Levantinske intermedijarne vode na dubinama oko 200 m. Uz to, MED12F3 reproducira veoma slabe ulazne struje u Otrantskim vratima (slika 31a), kao i istjecanje jadranskih dubokih gustih vodenih masa, uz zapadnu ali i uz istočnu obalu. Razdioba saliniteta u Južnojadranskoj kotlini (slika 31b) daje maksimume u dubokom dijelu (> 600 m), što ukazuje da Levantinska intermedijarna vode u simulaciji tone na dno kotline. Posljedice toga su: (i) ograničen proces duboke konvekcije i stvaranja Južnojadranske vode, s veoma plitkom maksimalnom dubinom miješanja (vidi poglavlje 4.5.1.2.), (ii) snižena gustoća simuliranih jadranskih dubokih vodenih masa zbog iznimno niskog saliniteta koji je uzrokovan nedostatkom advekcije Levantinske intermedijarne vode tijekom cijelog razdoblja simulacije, (iii) veoma slab tok jadranskih dubokih vodenih masa prema Otrantu i Jonskom moru te (iv) nepostojanje značajne termohaline cirkulacije. Zaključno, MED12F3 pokazuje značajno odstupanje pri reprodukciji jadransko-jonske termohaline cirkulacije, uključujući i režime BiOS-a uočene u sjevernom Jonskom moru (vidi poglavlje 4.5.2.).



Slika 31.Vertikalni presjeci (a) morskih struja u Otrantskim vratima (40 °N, pozitivne prijednosti označavaju struju prema sjeveru), i (b) saliniteta na poprečnom transektu u južnom Jadranu na 17.5 °E geografske dužine, usrednjenih u razdoblju 1980. - 2012., za simulaciju MED12F3.

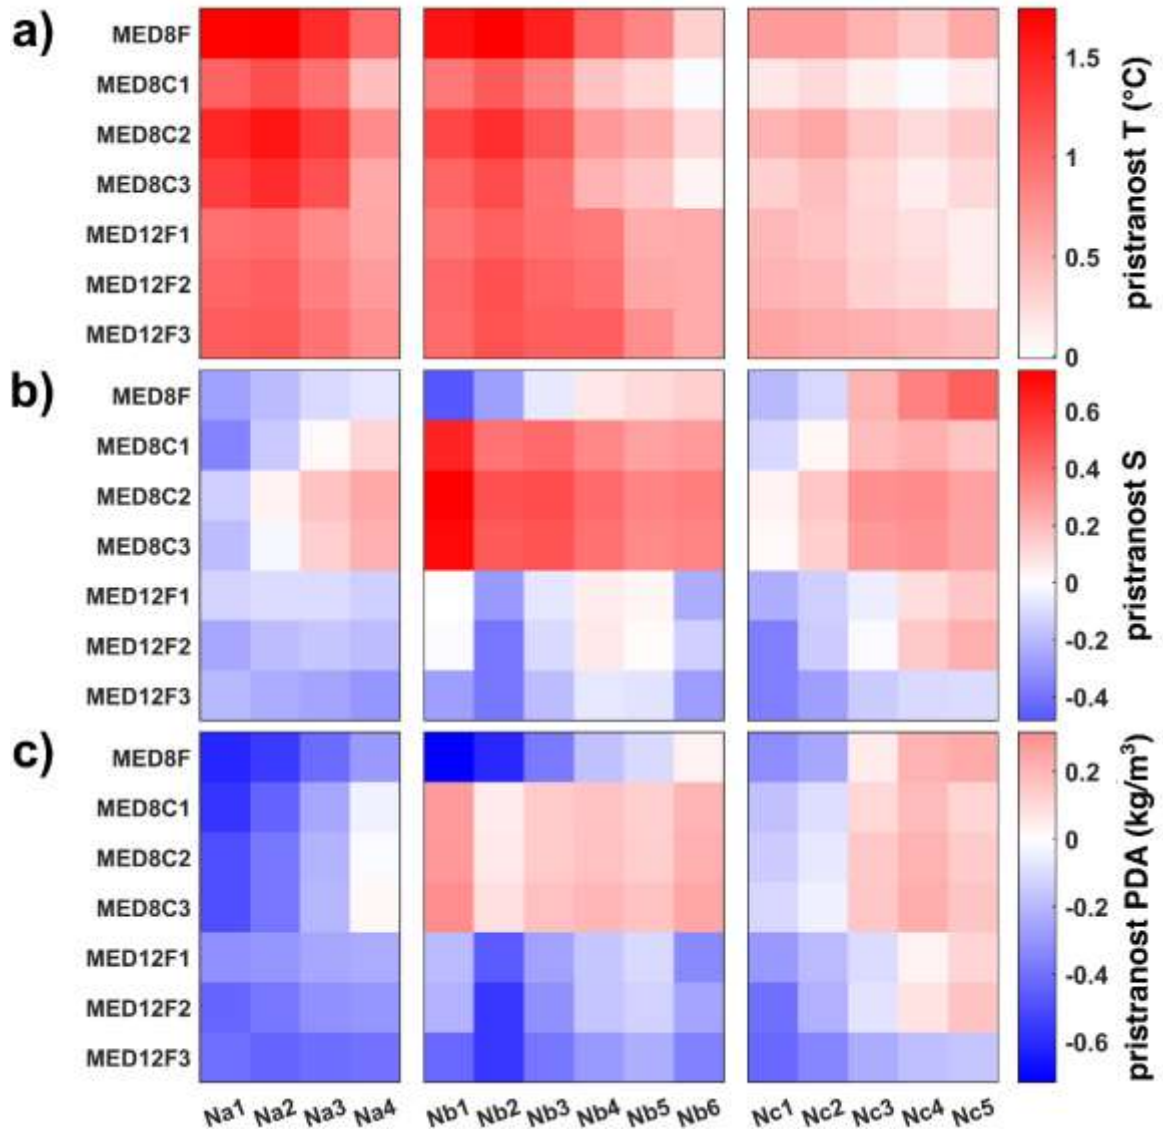
4.4. Validacija simulacija NEMOMED pomoću mjerenja temperature i saliniteta

U ovom poglavlju je napravljena validacija sedam simulacija (MED8F, MED8C1 - C3, MED12F1 - F3) pomoću dugoročnih *in situ* podataka temperature i saliniteta prikupljenih na nekoliko lokacija u Jadranskom moru (vidi poglavlje 2.4.1.).

4.4.1. Sjeverni Jadran

Za evaluaciju simulacija korišteni su podaci temperature i saliniteta prikupljenih na tri sjeverno-jadranska transekta (Na, Nb i Nc, slika 7), koji predstavljaju sjeverni, središnji i istočni dio tog područja. Postaje na poprečnim transektima Na i Nb su numerirane prateći smjer od zapada prema istoku, a na uzdužnom transektu Nc u smjeru od sjevera prema jugu.

Slika 32 prikazuje vertikalno usrednjene vrijednosti pristranosti temperature, saliniteta i anomalija potencijalne gustoće (*PDA*) za sva tri transekta. Temperatura je precijenjena u svim simulacijama, najviše u simulaciji MED8F (prosječna pristranost od 1.1 ^{o}C), a najmanje u simulaciji MED8C1 (prosječno odstupanje od 0.5 ^{o}C). Precjenjivanje temperature u svim simulacijama je najistaknutije u zapadnom (početak Na i Nb transekta) i sjevernom (transekt Na) dijelu, dok su nešto niža podcjenjivanja nađena na istočnom dijelu sjevernog Jadrana, u blizini istarske obale (transekt Nc). Termoklina gotovo doseže dno na zapadnom i najsjevernijem dijelu ovog područja, što nije opaženo u mjerenjima (npr. Supić i sur., 2004). Moguć razlog tome je nedovoljna vertikalna rezolucija u NEMOMED modelima (vidi poglavlje 2.1.1.), gdje model MED8 ima svega 5 - 6, a MED12 14 - 16 vertikalnih slojeva.



Slika 32. Vertikalno usrednjene vrijednosti pristranosti simulacija u odnosu na mjerenja za (a) temperaturu, (b) salinitet i (c) anomaliju potencijalne gustoće, nad transektima Na, Nb i Nc smještenih u sjevernom Jadranu. Procjena pristranosti je napravljena nad dnevnim vrijednostima uzimajući u obzir samo dane kad su vršena mjerenja.

U većem dijelu sjevernog Jadrana, salinitet je podcijenjen u svim simulacijama nespregnutih modela. Iznimka je sjeveroistočni dio gdje je salinitet precijenjen (transekt Nc), osim u simulaciji MED12F3 koja očekivano podcjenjuje salinitet na svim postajama. S druge strane, simulacije spregnutih modela u sjevernom Jadranu precjenjuju salinitet, osim na najsjevernijem dijelu (postaje Na1, Na2, i djelomično Nc1). Najviše precijenjivanje saliniteta je nađeno na postaji Nb1, smještenoj ispred delte rijeke Po, što ukazuje na to da dotok slatke vode iz rijeke Po nije pravilno reproduciran modelom TRIP.

U simulacijama nespregnutih modela precjenjivanje temperature zajedno s podcijenjenim salinitetom dovodi do snažnog podcjenjivanja gustoće, posebno istaknuto na središnjem i najsjevernijem dijelu sjevernog Jadrana, gdje pristranosti dosežu vrijednosti niže od -0.6 kg/m^3. Jedino područje gdje simulacije nespregnutih modela blago precjenjuju gustoću je južni dio transekta Nc (postaje Nc3 - Nc5), budući da je na tom području zabilježen previsoki salinitet. U simulacijama spregnutih modela gustoća je blago precijenjena u južnom i istočnom dijelu sjevernog Jadrana (transekt Nb i južni dio transekta Nc, za 0.1 - 0.2 kg/m^3), dok je u ostalim dijelovima sjevernog Jadrana podcijenjena (najviše odstupanje od oko -0.4 kg/m^3 je nađeno na postaji Na1).

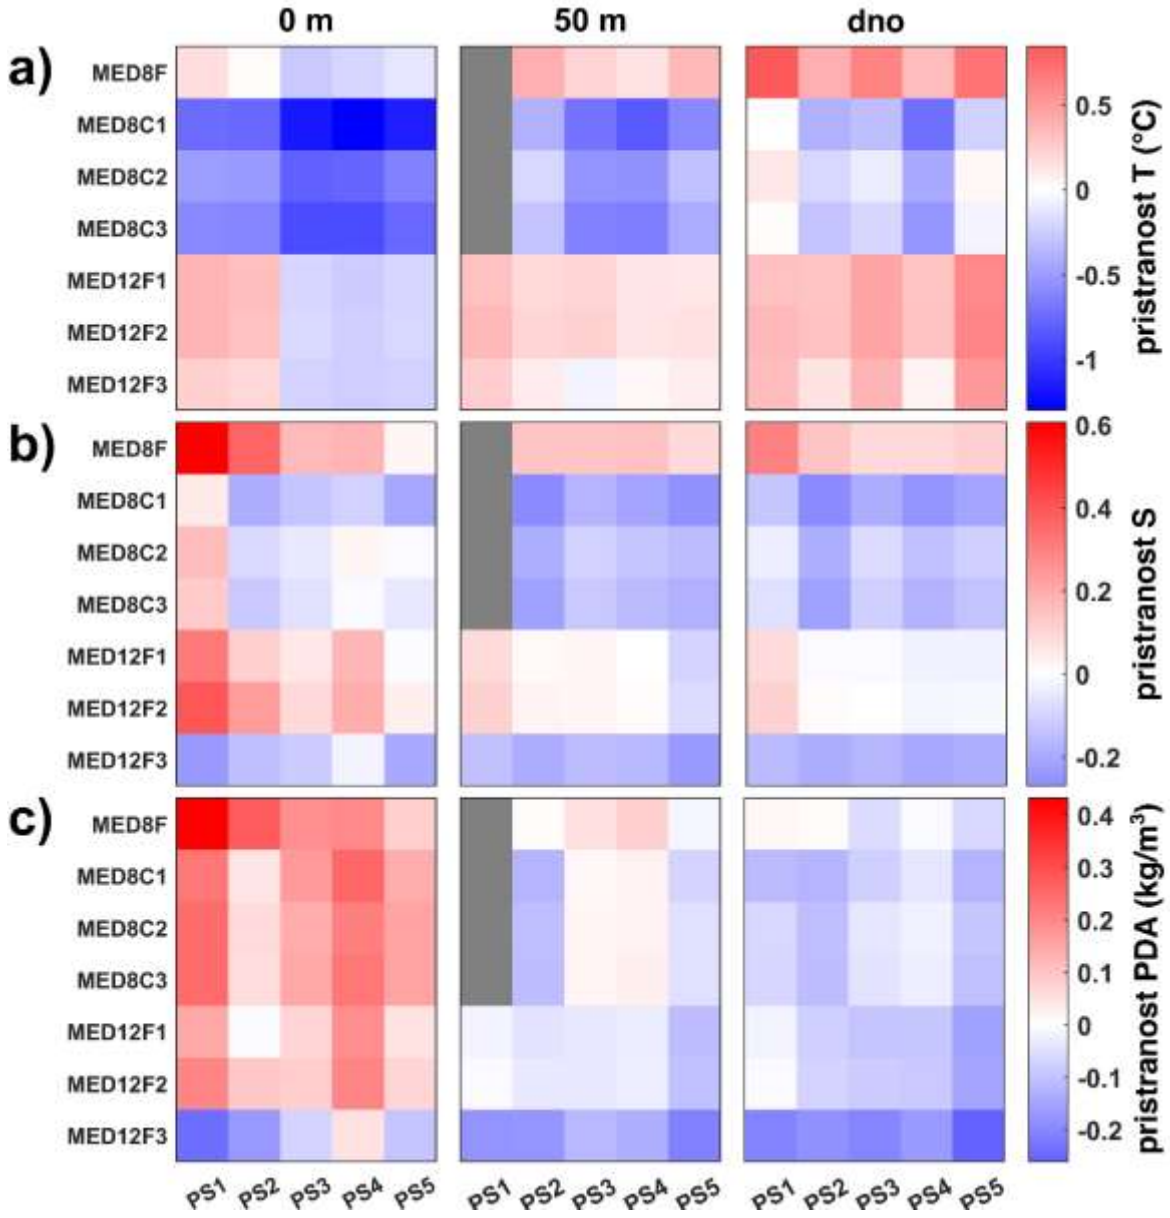
4.4.2. Srednji i južni Jadran

Evaluacija simulacija u srednjem i južnom Jadranu je napravljena pomoću dugoročnih *in situ* podataka temperature i saliniteta mjerenih na Palagruškom pragu (postaje PS1 - PS5, numerirane od sjevernog prema južnom dijelu transekta), te na postajama JK (Jabučka kotlina) i D1200 (Južnojadranska kotlina).

Na Palagruškom transektu vidljive su razlike u pristranosti temperature između nespregnutog i spregnutog modela (slika 33a). Simulacije spregnutog modela značajno podcjenjuju površinsku temperaturu mora (odstupanje do -1.3 ^{o}C). U srednjem sloju (50 m), gdje se osjeća utjecaj Levantinske intermedijarne vode, temperaturno podcjenjivanje je nešto slabije (do -0.8 ^{o}C), a najbolje slaganje simulacija spregnutih modela s mjerenjima se uočava u pridnenom sloju, posebice na postajama PS1 i PS5 (od 0 do -0.4 ^{o}C). U površinskom sloju sjevernog dijela Palagruškog transekta simulacije nespregnutih modela precjenjuju temperaturu, dok je na južnom dijelu transekta podcjenjuju. Slično kao i kod simulacija spregnutog modela, odstupanja temperatura raste s dubinom. Najveće precjenjivanje temperature je nađeno u pridnenom sloju u simulaciji MED8F (iznad 0.8 ^{o}C).

Najveća precjenjivanja saliniteta su zabilježena u simulaciji MED8F, uz prosječne vrijednosti pristranosti od 0.8 na površini, 0.1 u srednjem sloju, te 0.2 na dnu Palagruškog praga. Najniže odstupanje saliniteta se pojavljuje u simulaciji MED12F3, s prosječnim vrijedostima od -0.15 na površini, te -0.18 u srednjem i pridnenom sloju. Kroz čitav vodeni stupac, simulacije spregnutog modela uglavnom podcjenjuju salinitet, osim u površinskom dijelu bliže istočnoj obali, a najveće podcjenjivanje saliniteta je zabilježeno u srednjem i pridnenom sloju (do -0.3). U srednjem i pridnenom sloju, simulacije nespregnutog modela pokazuju vrlo dobro slaganje

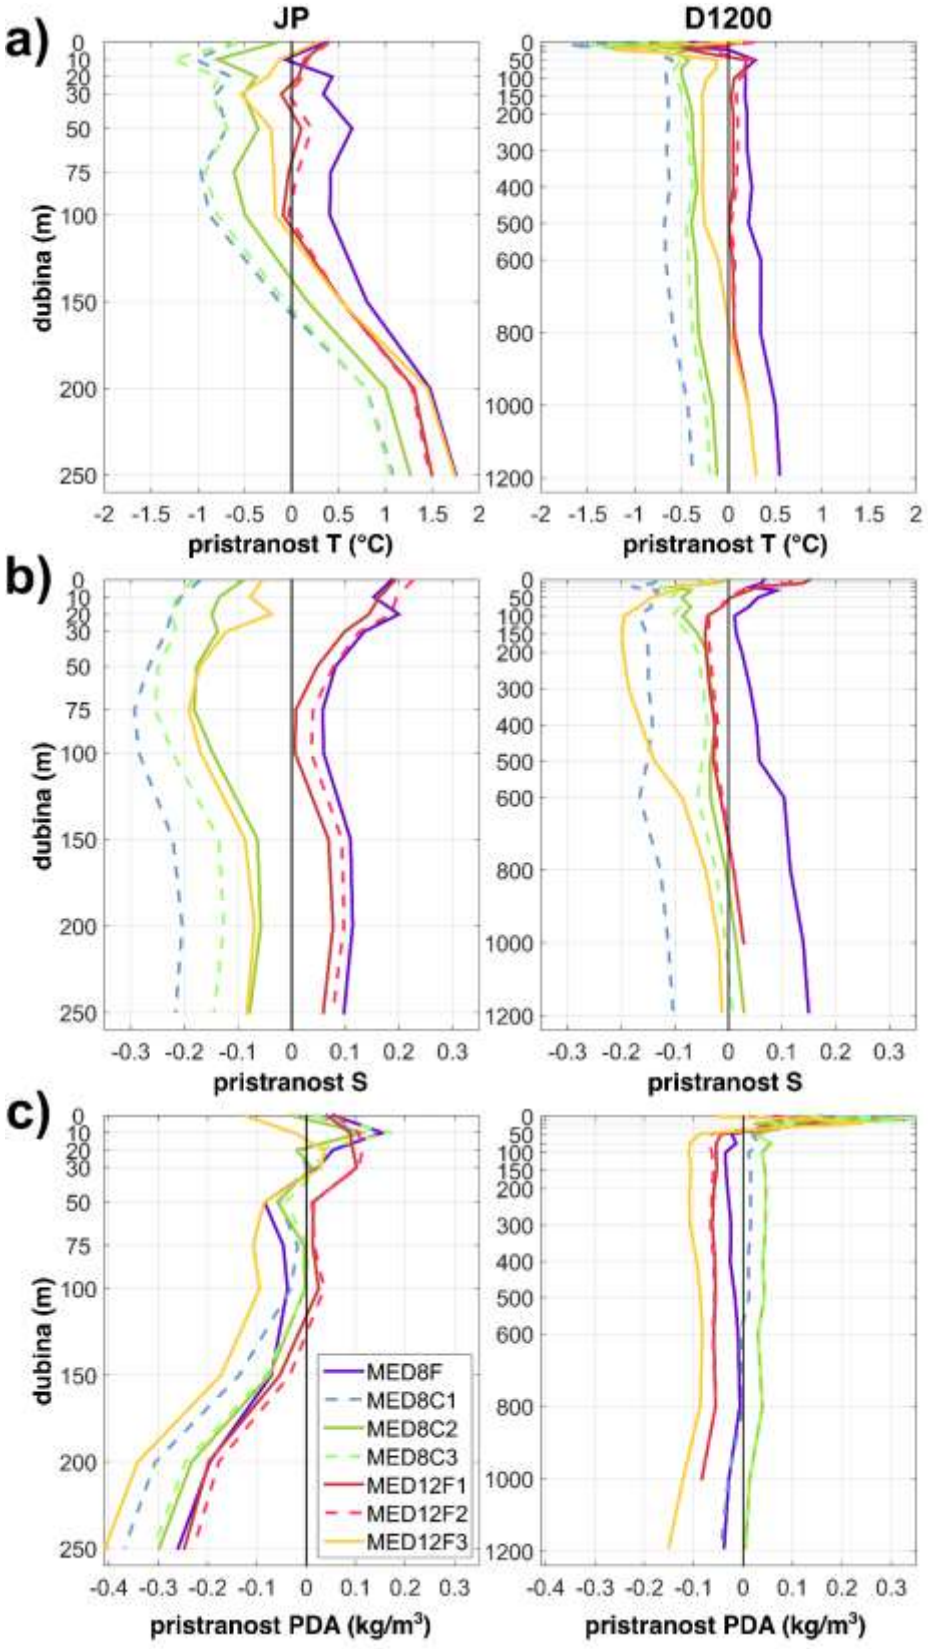
saliniteta s opažanjima, ukazujući na bolju sposobnost reproduciranja advekcije Levantinske intermedijarne vode u području Palagruškog praga.



Slika 33. Pristranost simulacija u odnosu na mjerenja za (a) temperaturu, (b) salinitet i (c) anomaliju potencijalne gustoće, na površini (lijevi stupac), 100 m dubine (srednji stupac) i dnu (desni stupac) Palagruškog transekta. Procjena pristranosti je napravljena uzimajući u obzir samo dane kad su vršena mjerenja. Dubina postaje PS1 u modelu MED8 je iznad 50 m, stoga nije bilo moguće odrediti pristranost na 50 m dubine (označeno sivim kvadratićima na slici).

Što se tiče pristranosti anomalije potencijalne gustoće, ona je uglavnom precjenjena na površini (osim u simulaciji MED12F3) a podcjenjena u ostatku vodenog stupca u svim simulacijama (slika 33c). Najveće podcjenjivanje gustoće u pridnenom sloju je zabilježeno u simulaciji MED12F3 (iznad 0.2 kg/m^3), zbog izrazito podcijenjenog saliniteta (iznad 0.2). Ostale simulacije blago (MED8F, do -0.07 kg/m^3) ili umjereno (MED12F1 - F2, do -0.15 kg/m^3) podcjenjuju gustoću. To se posebice odnosi na pridneni sloj postaja PS3 i PS5, područja kojima prolazi Sjevernojadranska voda na svom putu prema južnom Jadranu (Vilibić i sur., 2004; Marini i sur., 2016).

U Jabučkoj kotlini, na postaji JK, pristranost temperature je posebice izražena u dubljim slojevima (slika 34a, lijevi stupac), kod svih simulacija. Ti slojevi su dublji od Palagruškog praga (dubine veće od 170 m), stoga su pod slabim utjecajem advekcije Levantinske intermedijarne vode. S druge strane, to su područja akumulacije Sjevernojadranske vode (Artegiani i sur., 1997a; Vilibić i sur., 2004). Na dubini od 250 m, pristranost temperature u simulacijama nespregnutih modela je između 1.5 ^{o}C i 1.8 ^{o}C, a u simulacijama spregnutih modela je od 1.1 ^{o}C do 1.2 ^{o}C. To znači da sve simulacije ili neuspješno reproduciraju akumulaciju Sjevernojadranske vode na dnu Jabučke kotline, ili da je simulirana voda toplija nego li je to u stvarnosti. U intermedijarnom sloju podcjenjivanje temperature je niže ili zanemarivo kod simulacija nespregnutih modela u odnosu na simulacije spregnutih modela koji precjenjuju temperaturu, još jednom ukazujući da su karakteristike i kretanje Levantinske intermedijarne vode u Jadranskom moru uspješnije reproducirane nespregnutim modelima, posebice vidljivo u simulacijama MED12F1 i MED12F2. Uz vidljivo sustavno odstupanje među simulacijama, vertikalni presjeci pristranosti temperature kod svih simulacija su istog oblika, s malim promjenama u prvih 100 m dubine, nakon čega pristranost naglo raste prema dnu Jabučke kotline. Slično se uočava i kod vertikalnog profila pristranosti saliniteta (slika 34b, lijevi stupac). Sve simulacije u srednjem sloju (50 - 150 m) imaju konkavnu izbočinu, koja ukazuje na podcjenjivanje saliniteta Levantinske intermedijarne vode. To je posebno istaknuto u simulaciji MED12F3. Stoga, simulacije spregnutih modela i MED12F3 ili neuspješno reproduciraju advekciju Levantinske intermedijarne vode prema srednjem i sjevernom Jadranu, ili su termohaline karakteristike simulirane Levantinske intermedijarne vode podcijenjene već na samom izvoru (Levantinski bazen). Pristranosti temperature najviše utječu na pristranosti anomalije potencijalne gustoće (slika 34c, lijevi stupac). U dubokim slojevima, najveće podcjenjivanje gustoće je nađeno u simulaciji MED12F3 (-0.4 kg/m^3), a najmanje u ostalim simulacijama nespregnutih modela (-0.2 do -0.3 kg/m^3).



Slika 34. Vertikalni profili pristranosti simulacija u odnosu na mjerenja za (a) temperaturu, (b) salinitet i (c) anomaliju potencijalne gustoće, na postajama JK (lijevi stupac) i D1200 (desni stupac). Procjena pristranosti je napravljena nad dnevnim vrijednostima uzimajući u obzir samo dane kad su vršena mjerenja.

Na postaji D1200, sve simulacije imaju gotovo ujednačene vertikalne profile pristranosti temperature kroz cijeli vodeni stupac (slika 34, desni stupac), osim u površinskom i podpovršinskom sloju. Na dubinama od 20 - 30 m (sloj termokline), sve simulacije snažno podcjenjuju temperaturu (do -1.8 ^{o}C, slika 34a, desni stupac). Između 50 i 650 m dubine, vrijednosti pristranosti se povisuju i stabiliziraju, rezultirajući s podcijenjenim temperaturama u simulacijama spregnutih modela i u MED12F3 (od -0.4 ^{o}C do -0.6 ^{o}C) te precijenjenim temperaturama u ostalim simulacijama (od 0.2 do 0.3 ^{o}C). Prema dnu, pristranosti temperature u svim simulacijama rastu. Na dnu postaje D1200, blago podcjenjivanje temperature je nađeno u simulacijama MED8C2 i MED12C3 (0.1 ^{o}C), dok su precjenjene temperature nađene u simulacijama nespregnutih modela, još jednom ukazujući na njihovu nesposobnost reprodukcije Sjevernojadranske vode. Na svom dolasku iz sjevernog Jadrana, ta vodena masa tone uz rubove Južnojadranske kotline (Carniel i sur., 2016; Chiggiato i sur., 2016) te se akumulira u dubokim slojevima Južnojadranske kotline. Stoga, kod simulacija nespregnutih modela Sjevernojadranska voda je ili manjih volumena ili je karakterizirana višim temperaturama nego li je to zabilježeno u mjerenjima, što se vidi na slici 32a. Najveće precjenjivanje temperature na dnu postaje D1200 je nađeno u simulaciji MED8F (0.5 ^{o}C). Najmanja pristranost saliniteta je nađena u intermedijarnom sloju između 100 i 500 m dubine (do -0.2, slika 34b, desni stupac), gdje MED8C1 i MED12F3 pokazuju izrazito podcjenjivanje saliniteta. S druge strane, MED12F1 - F2 blago podcjenjuju salinitet. Prema dnu Južnojadranske kotline, pristranost saliniteta kod svih simulacija se povećava, slično kao i kod profila pristranosti temperature. Pristranost gustoće je dominantno određena pristranošću temperature, s izraženo visokim vrijednostima zabilježenim u podpovršinskom sloju (područje termokline) i opadanjem prema dubokim slojevima (1000 - 1200 m). Na dubinama od 800 do 1200 m podcjenjivanje gustoće je zabilježeno u svim simulacijama (u prosjeku -0.04 kg/m^3), osim u MED12F3 koja podcjenjuje gustoću za -0.07 kg/m^3.

4.5. Validacija procesa jadransko-jonskog sustava

4.5.1. Stvaranje guste vode

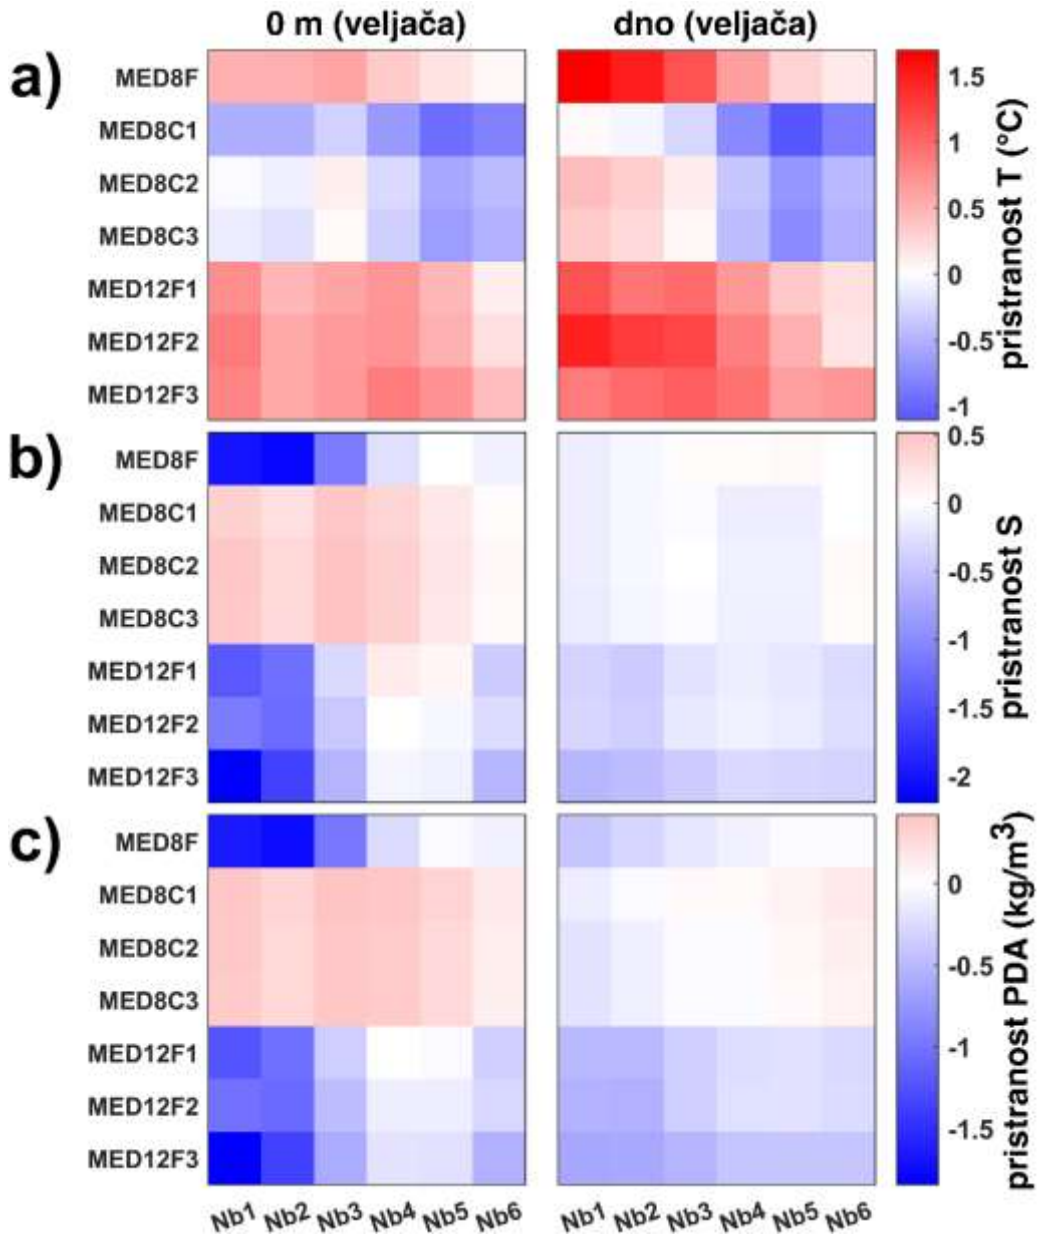
Stvaranje Sjevernojadranske vode se odvija u zimskom razdoblju, najčešće u veljači (Franco i Michelato, 1992; Artegiani i sur., 1997a; Vilibić i Supić, 2005; Kuzmić i sur., 2006). Upravo je tada temperatura u sjevernom Jadranu najmanja (Supić i sur., 2004). U zapadnom i središnjem dijelu sjevernog Jadrana se, pod utjecajem snažne bure, stvara ciklonalni vrtlog koji pogoduje konvektivnom miješanju (Orlić i sur., 1994; Bergamasco i sur., 1999; Beg-Paklar i

sur., 2001). Nakon stvaranja, Sjevernojadranska voda istječe zapadnom stranom sjevernog Jadrana (Vilibić i sur., 2004; Mihanović i sur., 2013), te puni duboke slojeve Jadrana, posebice Jabučku i Južnojadransku kotlinu. Stoga su načinjene analize pristranosti termohalinih varijabli u veljači, odvojeno za površinski i pridneni sloj transekta Nb (slika 35). Osim toga, posebno su analizirana prostorna obilježja stvaranja Sjevernojadranske vode u svim simulacijama, u zimi 2012. godine. Ta je godina obilježena jakim konvektivnim procesima u sjevernom Jadranu te je uspješno reproducirana oceanskim modelom visoke rezolucije (Mihanović i sur., 2013; Janeković i sur., 2014).

Stvaranje Južnojadranske vode, koji se u veljači i početkom ožujka odvija putem duboke konvekcije u Južnojadranskoj kotlini (Gačić i sur., 2002), je analiziran pomoću maksimalne dubine miješanja, ukupnog transporta kroz Otrant, te ukupnog volumena jadranskih gustih voda.

4.5.1.1. Sjeverni Jadran

Kao i tokom cijele godine, simulacije nespregnutih modela pokazuju precjenjivanje temperature te podcjenjivanje saliniteta u veljači u cijelom vodenom stupcu u sjevernom Jadranu (slika 35a i b). Razlike u pristranosti temperature i saliniteta procijenjene za veljaču u odnosu na godišnji prosjek su vidljive kod simulacija spregnutih modela. Zimske temperature su uglavnom podcijenjene (pristranost do -1.1 ^{o}C), dok je salinitet precijenjen na površini te blago podcijenjen na dnu transekta Nb (pristranost do -0.14). To je rezultiralo niskim vrijednostima pristranosti anomalije potencijalne gustoće u pridnenom sloju, što ukazuje na bolju sposobnost reproduciranja stvaranja Sjevernojadranske vode spregnutim modelima. Najniže pristranosti temperature i saliniteta, a time i gustoće, u simulacijama spregnutih modela se javlja na zapadnom dijelu transekta Nb (Nb1 - Nb3). U odnosu na godišnji prosjek, zimske temperature u simulacijama nespregnutih modela su do 1.7 ^{o}C više (slika 32a), dok je salinitet za 0.6 niži (slika 32b). Stoga možemo zaključiti da reprodukcija stvaranja Sjevernojadranske vode nije kvalitetna kod nespregnutih modela.

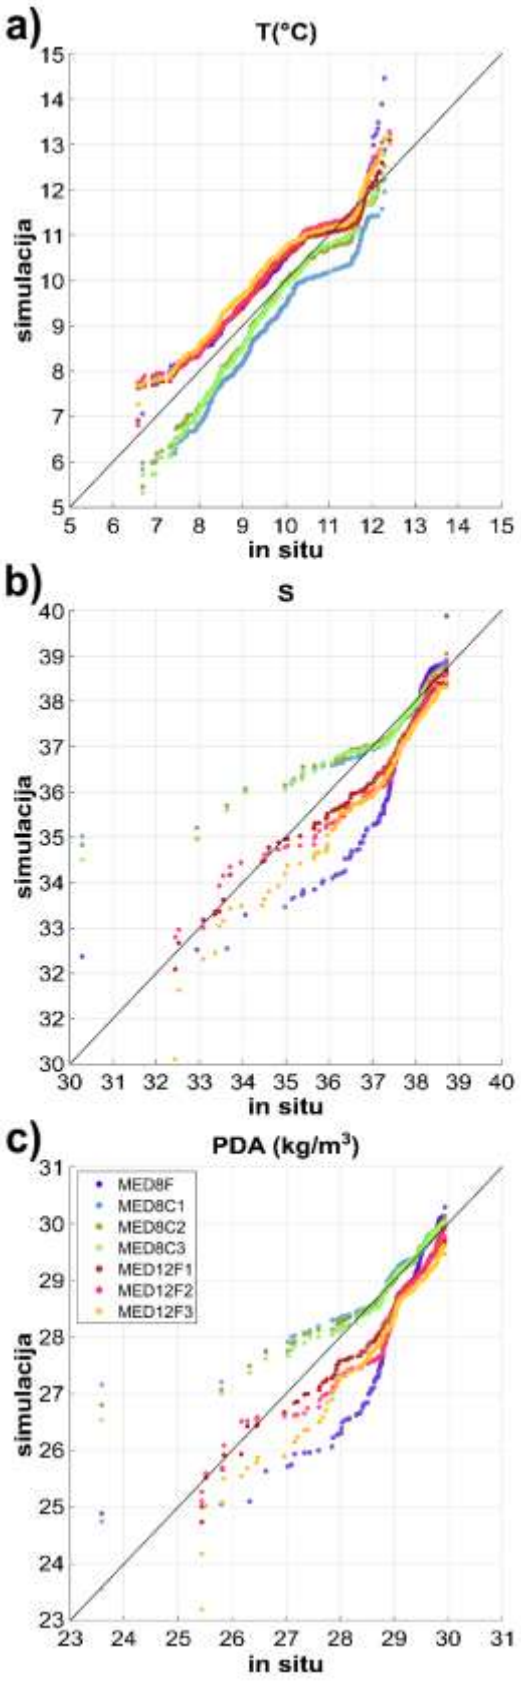


Slika 35. Pristranost simulacija u odnosu na mjerenja za (a) temperaturu, (b) salinitet i (c) anomaliju potencijalne gustoće, na površini (lijevi stupac) i dnu (desni stupac) procijenjenih za veljaču u vremenskom razdoblju 1980. - 2012., nad transektom Nb u sjevernom Jadranu.

Zimsko podcjenjivanje saliniteta u svim simulacijama nespregnutih modela je najizraženije na zapadnom dijelu transekta Nb, upravo u području ispred riječnih ušća (pristranost do -do 2.2, slika 35b). Te vode se rasprostiru na područje stvaranja guste vode, pa tako oslabljuju ili sprječavaju konvektivne procese u središnjem dijelu sjevernog Jadrana, gdje je zabilježen ciklonalni vrtlog tijekom puhanja jake bure (Zore-Armanda i Gačić, 1987; Kuzmić i sur., 2006). Suprotno, simulacije spregnutih modela precjenjuju salinitet (0.3 - 0.5 u

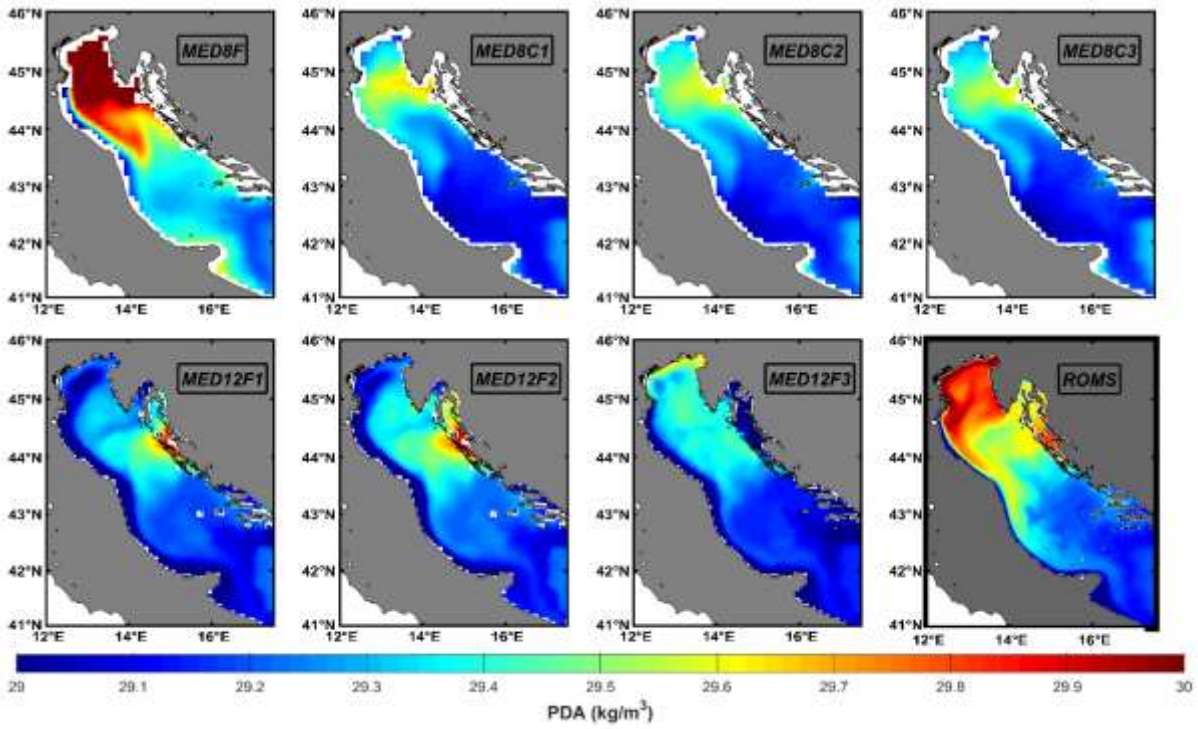
središnjem i zapadnom dijelu sjevernog Jadrana), što ukazuje na to da su u tim simulacijama riječne vode potisnute bliže obali.

Detaljnije istraživanje sposobnosti modela za reprodukciju Sjevernojadranske vode je napravljeno analizom kvantila. Vjerojatnosni graf (engl. *probability plot*), tzv. QQ-graf (engl. *Q-Q plot*), prikazuje mjeru slaganja promatranog skupa podataka (u našem slučaju su to simulirane vrijednosti) s određenom teorijskom razdiobom (u našem slučaju su to mjerenja). Slika 36 prikazuje QQ-graf za temperaturu, salinitet i anomaliju potencijalne gustoće u sjevernom Jadranu, gdje su uspoređene sve mjerene vrijednosti grupirane u kvantile, s kvantilima simuliranih mjesečnih vrijednosti u najbližim točkama modela. Kod svih simulacija se uočava sustavno odstupanje simuliranih temperatura naspram mjerenja (slika 36a). Najveća odstupanja u središnjim i rubnim dijelovima temperaturne razdiobe se javljaju kod simulacija nespregnutih modela. To posebice vrijedi za niže temperature koje su u nespregnutim simulacijama precijenjene do 1.2 ^{o}C, a koje se inače javljaju u veljači uslijed snažnih gubitaka topline na površini mora, i bitne su za stvaranje Sjevernojadranske vode. Simulacije spregnutih modela se najbolje slažu s mjerenom temperaturom u intervalu 9.0 - 11.0 ^{o}C, te oko 12 ^{o}C, dok su niže vrijednosti temperatura, vezane uz proces stvaranja guste vode, prilično podcijenjene. Sve simulacije dobro reproduciraju situacije s većim vrijednostima saliniteta (>38.0, slika 36b). U intervalu od 37.0 do 38.0, simulacije spregnutih modela također dobro reproduciraju salinitet, dok ih simulacije nespregnutih modela podcjenjuju. Najniže vrijednosti saliniteta (<37.0), mjerene na području utjecaja rijeke Po (zapadni dio sjevernog Jadrana), su snažno precijenjene kod spregnutih modela, dok ih simulacije nespregnutih modela blago podcjenjuju. Anomalije potencijalne gustoće veće od 28.2 kg/m^3 su vrlo dobro reproducirane simulacijama spregnutih modela, no niže gustoće su precijenjene zbog visokog saliniteta. Odstupanje saliniteta dominantno utječe i na podcjenjivanje gustoća ispod 28.8 kg/m^3, što je zabilježeno kod svih simulacija nespregnutih modela, osim u MED8F.



Slika 36. QQ-grafovi simuliranih vrijednosti (a) temperatura, (b) saliniteta i (c) anomalija potencijalne gustoće naspram svih mjerenja u sjevernom Jadranu u veljači.

Izuzetno snažan događaj stvaranja Sjevernojadranske vode se dogodio u veljači 2012. godine, kad su se mjerile rekordne vrijednosti anomalija potencijalne gustoće u sjevernom Jadranu (> 30.0 kg/m^3, Mihanović i sur., 2013; Raicich i sur., 2013; Benetazzo i sur., 2014; Janeković i sur., 2014; Ličer i sur., 2016). Sam događaj je uspješno reproduciran oceanskim modelom ROMS visoke rezolucije (2 km) koji je forsiran s 8-km atmosferskim modelom ALADIN i najnovijom riječnom klimatologijom (Janeković i sur., 2014). Simulacija ROMS je validirana na postojećim mjerenjima, te uspješno reproducira prostorne karakteristike i sve faze stvaranja Sjevernojadranske vode: (i) dugotrajno sušno razdoblje s niskim stopama oborina i riječnih protocima u prethodnoj godini, (ii) konvektivno stvaranje Sjevernojadranske vode s mezoskalnom cirkulacijom kojom dominira par ciklonalnog i anticiklonalnog vrtloga (Zore-Armanda i Gačić 1987; Beg-Paklar i sur., 2001; Kuzmić i sur., 2006) te (iii) transport Sjevernojadranske vode prema Jabučkoj i Južnojadranskoj kotlini zapadnom obalom Jadrana (Vilibić i Mihanović 2013; Mihanović i sur., 2013, Marini i sur., 2016). Stoga je događaj stvaranja Sjevernojadranske vode u veljači 2012. godine uzet za analizu prostornih karakteristika i dinamike stvaranja Sjevernojadranske vode u simulacijama modela NEMOMED. Slika 37 prikazuje prostorne razdiobe pridnene gustoće u veljači za svih sedam simulacija te za simulaciju ROMS.



Slika 37. Pridnene anomalije potencijalne gustoće u sjevernom i srednjem Jadranu, u veljači 2012. godine, za različite simulacije. Vrijednosti simulacije ROMS su preuzete iz Janeković i sur. (2014).

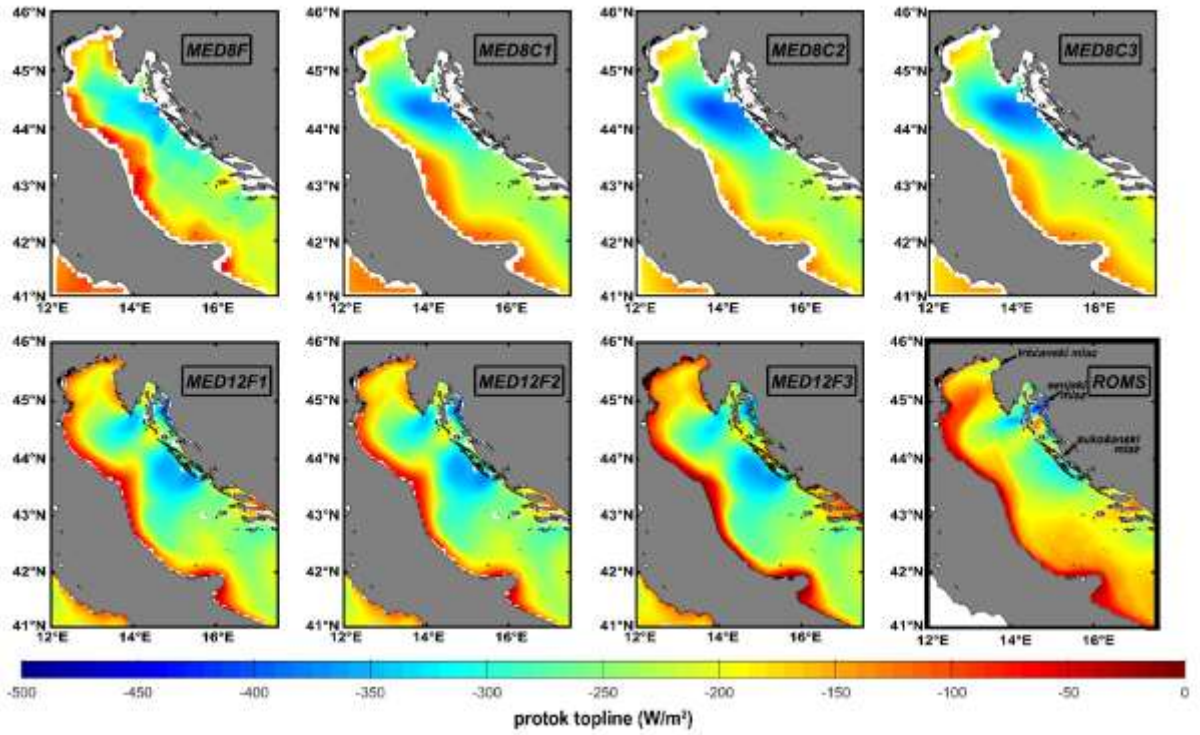
Uspoređujući klimatske simulacije s rezultatima ROMS-a, anomalija potencijalne gustoće u veljači 2012. godine je poprilično podcijenjena na većem dijelu sjevernog i srednjeg Jadrana u svim simulacijama, osim u MED8F-u (slika 37). Potonja simulacija je rezultirala maksimumom gustoće u najsjevernijem dijelu Jadrana, gdje su i mjerene rekordne vrijednosti gustoće (Mihanović i sur., 2013). Razlog tome je nedostatak riječnih protoka u simulaciji u sjevernom Jadranu (samo 2 ušća, slike 5 i 25). S druge strane, simulacije MED12F1 - F2 sadrže bolju riječnu klimatologiju (posebice MED12F2, vidi poglavlje 2.1.2.). Unatoč tome, te simulacije nisu uspješne u pravilnoj reprodukciji stvaranja Sjevernojadranske vode na otvorenom području Sjevernog Jadrana (vrijednosti anomalije potencijalne gustoće su znatno niže u usporedbi s modelom ROMS). Blago poboljšanje se zamjećuje u simulaciji MED12F2, u kojoj su vrijednosti gustoće u prosjeku nešto više u odnosu na MED12F1. Treba napomenuti da riječna forsiranja u svim simulacijama nespregnutih modela, osim MED12F2, nakon 2001. godine imaju konstantne vrijednosti, a to znači i veće protoke u odnosu na mjerene tijekom zime 2012. godine (Janeković i sur., 2014).

Međutim, obje simulacije veće rezolucije (MED12F1 i MED12F2) relativno dobro reproduciraju stvaranje guste vode u istočnom obalnom području sjevernog Jadrana, pri čemu

su polja simulacije MED12F2 bliža poljima ROMS-a. Simulacija MED12F3 ne reproducira stvaranje guste vode na istočnoj obali u čitavom razdoblju trajanja simulacije zbog izrazito precijenjenih riječnih protoka (u tom području protoci su za 270 m^3/s veći nego u simulaciji MED12F2). Bez obzira na izraženo sustavno odstupanje, ta simulacija jedina pravilno reproducira prostornu razdiobu pridnene anomalije potencijalne gustoće s maksimumom u najsjevernijem dijelu Jadrana.

Zbog grublje rezolucije modela, domena u MED8 ne obuhvaća istočno obalno područje. Stoga simulacije MED8F i MED8C1 - C3 nisu u mogućnosti reproducirati stvaranje guste vode u tom području, što je vjerojatno dovelo do podcjenjivanja ukupnog volumena Sjevernojadranske vode, budući da gusta voda stvorena u istočnom obalnom dijelu sjevernog Jadrana može značajno doprinijeti ukupnom volumenu Sjevernojadranske vode (oko 40% u 2012. godini, Janeković i sur., 2014).

Simulacije spregnutih modela na otvorenom dijelu sjevernog Jadrana reproduciraju Sjevernojadransku vodu s višim vrijednostima anomalije potencijalne gustoće nego li MED12F1 - F2. Međutim, područje maksimuma gustoće nije reproducirano u području otvorenog sjevernog Jadrana kao kod ROMS-a, već je smješteno ispred Kvarnerskog zaljeva.



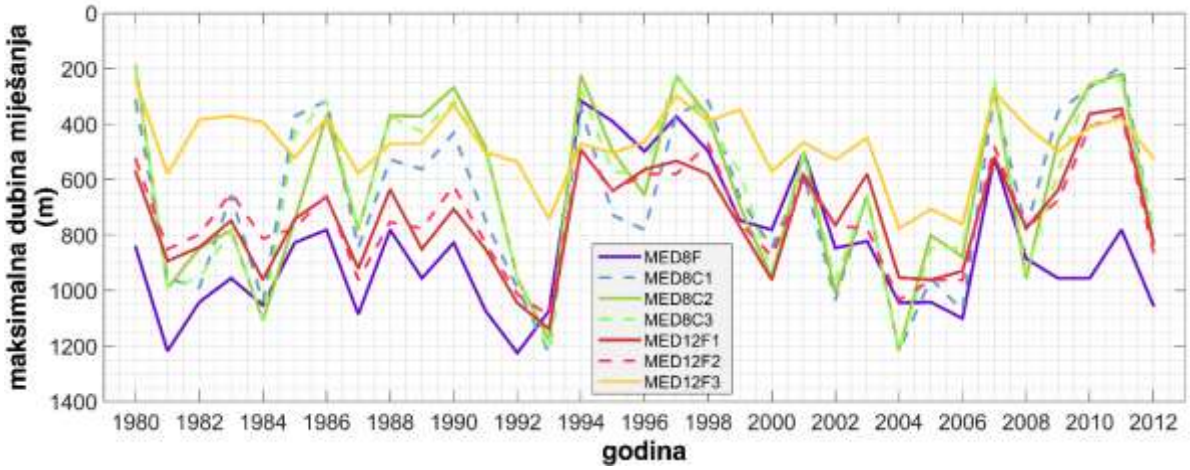
Slika 38. Površinski protoci topline u sjevernom i srednjem Jadranu, u veljači 2012. godine, za različite simulacije. Vrijednosti simulacije ROMS su preuzete iz Janeković i sur. (2014).

Kako su izraženi površinski gubici topline na sjevernom Jadranu najzaslužniji za stvaranje guste vode (Beg-Paklar i sur., 2001; Mihanović i sur., 2013), razlike u svojstvima pojedinih simulacija se mogu razlučiti analizirajući prostorne razdiobe gubitaka topline u veljači 2012. godine (slika 38). Simulacije s grubljom prostornom rezolucijom atmosferske komponente (modeli MED8) otkrivaju maksimume gubitaka topline na širem području sjevernog Jadrana, od istočnog obalnog područja prema otvorenom moru, s većim iznosima nego li je nađeno u simulaciji ROMS. Nadalje, te simulacije ne sadrže maksimume bure i povezane gubitke topline u području ispred Senja ili Trsta. Povećanje rezolucije atmosferskih forsiranja (atmosfersko forsiranje ALDERA u simulacijama MED12F1 - F3) rezultira detaljnijom razdiobom površinskih gubitaka topline, pri čemu se razabiru tri definirana mlaza bure (tršćanski, senjski i sukošanski mlaz, Janeković i sur., 2014). Međutim, u modelima MED12 (MED12F1 - MED12F3) gubici topline u senjskom mlazu su slabiji nego li u sukošanskom mlazu, što je u suprotnosti s rezultatima ROMS-a (Janeković i sur., 2014). Naime, simulacija ROMS daje dvostruko veće gubitke topline na području senjskog mlaza (gotovo 2000 W/m^2 u 2012. godini) od onog koji je pod utjecajem sukošanskog mlaza (oko 850 W/m^2 u 2012. godini). Nadalje, gubici topline u plitkom tršćanskom zaljevu (do 1000 W/m^2, Raicich i sur., 2013), gdje su i

zabilježeni maksimumi anomalije potencijalne gustoće tijekom veljače 2012. godine (mjerene gustoće su premašivale vrijednosti od 30.0 kg/m^3, Mihanović i sur., 2013, Raicich i sur., 2013; Janeković i sur., 2014), su veoma niski u modelima MED12, što je uzrokovalo nepravilno reproduciranje stvaranja guste vode u tom području.

4.5.1.2. Južni Jadran

Procjena jakosti duboke konvekcije u južnom Jadranu i stvaranja Južnojadranske vode u području duboke Južnojadranske kotline je načinjena pomoću maksimalne dubine miješanja (*MLD*). Za sve simulacije maksimalna dubina miješanja je računata uzimajući u obzir kriterij turbokline (Somot i sur., 2006; vidi poglavlje 2.5.2.). Na žalost, u Južnojadranskoj kotlini ne postoje dugoročna mjerenja temeljem kojih bi se mogla procijeniti međugodišnja varijabilnost maksimalne dubine miješanja. Jedina postaja za koju postoje dugoročni nizovi mjerenih termohalinih parametara je D1200 čija je dubina 1200 m, međutim, ona je smještena na rubu Južnojadranske kotline, te stoga ne može poslužiti za pouzdanu procjenu maksimalne dubine miješanja. Iz tog razloga, validacija simuliranih maksimalnih dubina miješanja se oslanja na publicirane procjene dobivene povremenim terenskim istraživanjima.

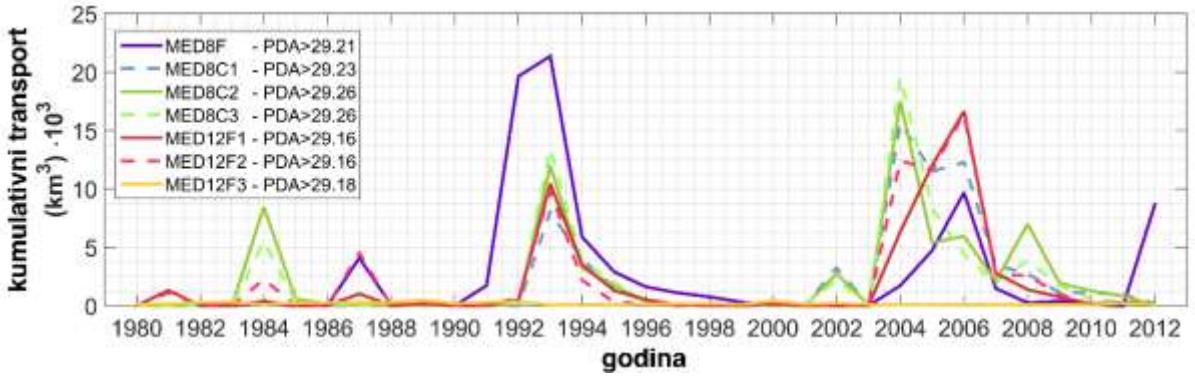


Slika 39. Vremenski nizovi godišnjih maksimalnih dubina miješanja procijenjenih iz dnevnih vrijednosti u južnom Jadranu (područje 1 na slici 7), za sve simulacije.

Slika 39 prikazuje simuliranu međugodišnju varijabilnost maksimalnih godišnjih vrijednosti dubine miješanja izdvojenih iz dnevnih nizova u južnom Jadranu. Sve simulacije daju maksimalne dubine miješanja u veljači, kada se najčešće i događa proces duboke konvekcije (Gačić i sur., 2002). Prosječne vrijednosti maksimalnih godišnjih dubina miješanja u čitavom razdoblju (1980. - 2012.) iznose 844 m, 673 m, 641 m, 636 m, 738 m, 733 m, i 477 m, redom za simulacije MED8F, MED8C1, MED8C2, MED8C3, MED12F1, MED12F2, i MED12F3 simulacije. Zaključno, MED8F u pravilu reproducira najveće godišnje maksimalne dubine miješanja, dok MED12F3 daje najmanje. Iako gore navedeni srednjaci ukazuju na to da simulacije nespregnutih modela u pravilu daju veće maksimalne dubine miješanja od simulacija spregnutih modela, situacija je suprotna kod izraženih konvektivnih godina, kao što su 1984., 1993. i 2004. Osim toga, simulirana maksimalna dubina mješanja često dosiže dno Južnojadranske kotline (1200 m), što nije nikad zabilježeno mjerenjima. Analize vertikalnih profila temperature i saliniteta, prikupljenih nakon 1970-tih godina (Vilibić i Orlić, 2001), ukazuju na to da maksimalna dubina miješanja nije premašivala 900 m. Ona je procijenjena na 800 m u 1987. godini (Vilibić i Orlić, 2001), na 600 m u 1996. godini (Manca i Bregant, 1998), na 900 m u 1992. godini i 300 m u 1998. godini (Gačić i sur., 2002), na 650 m u 2006. godini (Vilibić i Šantić, 2008), te na 500 m u 2012. godini (Mihanović i sur., 2013; Najdek i sur., 2014). S druge strane, slabe konvektivne godine u južnom Jadranu nisu često istraživane. U literaturi se mogu pronaći samo procjene za dvije godine: 35 m u 1997. godini (Gačić i sur., 2002), te 250 - 300 m u 2015. godini (Lučić i sur., 2017). Unatoč poduzorkovanju mjerenja, tj. nedostatka mjerenja u razdobljima intenzivnog procesa stvaranja guste vode, što može podcijeniti pravu vrijednost dubine miješanja u južnom Jadran, može se zaključiti da je vertikalno miješanje u svim simulacijama snažnije nego li u stvarnosti, osim u MED12F3 koja simulira slabije vertikalno miješanje. Jedan od mogućih razloga je podcijenjena gustoća na dnu same kotline u svim simulacijama (800 - 1200 m, vidi poglavlje 4.4.2.) koja je smanjila pridnenu stratifikaciju, pa je simulirano vertikalno miješanje dosizalo veće dubine i samo dno kotline.

U svim simulacijama je izražena međugodišnja i dekadska varijabilnost stvaranja Južnojadranske vode (slika 39), posebice vidljivo u simulacijama spregnutih modela. Više vrijednosti maksimalnih dubina miješanja su povezane s godinama snažnih gubitaka topline (slika 26b). Prosječni koeficijent korelacije između zimskih površinskih gubitaka topline u južnom Jadranu i godišnje maksimalne dubine miješanja za sve simulacije iznosi ~ 0.8 (značajnost od 99%), što ukazuje na snažan utjecaj atmosferskog forsiranja na stvaranje

Južnojadranske vode. Isto je zaključeno i kod analiza duboke konvekcije u Lionskom zaljevu (L'Hévéder i sur., 2013; Somot i sur., 2018). Nakon 1993. godine, sve simulacije bilježe razdoblje oslabljene južnojadranske konvekcije, istovremeno sa slabim površinskim protocima topline. Treba napomenuti da na dekadsku varijabilnost konvekcije u južnom Jadranu također utječe i proces BiOS-a (poglavlje 1.4.) koji je odgovoran za advekciju vodenih masa iz sjevernog Jonskog mora koje utječu na stratifikaciju vodenog stupca u Južnojadranskoj kotlini.



Slika 40. Kumulativni godišnji transporti Južnojadranske duboke vode kroz Otrantska vrata, za određeni prag gustoće. U legendi su prikazane vrijednosti pragova gustoće koje su određene 95-tim percentilom od svih vrijednosti gustoća ispod 100 m dubine, za svaku simulaciju zasebno.

Nakon stvaranja, Južnojadranska voda teče pridnenim slojevima Otrantskih vrata prema dubokim slojevima istočnog Sredozemlja (Roether i Schlitzer, 1991; Robinson i sur., 2001). Stoga su izračunati godišnji kumulativni transporti vode na transektu u Otrantskim vratima u smjeru juga (40 ^{o}N, izlazna struja), za vodu iznad određenog praga gustoće (slika 40). Dosadašnja analiza je pokazala da se termohaline karakteristike značajno razlikuju među pojedinim simulacijama, posebice salinitet koji utječe na gustoću Jadranskog mora, stoga nije moguće definirati jedinstveni prag gustoće za procjenu transporta. Iz tog razloga, prag gustoće je određen pomoću 95-tog percentila svih prosječnih mjesečnih vrijednosti anomalije potencijalne gustoće na dubinama ispod 100 m (ispod sezonske termokline, Buljan i Zore-Armanda, 1976) na transektu u Otrantskim vratima (slika 40). Procijenjeni prag gustoće je veći i realističniji u simulacijama spregnutih modela (Vilibić i Orlić, 2001; Mantziafou i Lascaratos, 2008): u MED8C1 iznosi 29.23 kg/m^3, a u MED8C2 - C3 iznosi 29.26 kg/m^3. Simulacija MED8F daje nešto niži prag gustoće (29.21 kg/m^3), dok su najniže vrijednosti nađene u MED12F1 - F2 (29.16 kg/m^3), te u simulaciji MED12F3 (29.18 kg/m^3).

U svim simulacijama, osim MED8F i MED12F3, kumulativni transport je u intervalu od 1500 km^3/god do 17000 km^3/god, s izraženom međugodišnjom varijabilnošću (slika 40). Ove procjene su u suglasnosti s procjenama nađenima u literaturi: višegodišnja mjerenja morskih struja u Otrantskim vratima ukazuju na jaku međugodišnju varijabilnost istjecanja Južnojadranske vode u intervalu od 3150 km^3/god do 13000 km^3/god (Gačić i sur., 1996, 2002), a analiza box-modelom za razdoblje 1975. - 1976. je dala vrijednosti transporta od 9500 km^3/god do 12500 km^3/god (Vilibić i Orlić, 2002). Sveukupno gledajući, godine s visokim transportima Južnojadranske vode su 1984., 1987., 1992. - 1993., 2004. - 2009. i 2012, pri čemu se simulacije međusobno dobro slažu u 1993., 2004. i 2006. godini. Značajno odudaranje transporta Južnojadranske vode je zabilježen 1992. i 1993. godine u simulaciji MED8F, premašujući 20000 km^3/god, dok ostale simulacije daju umjerene vrijedosti transporta. Od sredine 1990-tih do početka 2000-tih godina sve simulacije imaju iznimno nizak transport, što odgovara razdoblju nakon Istočnosredozemnog tranzijenta, kada su u Jadranu mjerene veoma niske vrijednosti saliniteta zbog pojačane advekcije voda iz zapadnog Sredozemlja. Posljedično, stvaranje jadranskih gustih voda je bilo oslabljeno (Vilibić i sur., 2012).

Uspoređujući međugodišnju varijabilnost transporta i maksimalne dubine miješanja (slika 39), uočavaju se sličnosti u većini godina, dok se u nekim godinama razlikuju. Tako se npr. slab transport Južnojadranske vode u svim simulacijama uočava u razdoblju 1981. - 1982., dok je u isto vrijeme konvektivni proces u Južnojadranskoj kotlini skoro dosegao dno, posebice u simulaciji MED8F (slika 39). Međutim, u tom razdoblju Južnojadranska voda je u MED8F-u imala nizak salinitet i nižu gustoću (prosječna vrijednost anomalije potencijalne gustoće u veljači 1982. godine u Južnojadranskoj kotlini je iznosila 29.2 kg/m^3) u odnosu na ukupni prosjek (prosječna vrijednost u veljači u razdoblju 1980. - 2012. iznosi 29.3 kg/m^3). S druge strane, maksimumi dubine miješanja u 1993., 2004. i 2006. godini odgovaraju visokim transportima jadranskih gustih voda u Otrantskim vratima.

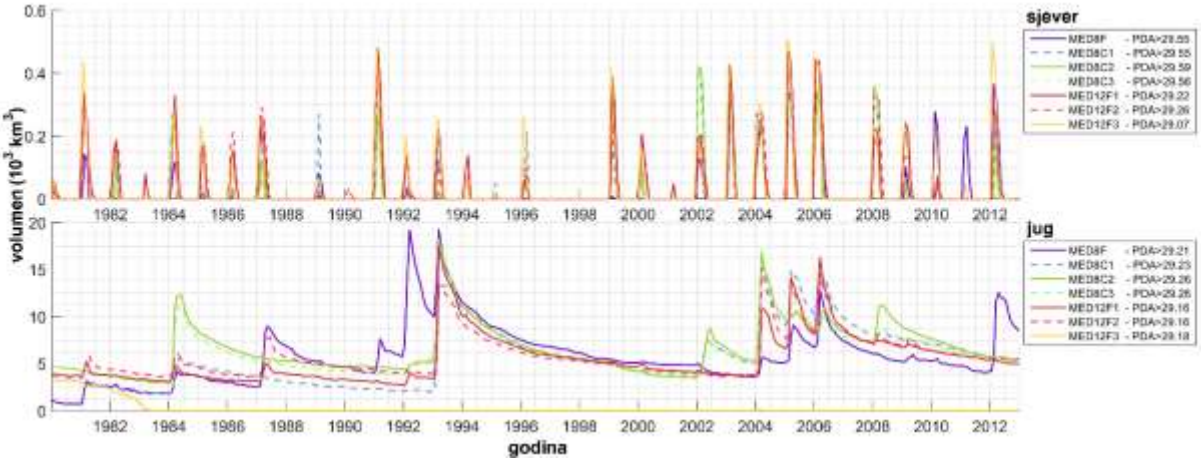
Treba napomenuti da MED12F3, za razliku od ostalih simulacija, ne pokazuje značajnu međugodišnju varijabilnost. Štoviše, transport Južnojadranske vode kroz Otrantska vrata u toj je simulaciji snažno podcijenjen, a u nekim godinama iščezava. Za razliku od ostalih simulacija, koeficijent korelacije između maksimalne dubine miješanja i kumulativnih transporta je ~ 0.1 i nije statistički značajan.

4.5.1.3. Varijabilnost stvaranja jadranskih gustih voda

Međugodišnja varijabilnost stvaranja jadranskih gustih voda se može procijeniti i određivanjem ukupnog volumena voda karakteriziranim gustoćama iznad određenog praga (slika 41). Računati su mjesečni srednjaci volumena, posebno za sjeverni i južni Jadran (područja 1 i 2 na slici 7). Pragovi anomalije potencijalne gustoće su određeni 95-tim percentilom svih vrijednosti u području sjevernog Jadrana, dok su za južni Jadran vrijednosti praga gustoće uzete iz analize kumulativnog transporta kroz Otrant (slika 40).

U svim simulacijama, konvektivni procesi i stvaranje guste vode u sjevernom Jadranu se pojavljuju gotovo svake godine, s promjenjivim intenzitetom. U skladu s postojećom literaturom (Artegiani i Salusti, 1987; Vilibić i sur., 2004; Vilibić i Supić, 2005; Mihanović i sur., 2013), snažnija produkcija Sjevernojadranske vode se pojavljuje u godinama 1981., 1984., 1987., 1991., 1999., te u razdobljima 2002. - 2006. i 2008. - 2012. Razlike među simulacijama su vidljive u gustoćama vodene mase, procjenjene pragovima anomalija potencijalnih gustoća. Simulacije spregnutih modela reproduciraju za oko 0.3 kg/m^3 gušću Sjevernojadransku vodu od simulacija nespregnutih modela (osim MED8F, koja je karakterizirana visokim salinitetom), zbog izraženijih površinskih gubitaka topline. Zanimljivo je uočiti sezonsku varijabilnost ukupnih volumena kod svih simulacija (zimski maksimum i ljetni minimum), koja se javlja zbog kratkog vremena zadržavanja Sjevernojadranske vode na području sjevernog Jadrana (svega nekoliko mjeseci; Artegiani i Salusti, 1987; Vilibić, 2003; Janeković i sur., 2014).

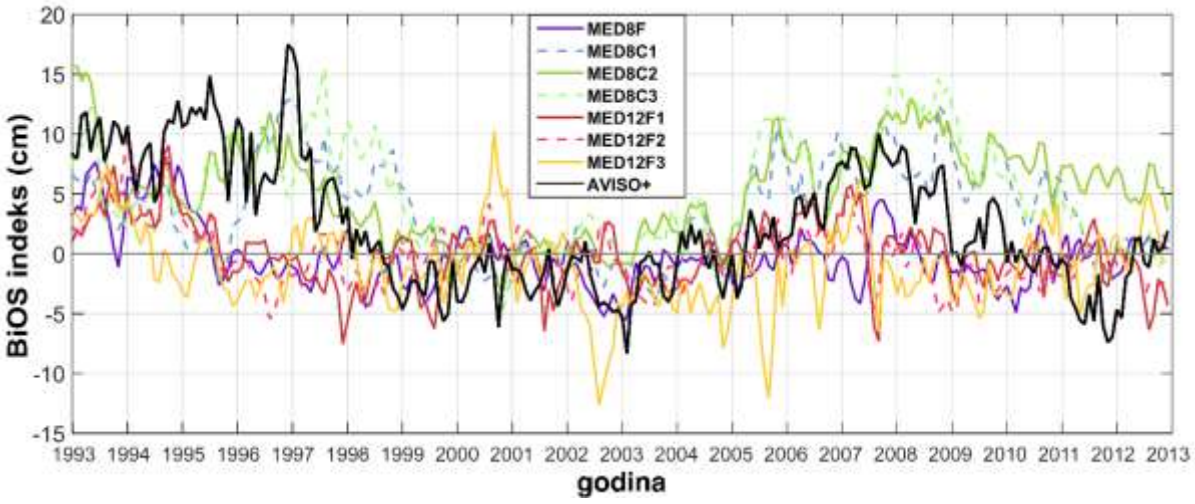
Za razliku od sjevernog Jadrana, volumeni guste vode u južnom Jadranu su korelirani s transportima Južnojadranske vode kroz Otrantska vrata. Koeficijent korelacije između godišnjih vrijednosti oba niza je između 0.86 i 0.89, značajan na 99-postotnoj razini, za sve simulacije osim MED12F3. Naime, na početku simulacije MED12F3 pojavljuje se slaba konvekcija u južnom Jadranu, nakon čega se volumen guste vode snizio gotovo do nule. U ostalim simulacijama, snažna konvekcija u južnom Jadranu se pojavljuje tokom 1993. godine, te između 2004. i 2006. godine, što je u skladu s literaturom (Vilibić i Šantić, 2008; Mantziafou i Lascaratos, 2008).



Slika 41. Vremenski nizovi simuliranih volumena guste vode na sjevernom (gornji red) i južnom (donji red) Jadranu, usrednjenih nad područjima 1 i 2 sa slike 7. Gornja legenda prikazuje pragove gustoće određenih 95-tim percentilom svih vrijednosti gustoća u sjevernom Jadranu, posebno za svaku simulaciju. Donja legenda prikazuje pragove gustoće preuzete sa slike 40.

4.5.2. Jadransko-jonska bimodalna oscilacija

Budući da se Jadransko-jonska bimodalna oscilacija (BiOS) manifestira kroz izmjenu ciklonalne i anticiklonalne cirkulacije u sjevernom Jonskom moru, za kvantifikaciju procesa je predložen parametar na temelju razine mora (Gačić i sur., 2010; Bessieres i sur., 2013; Mihanović i sur., 2015; Reale i sur., 2016), i to jednostavan BiOS indeks (vidi poglavlje 2.5.3., slika 42). Pozitivna vrijednost BiOS indeksa ukazuje na anticiklonalnu cirkulaciju u sjevernom Jonskom moru povezanu s pojačanom advekcijom manje slanih atlantskih vodenih masa, a negativna vrijednost na ciklonalnu cirkulaciju i advekciju Levantinske intermedijarne vode visokog saliniteta prema Jadranu.



Slika 42. Vremenski nizovi BiOS indeksa u sjevernom Jonskom moru (vidi objašnjenje u tekstu), procijenjeni za sve simulacije, te za mjerenja apsolutne dinamičke topografije AVISO+.

Iz mjerenih vrijednosti BiOS indeksa (slika 42) uočavaju se dva anticiklonalna i dva ciklonalna perioda:

- anticiklonalni periodi su zabilježeni od 1993. do 1997. godine, te od 2006. do 2010. godine,
- ciklonalni periodi su zabilježeni od 1998. do 2005. godine, te nakon 2011. godine.

Simulacije nespregnutih modela značajno podcjenjuju vrijednosti BiOS indeksa i za ciklonalnu i za anticiklonalnu cirkulacije, što je posebice uočljivo između 1995. i 1997. godine kad su vrijednosti indeksa u simulacijama nespregnutih modela blizu nule, dok je mjereni BiOS indeks bio iznimno visok i pozitivan, ukazujući na snažnu anticiklonalnu cirkulaciju u sjevernom Jonskom moru. S druge strane, simulacije spregnutih modela bolje prate mjerenja, iako je u simulacijama MED8C1 i MED8C3 prijelaz iz anticiklonalne u ciklonalnu fazu kasnio za oko jednu godinu u usporedbi s mjerenjima. Simulacije nespregnutih modela također podcjenjuju i drugu anticiklonalnu fazu (2006. - 2010.), dok simulacije spregnutih modela daju više vrijednosti BiOS indeksa od mjerenog. Promjena režima u 2011. godini je relativno dobro reproducirana u MED8C1 i MED8C3 , dok se u MED8C2 ciklonalna cirkulacija zadržava do kraja analiziranog razdoblja. U razdobljima opažene ciklonalne cirkulacije, odstupanja simulacija su puno niža nego li u razdobljima anticiklonalne cirkulacije. Simulacija MED12F3 nije uspjela reproducirati ciklus BiOS-a, zbog slabog ili izostanka transporta jadranskih gustih voda kroz Otranto (slika 40).

4.6. Diskusija

U ovom poglavlju se napravljene analize sedam simulacija modelom NEMOMED, čime se istražio utjecaj pojedinih postavki simulacije na reprodukciju jadranskih termohalinih svojstava i stvaranja gustih voda. Simulirane vrijednosti termohalinih varijabli su validirane na postojećim *in situ* podacima temperature i saliniteta, a uz to su se detaljno analizirali jadranski procesi stvaranja gustih voda, te oscilacije uzrokovane mehanizmom BiOS-a.

Simulacije nespregnutih modela (MED8F i MED12F1 - F2) generalno precjenjuju temperaturu i salinitet u Jadranu, pri čemu MED8F ima najveću pristranost temperature i saliniteta u čitavom vodenom stupcu Jadrana. S druge strane, MED12F3 znatno podcjenjuje jadranski salinitet, zbog nepravilno definiranih riječnih protoka, vjerojatno u cijelom Sredozemlju, dok je, kao i kod ostalih modela MED12, u simulaciji MED12F3 temperatura precijenjena. Zbog tih odstupanja sve simulacije podcjenjuju stvaranje guste vode u sjevernom Jadranu. Stvaranje guste vode je nešto bolje reproducirano spregnutim (MED8C1 - C3) nego nespregnutim modelima. Jedan od razloga tome je 20 - 30% veći gubitak topline u sjevernom Jadranu u spregnutim modelima. Nadalje, niža horizontalna i vertikalna rezolucija u modelima MED8 u kombinaciji s nižom prostornom i vremenskom rezolucijom atmosferskog forsiranja ARPERA (~ 50 km, dnevno) je onemogućila pravilnu reprodukciju konvektivnih procesa u sjevernom Jadranu u modelima MED8, dok su prostorno-vremenske karakteristike nešto bolje reproducirane modelom MED12. Naime, veća rezolucija atmosferskog forsiranja ALDERA (~ 13 km, 3-satno) u modelu MED12 je rezultirala realističnijom reprezentacijom bilance topline na površini mora, posebice u Tršćanskom zaljevu.

Dokaz da je simulirano stvaranje Sjevernojadranske vode u svim simulacijama podcijenjeno su odstupanja termohalinih vrijednosti (poglavito temperature) u Jabučkoj i Južnojadranskoj kotlini. Obje kotline su kolektori Sjevernojadranske vode, koja se akumulira u njihovim dubokim slojevima (ispod 200 m u Jabučkoj kotlini, te ispod 800 m u Južnojadranskoj kotlini, Bensi i sur., 2013; Querin i sur., 2013; Chiggiato i sur., 2016; Langone i sur., 2016). Izrazito precjenjivanje temperature na dnu Južnojadranske kotline u svim simulacijama je smanjilo stabilnost dubokih slojeva (800 - 1200 m) te je maksimalna dubina miješanja u pojedinim godinama dosizala dno kotline. U literaturi nije zabilježeno vertikalno miješanje dublje od 900 m. Podcjenjivanje stvaranja guste Sjevernojadranske vode nije jedini razlog snažnog vertikalnog miješanja u južnom Jadranu. Nepravilna reprodukcija svojstava i advekcije

Levantinske intermedijarne vode u srednjim slojevima Jadrana, posebice uočljiva u simulacijama MED8C1 - C3 koje daju niže vrijednosti saliniteta, mijenja stabilnost vertikalnog stupca u kojem se odvija miješanje, stoga se time mijenja i intenzitet duboke konvekcije.

Bolje slaganje saliniteta u sloju toka Levantinske intermedijarne vode je postignuto simulacijama MED12F1 i MED12F2. Jedan razlog tome može biti viša vertikalna rezolucija oceanske komponente modela MED12. Naime, broj vertikalnih slojeva u Otrantskim vratima u modelu MED12 je 45, dok je u modelu MED8 samo 24. Nadalje, rezolucija modela može utjecati i na procese koji se odvijaju u Levantinskom zaljevu i Jonskom moru te posljedično na dubinu jezgre ulaska Levantinske intermedijarne vode u Jadran. U simulacijama MED12F1 i MED12F2 ta je dubina ~ 200 m, dok je u simulacijama modelom MED8 ona na većim dubinama. Na žalost ne postoje dugoročna mjerenja termohalinih vrijednosti u Otrantskim vratima, koja bi mogla poslužiti za pravilnu validaciju toka Levantinske intermedijarne vode. Povremena terenska istraživanja dokumentiraju ulazak Levantinske intermedijarne vode na dubinama od 150 do 400 m (Gačić i sur., 1996; Malanotte-Rizzoli i sur., 1997; Kršinić i Grbec, 2002; Manca i sur., 2002).

Za razliku od ostalih simulacija, MED12F3 pokazuje iznimno lošu sposobnost reproduciranja termohalinih svojstava, procesa duboke konvekcije u južnom Jadranu te izmjenu vodenih masa u Otrantskim vratima. Ta simulacija ima drugačije početne uvjete od ostalih simulacija modela MED12F, veoma kratak period prilagodbe (6 godina), te precijenjeni unos slatke vode koji je doveo do značajnog podcjenjivanja saliniteta u Jadranu. Takvi uvjeti su, već pri početku simulacije, zapriječili pojavu duboke konvekcije u južnom Jadranu u cijelom razdoblju simulacije. Međutim, zbog svoje visoke prostorne rezolucije oceanskog modela u Jadranu (~ 2 km), simulacija MED12F3 je jedina uspjela reproducirati prostorna obilježja najsjevernijeg dijela Jadranskog mora za vrijeme intenzivnog stvaranja gustih voda.

Što se tiče BiOS-a, spregnute simulacije pokazuju bolju sposobnost reprodukcije BiOS indeksa, za kojeg je dokumentirano da opisuje opažene dekadske oscilacije cirkulacije u sjevernom Jonskom moru (Gačić i sur., 2010). Međutim, kako analizirane simulacije neadekvatno mapiraju prostorna obilježja procesa BiOS-a (poglavlje 3.5.), postavlja se pitanje je li tako pojednostavljeni indeks primjenjiv za opisivanje simulirane promjene BiOS-a.

Uspoređujući simulacije koje se razlikuju u samo jednom parametru, MED8C2 i MED8C3 (isključen ili uključen trend aerosola) te MED12F1 i MED12F2 (stara ili nova riječna klimatologija), može se zaključiti da:

1. uključivanje nove riječne klimatologije je nešto povisilo salinitet u MED12F2, a time i gustoću u srednjim i dubokim slojevima Jadrana (posebice u istočnom obalnom dijelu sjevernog Jadrana). Iznimka je površina, gdje je prosječni salinitet u MED12F2 nešto niži nego u MED12F1. Stoga je simulacija MED12F2 rezultirala manjim poboljšanjem u reprodukciji oba konvektivna procesa u Jadranu. Razlog niskim razlikama u dvjema simulacijama je ukupni riječni dotok u Jadran. Naime, iako se način predstavljanja riječnih dotoka u Jadransko more razlikuje u simulacijama MED12F1 i MED12F2 (vidi poglavlje 2.1.2.), njihovi ukupni prosječni godišnji volumeni u Jadranu su veoma blizu (3720 m^3/s naspram 3630 m^3/s), stoga je utjecaj na snagu i brzinu stvaranja gustih voda u Jadranu neznatan (Verri i sur., 2018). Uključivanje nove riječne klimatologije je neznatno utjecalo na BiOS indeks, osim u godinama 1997. i 1998. te u 2008. i 2009. godini kad su razlike uočljivije.

2. uključivanje trenda aerosola nije značajno promijenilo termohalina svojstva Jadrana, ali je značajno promijenilo vrijeme trajanja anticiklonalnih perioda BiOS-a. U simulaciji MED8C3 s uključenim trendom aerosola, drugi anticiklonalni period se završio početkom 2011. godine, dok se u MED8C2-u nastavio sve do kraja simuliranog razdoblja.

Da bi se rangirala važnost pojedinih čimbenika na varijabilnost stvaranja gustih voda te BiOS-a, procijenjene su korelacije između parametara koji opisuju spomenute procese (anomalija potencijalne gustoće u sjevernom Jadranu u veljači – za analizu Sjevernojadranske vode te kumulativni transport kroz Otrant – za analizu Južnojadranske vode) i potencijalnih „pokretača“ tih procesa u simulacijama (slika 43):

- zimski (SPSV) površinski protoci topline u sjevernom i južnom dijelu Jadrana (područja 1 i 2 na slici 7),
- salinitet u veljači za ista područja sjevernog i južnog Jadrana, te
- riječni protoci procijenjeni za prethodnu godinu u sjevernom Jadranu te u čitavom Jadranu.

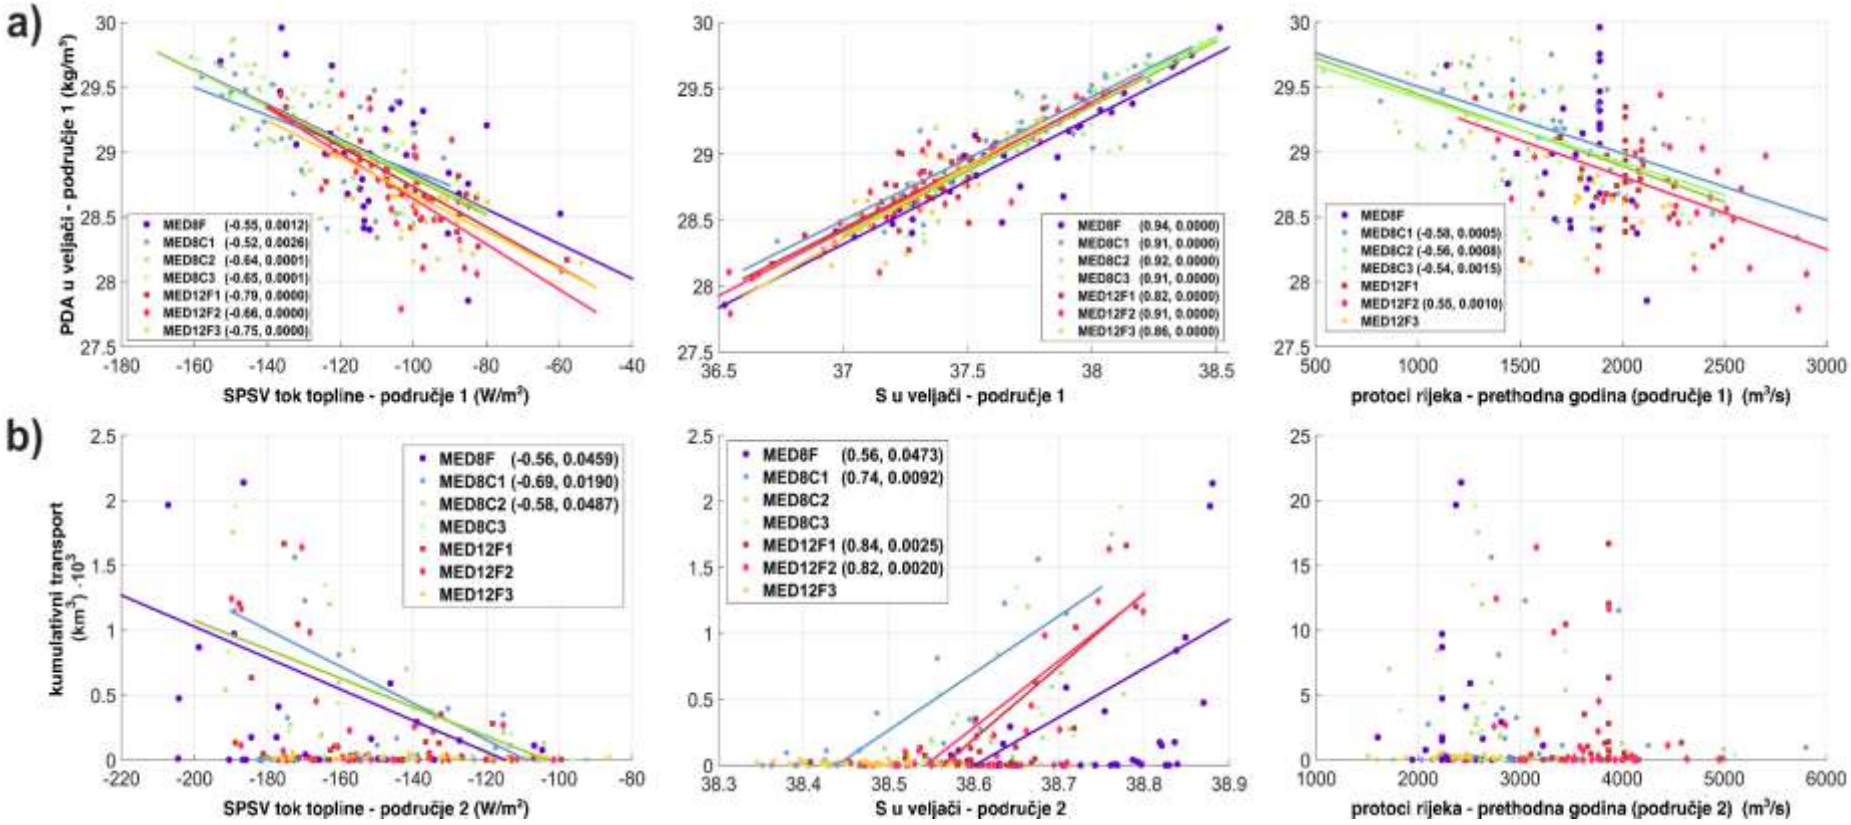
Pri tome su uzete u obzir samo značajne vrijednosti korelacija na razini značajnosti od 95%.

Što se tiče simuliranog stvaranja Sjevernojadranske vode (slika 43a), najznačajnija korelacija s gustoćom u veljači za sve simulacije je uspostavljena sa salinitetom u veljači u

sjevernom Jadranu. Nešto slabija veza je nađena sa zimskim hlađenjem površine mora (SPSV), rangirajući efekt gubitaka topline u sjevernom Jadranu manje bitnim od saliniteta za stvaranje Sjeverojadranske vode. Slaba korelacija je nađena između anomalije potencijalne gustoće u veljači i riječnih protoka, čime je međugodišnja varijabilnost dotoka svježe vode rijekama najmanje važna za stvaranje guste vode u sjevernom Jadranu u analiziranim simulacijama. Međutim, širenje riječnih vodenih masa značajno utječe na prostornu razdiobu stvaranja guste vode (vidi poglavlje 4.5.1.1.). Različiti nagibi pravaca regresije između anomalije potencijalne gustoće i protoka topline u razdoblju SPSV u sjevernom Jadranu ukazuju na to da brzina hlađenja za istu količinu gubitaka energije varira među simulacijama, dok je odnos između anomalije potencijalne gustoće i saliniteta u veljači podjednak u svim simulacijama.

Kod stvaranja Južnojadranske vode (slika 43b), pronađena je slabija korelacija između transporta jadranske duboke vode i „pokretača“ procesa. Salinitet u veljači u južnom Jadranu i zimski površinski gubici topline imaju jednako važnu ulogu za istjecanje Južnojadranske vode prema Jonskom moru. S druge strane, riječni protoci ne pokazuju značajnu korelaciju s kumulativnim transportom. Uočava se i bitna razlika između simulacija spregnutih i nespregnutih modela; nespregnuti modeli daju značajniju korelaciju transporta sa salinitetom u veljači, dok je kod spregnutih modela zimsko hlađenje najznačajniji „pokretač“ procesa.

Veza između BiOS indeksa i „pokretača“ BiOS-a (npr. transport jadranske guste vode kroz Otrant ili maksimalna dubina miješanja u Južnojadranskoj kotlini) nije uspostavljena na razini značajnosti od 95%. Kao što je prije spomenuto, prostorna razdioba cirkulacije u sjevernom Jonskom moru vezana uz BiOS varira među pojedinim simulacijama i nije u potpunosti sukladan opažanjima. Stoga predloženi BiOS indeks (Gačić i sur., 2010) vjerojatno nije u mogućnosti precizno opisati BiOS u analiziranim simulacijama.



Slika 1. Grafovi raspršenja između (a) gustoće u veljači i protoka topline u razdoblju SPSV (lijevi stupac), saliniteta u veljači (srednji stupac), te protoka rijeka iz prethodne godine (desni stupac) u sjevernom Jadranu (područje 1 na Slika 7), te između (b) ukupnog godišnjeg transporta Južnojadranske vode kroz Otrant i protoka topline u razdoblju SPSV (lijevi stupac) i saliniteta u veljači na južnom Jadranu (područje 2 na Slika 7, srednji stupac), te ukupnog protoka jadranskih rijeka iz prethodne godine (desni stupac). U legendi su navedene samo značajne korelacije i njihove p-vrijednosti, koje su također prikazane i linijama na grafovima. Za slučaj (b) procjene korelacija nisu uključivale transport Južnojadranske vode koji je bio ispod 0.1 km^3/god.

5. SIMULACIJE BUDUĆE KLIME

Prema recentnim regionalnim klimatskim projekcijama, klima Sredozemlja će postati toplija i suša tijekom 21. stoljeća. Međutim, pitanje je kako će klimatske promjene utjecati na dinamiku mora, a time i na promjene termohalinih svojstava Sredozemlja, budući da je utjecaj površinskog saliniteta na konvektivne procese nepoznat. Dosadašnja istraživanja numeričkim modelima ukazuju na to da će do kraja 21. stoljeća termohalina cirkulacija Sredozemnog mora oslabiti do 40% u srednjim slojevima i čak do 80% u dubljim slojevima u odnosu na trenutno klimatsko stanje, prvenstveno zbog smanjenja intenziteta zimskih stvaranja gustih voda (Somot i sur., 2006). Termohalina svojstva i pripadni procesi u Jadranu u budućoj klimi još uvijek nisu dovoljno istraženi, a jedini nagovještaj budućih svojstava u Jadranu, temeljen na analizi dostupnih dugoročnih nizova oceanskih podataka, ukazuje na slabljenje termohaline cirkulacije u Jadranu u posljednjih 70 godina (Vilibić i sur. 2013).

Stoga su u ovom poglavlju preliminarno istražene tri potencijalne budućnosti klime u Jadranu u 21. stoljeću, analizirajući polja oceanskog regionalnog klimatskog modela CNRM-RCSM4. Razlog odabira modela CNRM-RCSM4 jest to što su atmosferski i oceanski model spregnuti, a u prethodnom poglavlju je pokazano da spregnuti modeli imaju bolju sposobnost reprodukcije jadranske termohaline cirkulacije, tj. njenih pokretača (stvaranje guste vode te BiOS-a) od nespregnutih.

Napravljene su analize rezultata modela za tri različita scenarija emisija stakleničkih plinova (vidi poglavlje 2.2.1., IPCC, 2013): RCP8.5, RCP4.5 i RCP2.6. Rubni uvjeti zadani u modelu CNRM-RCSM4 su preuzeti iz globalnog klimatskog modela CNRSM – CM5 kojemu je rezolucija atmosferske komponente 50 km, a oceanske 9 - 12 km. Oni ne reproduciraju stvarnu kronologiju termohaline varijabilnosti Sredozemnog mora (Darmaraki i sur., 2019), već statistička obilježja pojedinih klimatskih razdoblja (npr. srednje vrijednosti, varijabilnost). Za potrebe ovog rada definirani su sljedeća 30-godišnja razdoblja projekcija modela:

- bliska budućnost (razdoblje 2011. - 2040.)
- srednja budućnost (razdoblje 2041. - 2070.)
- daleka budućnost (razdoblje 2071. - 2100.)

Dvodimenzionalne varijable modela CNRM-RCSM4 korištene u analizama su vrijednosti prvog sloja modela koji se proteže do 6 m dubine, osim maksimalne dubine miješanja koja je računata iz trodimenzionalnih polja temperature i saliniteta. Za kontrolu kvalitete simulacija svih scenarija, koristila se kontrolna simulacija (CTRL) koja je forsirana površinskim

protocima topline i mase trenutne klime preuzete iz razdoblja 1950. - 1979.. Projekcije triju scenarija (RCP8.5 – visoko-emisijski scenarij, RCP4.5 – srednje-emisijski scenarij, i RCP2.6 – nisko-emisijski scenarij) su uspoređivane sa zadnjih 30 godina povijesne simulacije (HIST, razdoblje 1976. - 2005.), a koje predstavlja referentno razdoblje.

Da bi se izdvojio klimatski signal od prirodne međugodišnje varijabilnosti sadržane u povijesnoj simulaciji, napravljena je procjena intervala pouzdanosti (IP) za 30-godišnje nizove povijesne simulacije (1976. - 2005.). Interval pouzdanosti (IP) se računao sljedećim izrazom:

$$IP = z \cdot \left(\frac{std(vremenski\ niz)}{\sqrt{N}} \right),$$

pri čemu su $N = 30$ (duljina vremenskog niza), a $z = 2.0452$ (vrijednost koja odgovara 95% značajnosti za nizove duljine 30). U daljnjim analizama, za sve prostorne razdiobe odstupanja (anomalije) su prikazane samo za one vrijednosti koje su bile izvan intervala pouzdanosti, tj izvan intervala $[-IP, +IP]$.

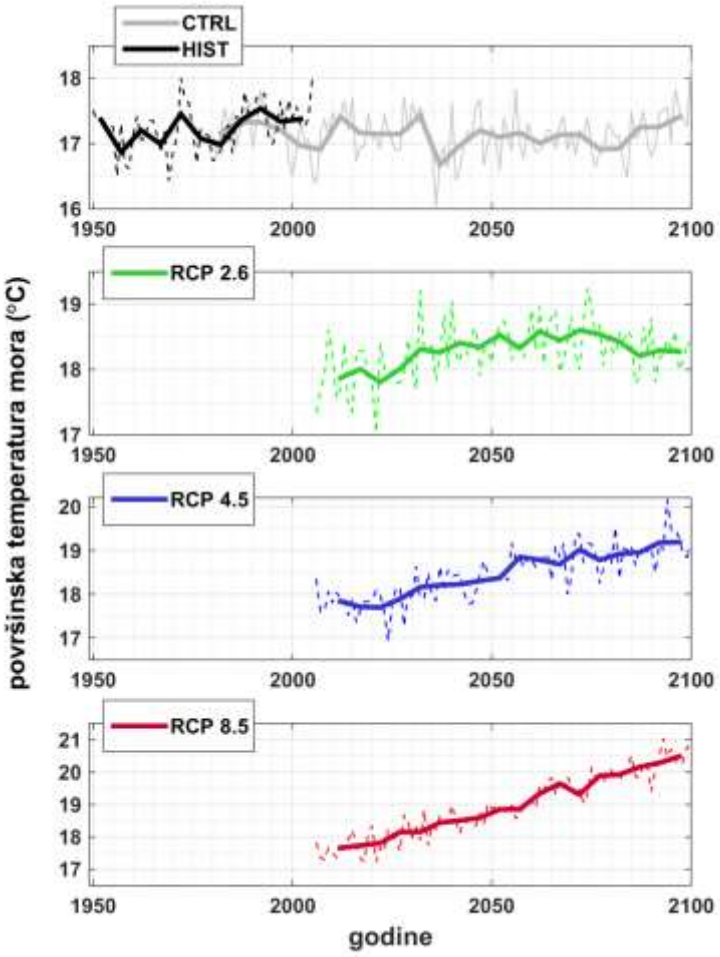
5.1. Analiza projekcija polja temperature

Promjena površinske temperature u različitim scenarijima emisije stakleničkih plinova u 21. stoljeću je uspoređena s referentnim razdobljem. Kako je linearni trend temperature u kontrolnoj simulaciji veoma nizak i beznačajan (0.005 ºC/100 god što nije statistički značajno na razini od 95%), možemo pretpostaviti da projekcije ne sadrže početna odstupanja, već samo signal zadan klimatskim promjenama.

Tablica 2. prikazuje površinske temperature mora usrednjene preko čitavog Jadrana (do transekta u Otrantskim vratima, 40 ºN) za razdoblje povijesne simulacije (HIST), te za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) u razdobljima bliske, srednje i daleke budućnosti. Očekivano, prosječna površinska temperatura Jadrana raste u svim projekcijama. Već i za nisko-emisijski scenarij (RCP2.6), prosječna površinska temperatura mora će se povećati za više od 1 ºC na kraju 21. stoljeća u odnosu na referentno razdoblje (HIST, 1976. - 2005.), dok scenarij RCP4.5 daje porast od 1.7 ºC, a RCP8.5 daje porast od 2.7 ºC. Zanimljivo je primijetiti promjenu površinske temperature u Jadranu u scenariju RCP2.6. Do kraja 2040. godine površinska temperatura u Jadranu raste, nakon čega dominira samo međugodišnja varijabilnost, a nakon 2070. godine temperatura polagano opada prema kraju razdoblja simulacije (slika 44).

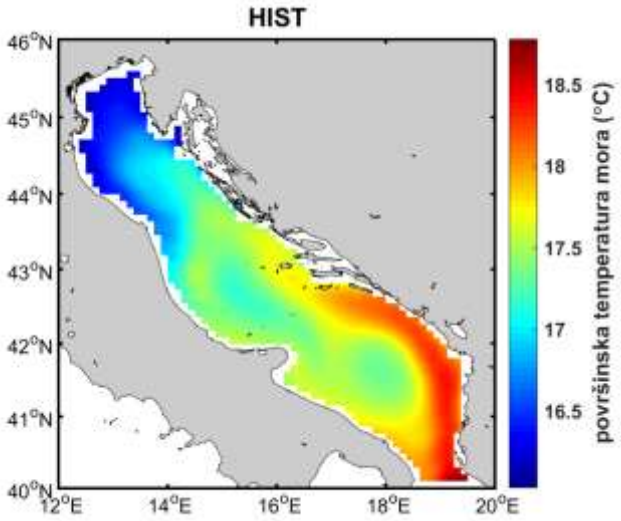
Tablica 2. Prosječne vrijednosti površinske temperature u Jadranu, za povijesnu simulaciju (HIST) u razdoblju od 1976. do 2005. te za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) u razdobljima bliske (2011. - 2040.), srednje (2041. - 2070.) i daleke (2071. - 2100.) budućnosti.

SIMULACIJA	HIST	RCP2.6			RCP4.5			RCP8.5		
razdoblje	1976.-2005.	2011.-2040.	2041.-2070.	2071.-2100.	2011.-2040.	2041.-2070.	2071.-2100.	2011.-2040.	2041.-2070.	2071.-2100.
SST (°C)	17.31	18.07	18.43	18.38	17.94	18.53	19.02	18.04	18.99	20.05

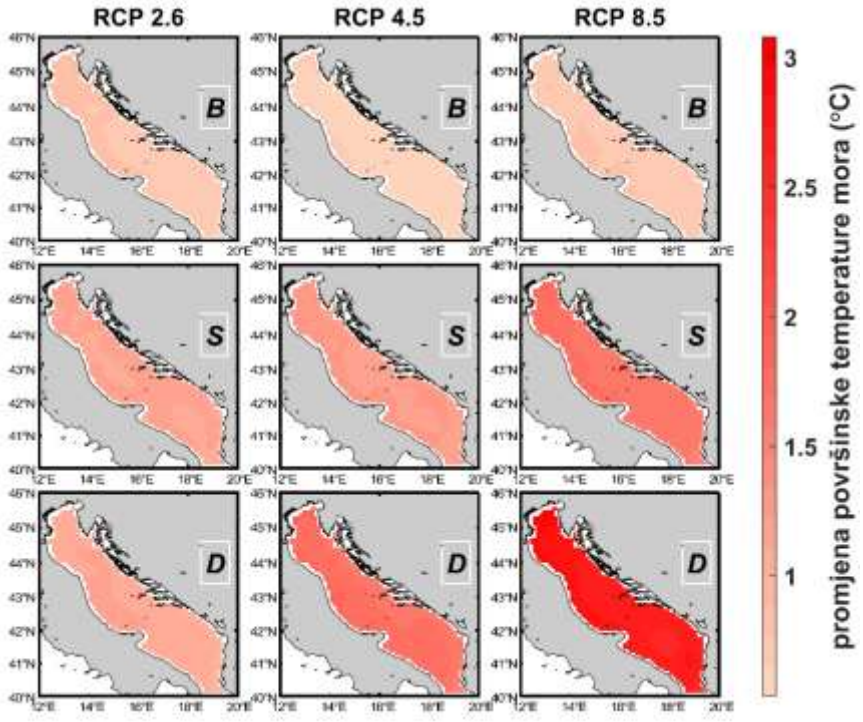


Slika 44. Vremenski nizovi površinskog saliniteta u Jadranu za povijesnu simulaciju (HIST), te za tri scenarija (RCP2.6, RCP4.5 i RCP8.5). Na slici je prikazan i vremenski niz kontrolne simulacije (CTRL). Na y-osi se nalaze različite skale.

Prosječna prostorna razdioba temperature za referentno razdoblje (HIST, slika 45) ukazuje da model pravilno reproducira osnovna svojstva u Jadranu: minimum temperature u sjevernom Jadranu najviše uzrokovan hladnim prodorima bure, maksimum temperature uz istočnu obalu južnog Jadrana koji ukazuje na postojanje sjeverozapadne struje uz istočnu obalu Jadrana, te minimum temperature u središnjem dijelu južnog Jadrana, kao indikator ciklonalnog vrtloga.



Slika 45. Prosječna prostorna razdioba površinske temperature u Jadranu za referentno razdoblje povijesne simulacije (1976. - 2005., HIST).

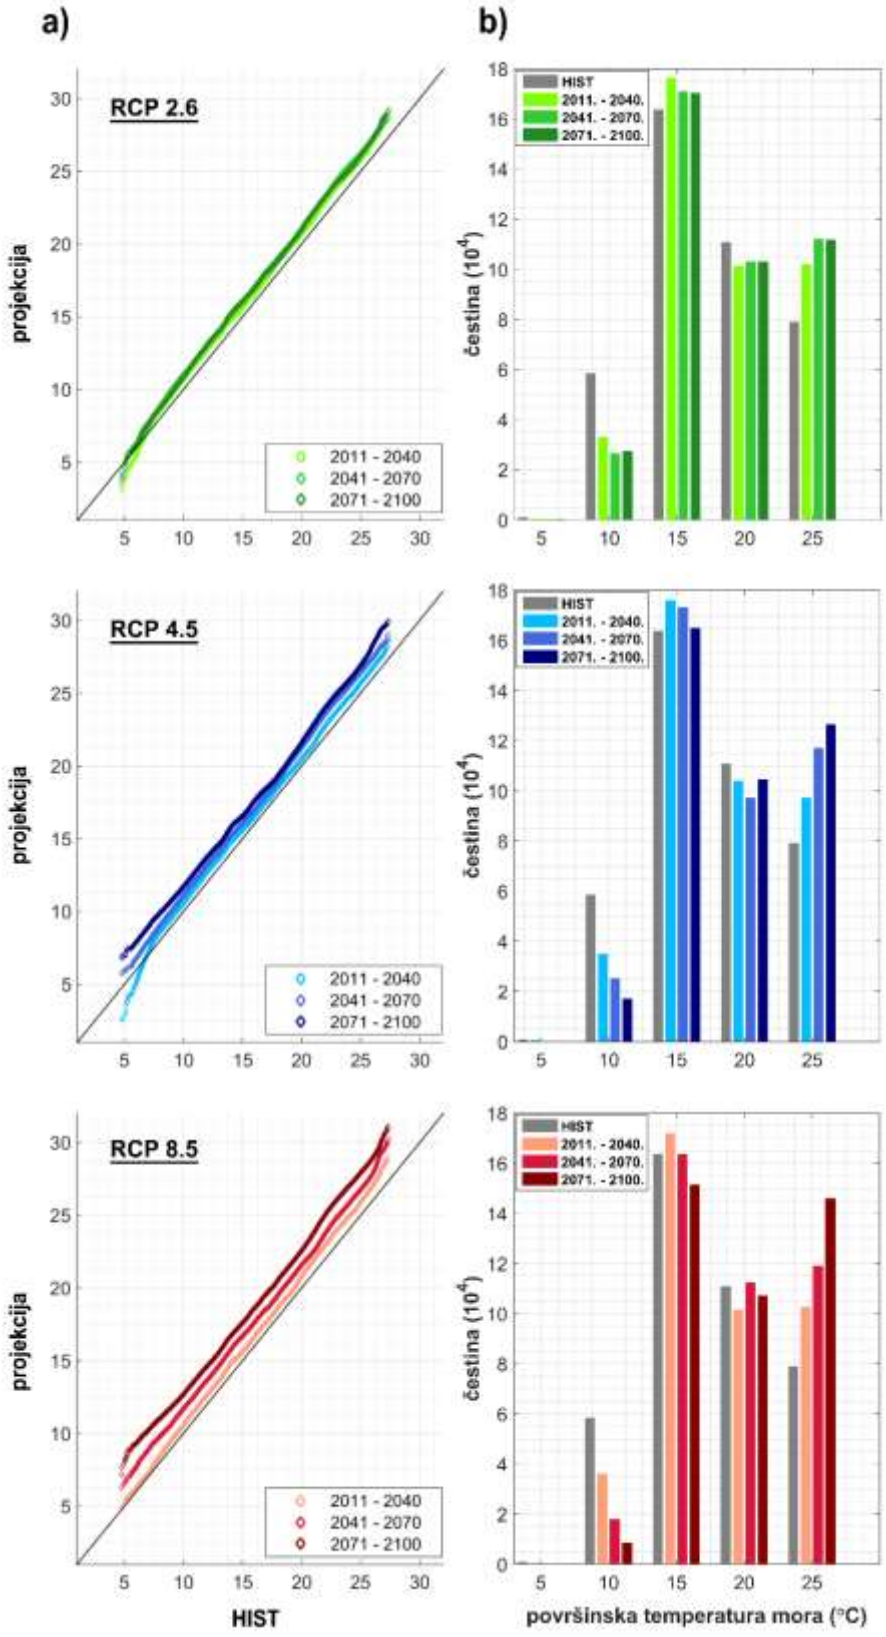


Slika 46. Promjene površinske temperature u Jadranu za tri definirana razdoblja (bliska budućnost – B, srednja budućnost – S i daleka budućnost - D) i za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) u odnosu na referentno razdoblje (1976. - 2005., HIST). Na slici su prikazane samo one vrijednosti koje su izvan intervala pouzdanosti *IP*.

Promjene površinske temperature u Jadranskom moru u budućoj klimi su pozitivne i prostorno homogene u svim razdobljima i za sve scenarije (slika 46). U bliskoj budućnosti (2011. - 2040.), porast površinske temperature mora je sličan u svim scenarijima, te iznosi između 0.6 - 0.7 ^{o}C, dok u ostalim razdobljima (srednje i daleke budućnosti) promjene postaju izraženije za srednje- i visoko-emisijske scenarije (RCP4.5 i RCP8.5). Najviši porast površinske temperature mora na kraju 21. stoljeća u čitavom Jadranu se očekuje u RCP8.5, tj. u scenariju koji pretpostavlja trenutni porast stakleničkih plinova u atmosferi (tzv. *„bussiness-as-usual"* scenarij).

Analiza promjena površinske temperature mora u budućoj klimi u odnosu na temperaturu referentnog razdoblja (HIST, 1976. - 2005.) je načinjena pomoću QQ-grafova i histograma. Najniži porast niskih temperatura (do 13 ^{o}C), uobičajenih za zimsko razdoblje, je nađen u bliskoj budućnosti (2011. - 2040.) scenarija RCP8.5 (slika 47a). Ostale projekcije (RCP4.5 i RCP2.6), u bliskoj budućnosti bilježe nešto niže zimske temperature u odnosu na referentno razdoblje. Ostale vrijednosti temperatura pokazuju porast u odnosu na referentno razdoblje kod svih scenarija. To znači da će, u bliskoj budućnosti, zimsko hlađenje površine

mora i dalje biti snažno (ili snažnije) kao i u povijesnom razdoblju (1976. - 2005.). U kasnijim razdobljima (srednja i daleka budućnost), sve projekcije predviđaju temperaturni porast u cijeloj godini, odnosno po svim percentilima temperature. Štoviše, nakon 2040. godine, sve projekcije pokazuju monotoni rast površinske temperature mora. Slično se može zaključiti iz razdiobe histograma površinske temperature (slika 47b), u kojima se vidi povećanje zimskih (sa oko 10 ^{o}C na oko 15 ^{o}C) i ljetnih temperatura (sa oko 20 ^{o}C na oko 25 ^{o}C).



Slika 47. a) QQ-grafovi površinske temperature u Jadranskom moru projicirane za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) naspram referentnog razdoblja (HIST, 1976. - 2005.), za tri razdoblja (bliska, srednja i daleka budućnost) te b) odgovarajući histogrami. Vrijednosti temperature u histogramima su podijeljene u klase širine 5, čija su središta naznačena na x-osi.

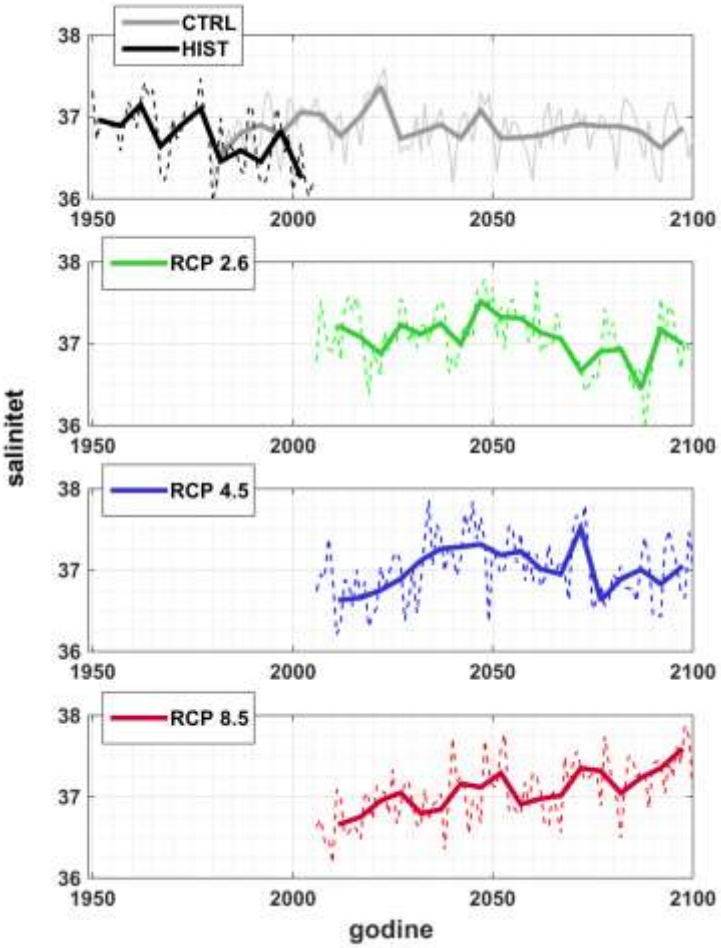
5.2. Analiza projekcija polja saliniteta

Slično kao i kod površinske temperature mora, trend prosječnog saliniteta površine u Jadranskom moru u čitavom razdoblju kontrolne simulacije, je nizak (-0.05/100 god) i nije statistički značajan. To dodatno potvrđuje stabilnost modela CNRM-RCSM4, i vjerodostojnost reproduciranja klimatskog signala u trima scenarijima (RCP8.5, RCP4.5 i RCP2.6).

U usporedbi s referentnim razdobljem, prosječni površinski salinitet Jadrana pokazuje rast u 21. stoljeću, zabilježen kod svih triju projekcija (tablica 3.). Najviši porast na kraju 21. stoljeća (razdoblje daleke budućnosti) je nađen u scenariju RCP8.5 (salinitet viši za 0.71). Nešto niži porast daje scenarij RCP4.5 (za 0.38), dok se najniži porast predviđa scenarijem RCP2.6 (za 0.27). Porast površinskog saliniteta je u skladu s analizama projekcija za čitavo Sredozemlje (Somot i sur., 2006). Scenariji RCP2.6 i RCP4.5 daju najveće poraste površinskog saliniteta u razdoblju srednje budućnosti (2041. - 2070., porast od 0.64 za RCP2.6 i od 0.58 za RCP4.5), nakon čega se prosječni površinski salinitet u Jadranu u tim scenarijima smanjuje.

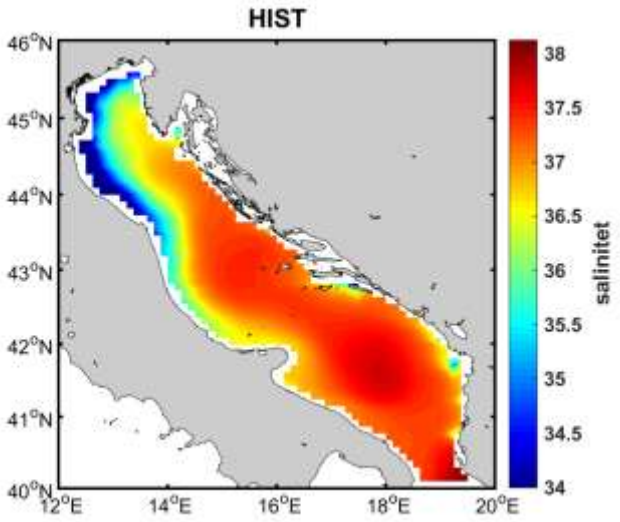
Tablica 3. Prosječne vrijednosti površinskog saliniteta u Jadranu, za povijesnu simulaciju (HIST) u razdoblju od 1976. do 2005. te za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) u razdobljima bliske (2011. - 2040.), srednje (2041. - 2070.) i daleke (2071. - 2100.) budućnosti.

SIMULACIJA	**HIST**	**RCP2.6**			**RCP4.5**			**RCP8.5**		
razdoblje	1976.-2005.	2011.-2040.	2041.-2070.	2071.-2100.	2011.-2040.	2041.-2070.	2071.-2100.	2011.-2040.	2041.-2070.	2071.-2100.
SST	36.59	37.13	37.23	36.86	36.90	37.17	36.97	36.9	37.07	37.30

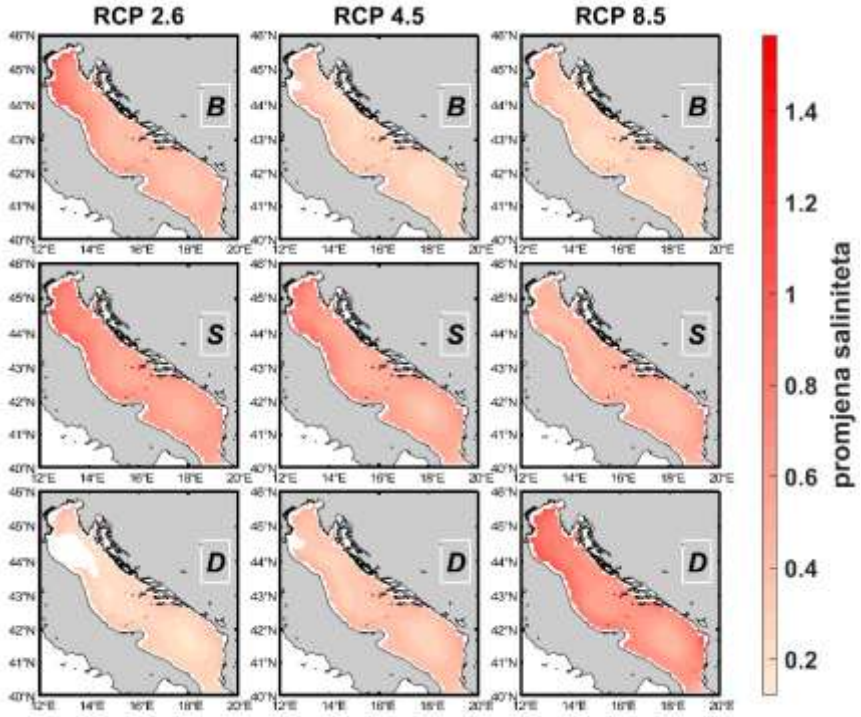


Slika 48. Vremenski nizovi površinskog saliniteta u Jadranu za povijesnu simulaciju (HIST), te za tri scenarija (RCP2.6, RCP4.5 i RCP8.5). Na slici je prikazan i vremenski niz kontrolne simulacije (CTRL).

Za razliku od promjena površinske temperature mora, utjecaj klimatskih promjena na površinski salinitet nije toliko uočljiv, zbog jakog prirodnog signala međugodišnje i dekadske varijabilnosti sadržane u svim simulacijama, pa tako i u kontrolnoj simulaciji (slika 48). Jedina simulacija koja prikazuje relativno jasnu sliku rasta površinskog saliniteta po razdobljima je RCP8.5, iako je i kod te simulacije vidljiva snažna varijabilnost. Razlog tome je što je površinski salinitet u Jadranu uvjetovan dotocima rijeka, i pod utjecajem je BiOS-a (Gačić i sur., 2010), koji zajedničkim djelovanjem „definiraju“ njegovu snažnu međugodišnju i dekadsku varijabilnost u Jadranu. Stoga se za pravilnu procjenu utjecaja klimatskih promjena na površinski salinitet u Jadranu načinila analiza promjena površinskog saliniteta u budućoj klimi u odnosu na povijesnu klimu, i to samo s vrijednostima koje su izlazile iz intervala pouzdanosti procijenjenog na temelju povijesne simulacije.

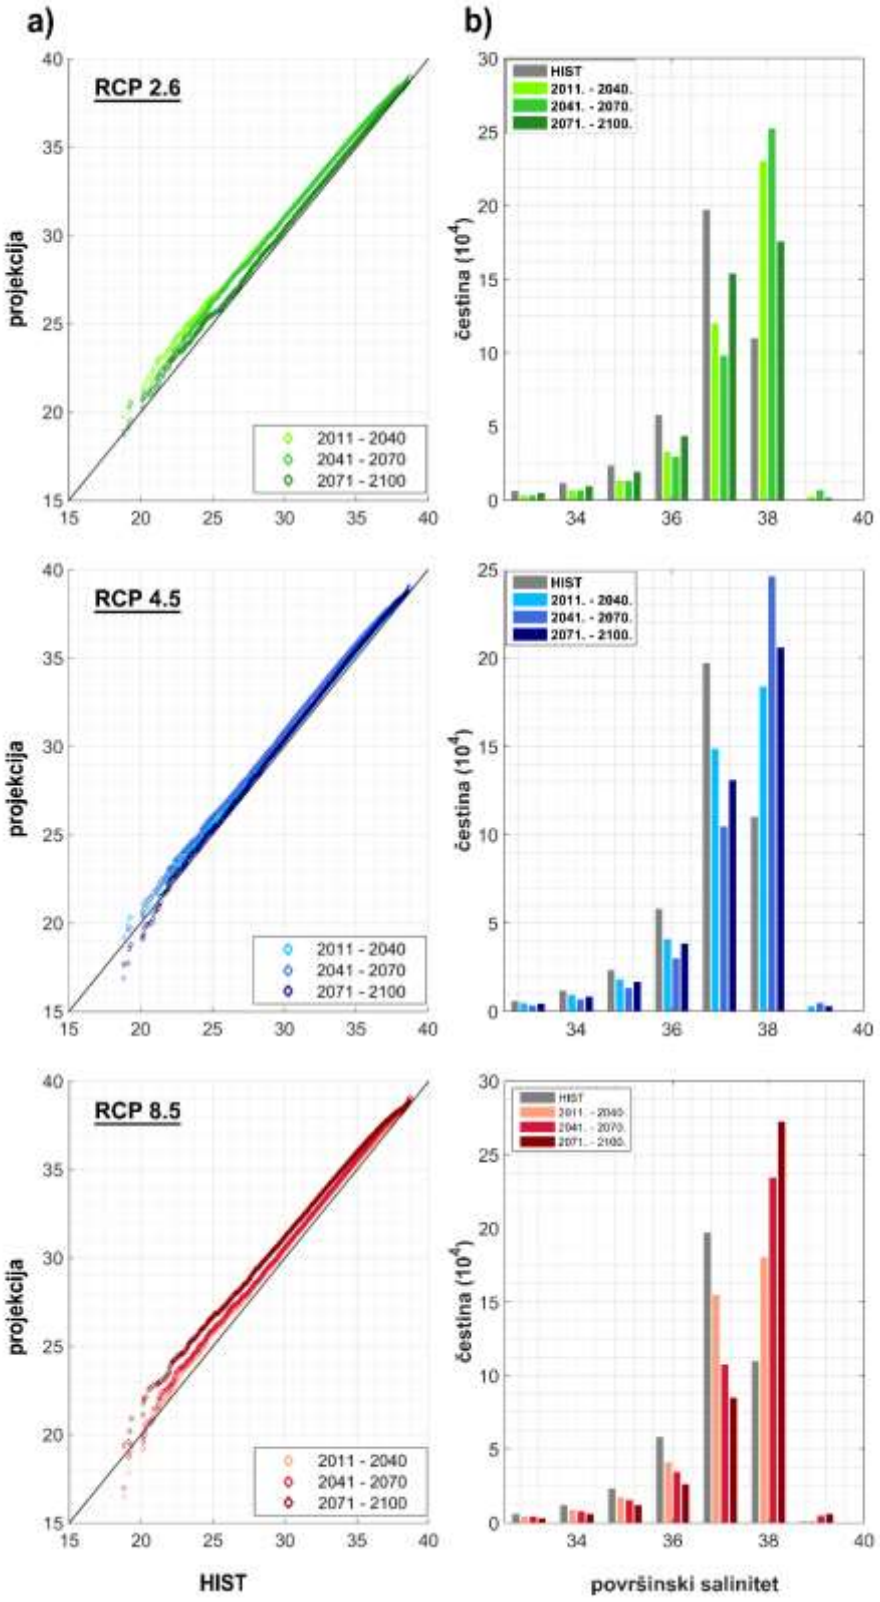


Slika 49. Prosječna prostorna razdioba površinskog saliniteta u Jadranu za referentno razdoblje povijesne simulacije (1976. - 2005., HIST).



Slika 50. Promjene površinskog saliniteta u Jadranu za tri definirana razdoblja (bliska budućnost – B, srednja budućnost – S i daleka budućnost - D) i za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) u odnosu na referentno razdoblje (1976. - 2005., HIST). Na slici su prikazane samo one vrijednosti koje su izvan intervala pouzdanosti *IP*.

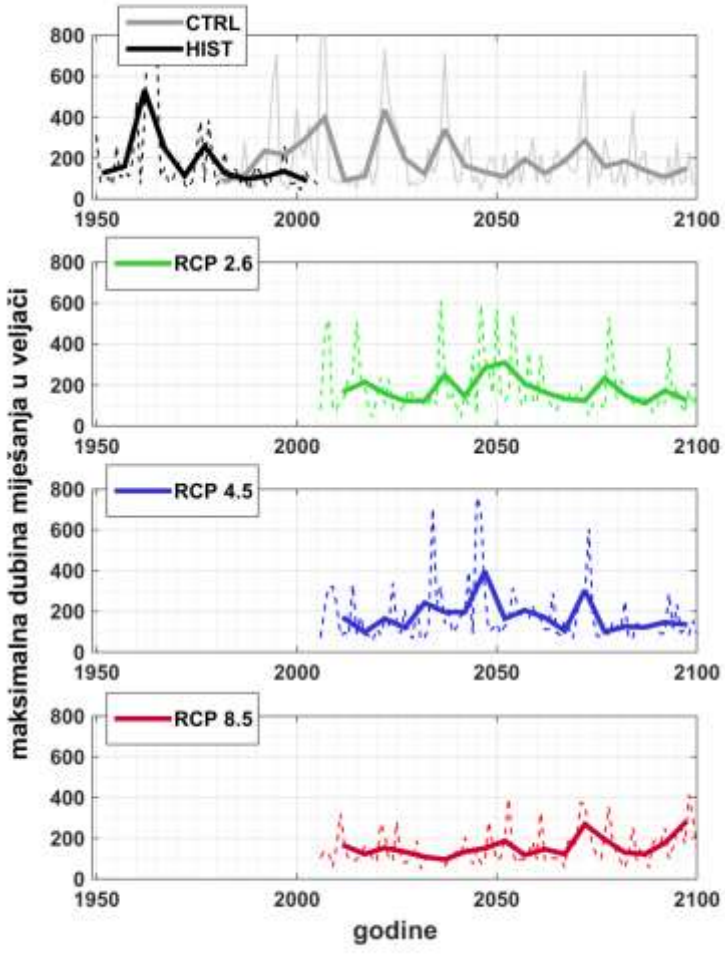
Polje prostorne razdiobe površinskog saliniteta povijesne simulacije za razdoblje 1976. - 2005. (slika 49) je u suglasju sa zabilježenim poljima u sadašnjoj klimi. Model reproducira minimume saliniteta u obalnom području sjevernog i zapadnog Jadrana pod utjecajem sjevernojadranskih rijeka, Zapadno-jadransku obalnu struju koje je izražena sve do rta Gargano, i maksimalne vrijednosti u središnjem dijelu srednjeg i južnog Jadrana (Artegiani i sur., 1997a; Lipizer i sur., 2014). U gotovo svim područjima Jadrana, i za sve projekcije, uočava se porast saliniteta u odnosu na referentno razdoblje (HIST, 1976. - 2005., slika 50), s većim porastom u priobalnim područjima karakteriziranim niskim salinitetom (slika 51b). Kod scenarija RCP2.6 snažniji rast saliniteta je zabilježen u područjima utjecaja sjevernojadranskih rijeka (slika 50 i slika 51b), što može ukazati na smanjenje riječnih protoka u bliskoj i srednjoj budućnosti (do 2070. godine). Daleka budućnost (2071. - 2100.) u scenariju RCP2.6 je karakterizirana nižim porastom površinskog saliniteta u usporedbi sa srednjom budućnosti (2041. - 2070.), ali i snažnijim dekadskim oscilacijama (slika 48), što može ukazati na jačanje BiOS-a. Slične promjene se očekuju i sa scenarijem RCP4.5, ali s višim porastom površinskog saliniteta. Najsnažniji utjecaj klimatskih promjena se predviđa scenarijem RCP8.5, čija simulacija pokazuje značajan porast površinskog saliniteta u Jadranu, mjestimično preko 1.45 (u pojedinim obalnim područjima Jadrana, slika 51a).



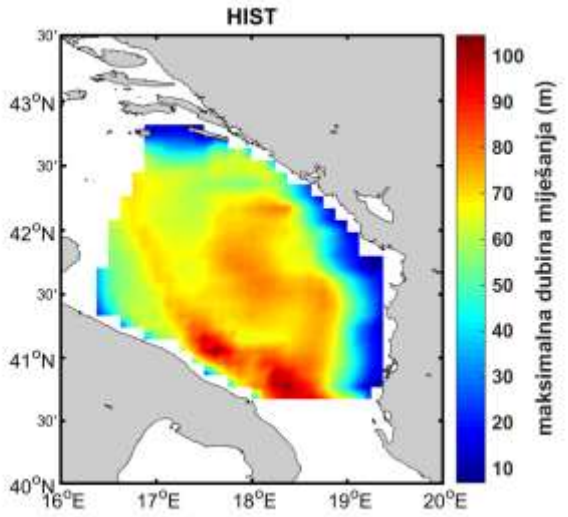
Slika 51. a) QQ-grafovi površinskog saliniteta u Jadranskom moru projiciranog za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) naspram referentnog razdoblja (HIST, 1976. - 2005.), za tri razdoblja (bliska, srednja i daleka budućnost) te b) odgovarajući histogrami. Vrijednosti saliniteta u histogramima su podijeljene u klase širine 1, čija su središta naznačena na x-osi.

5.3. Analiza projekcija dubine miješanja

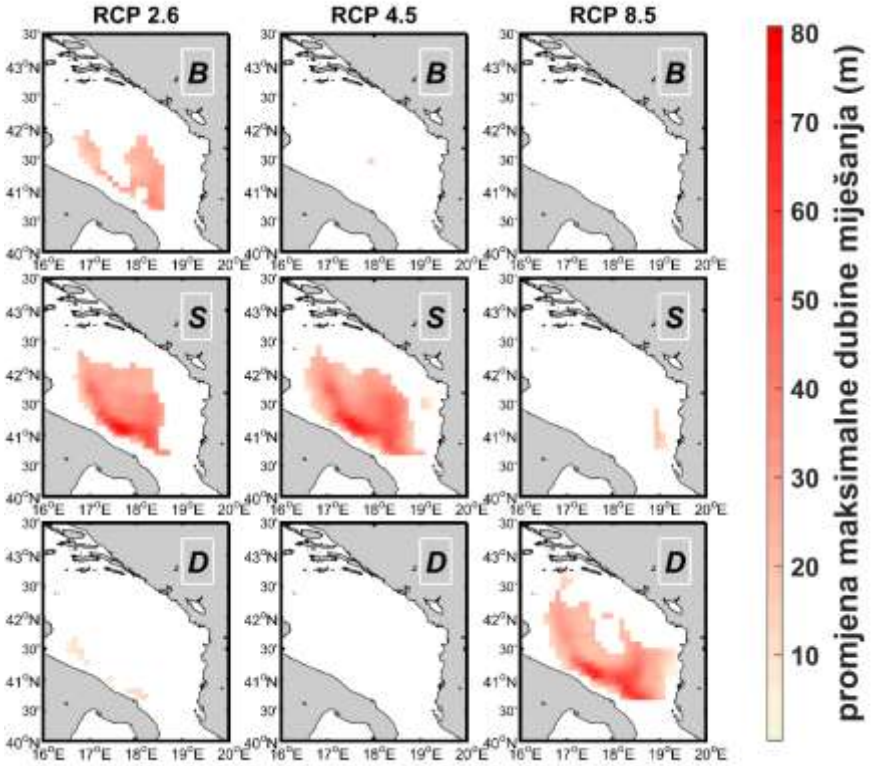
Vremenski nizovi godišnjih maksimalnih dubina miješanja u južnom Jadranu (područje prikazano na slici 53) su prikazani na slici 52. Maksimalna dubina miješanja je izdvojena iz dnevnih vrijednosti dubine miješanja za veljaču, kada ona i doseže svoje najveće vrijednosti, za vrijeme duboke konvekcije. U bliskoj i srednjoj budućnosti, scenariji RCP2.6 i RCP4.5 predviđaju izraženiju varijabilnost i snažniju konvekciju u usporedbi s referentnim razdobljem, dok u daljnjoj budućnosti konvektivni procesi slabe. U scenariju RCP8.5 nije zabilježen ni jedan događaj izraženije duboke konvekcije, uz maksimalnu dubinu miješanja do 400 m. Potrebno je primijetiti da je dubina miješanja u referentnom razdoblju (HIST, 1976. - 2005.) bitno niža u odnosu na prethodno razdoblje u istoj simulaciji.



Slika 52. Vremenski nizovi maksimalne dubine miješanja u veljači u južnom Jadranu za povijesnu simulaciju (HIST), te za tri scenarija (RCP2.6, RCP4.5 i RCP8.5). Na slici je prikazan i vremenski niz kontrolne simulacije (CTRL).



Slika 53. Prosječna prostorna razdioba maksimalne dubine miješanja u veljači u Jadranu za referentno razdoblje povijesne simulacije (1976. - 2005., HIST).



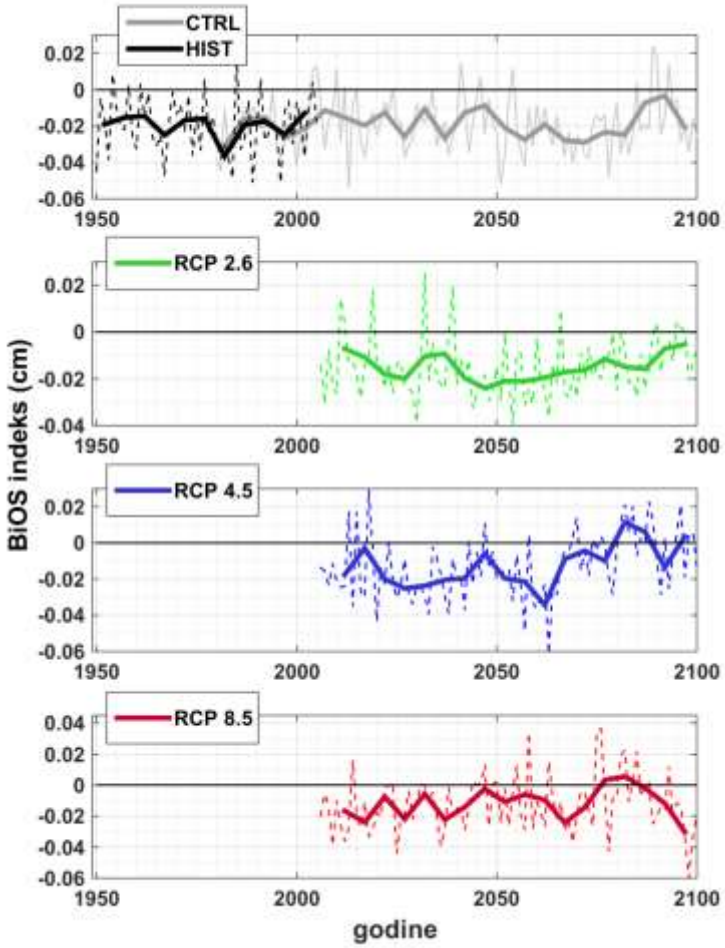
Slika 54. Promjene maksimalne dubine miješanja u južnom Jadranu u veljači za tri definirana razdoblja (bliska budućnost – B, srednja budućnost – S i daleka budućnost - D) i za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) u odnosu na referentno razdoblje (1976. - 2005., HIST). Na slici su prikazane samo one vrijednosti koje su izvan intervala pouzdanosti *IP*.

Za povijesnu simulaciju u razdoblju 1976. - 2005., prosječna prostorna razdioba maksimalne dubine miješanja u veljači je prikazana na slici 53. Slično kao i kod simulacije MED8F (vidi poglavlje 3.4.), područje snažnije zimske konvekcije je smješteno na južnom rubnom dijelu Južnojadranske kotline, dok je nešto slabija konvekcija vidljiva u njenom najdubljem središnjem dijelu. Upravo na području gdje je simulirana najsnažnija konvekcija, scenarij RCP8.5 u daljnjoj budućnosti jasno daje porast maksimalne dubine miješanja u veljači, i to do 80 m (slika 54). Drugi scenariji pokazuju vidljive promjene u srednjoj budućnosti (2041. - 2070.), s najvećim povećanjem maksimalne dubine miješanja u južnom rubnom dijelu, i nešto slabijim u središtu. U ostalim razdobljima, utjecaj klimatskih promjena se nije mogao razabrati, obzirom na jaku prirodnu varijabilnost konvekcije u južnom Jadranu.

5.4. Analiza projekcija BiOS-a

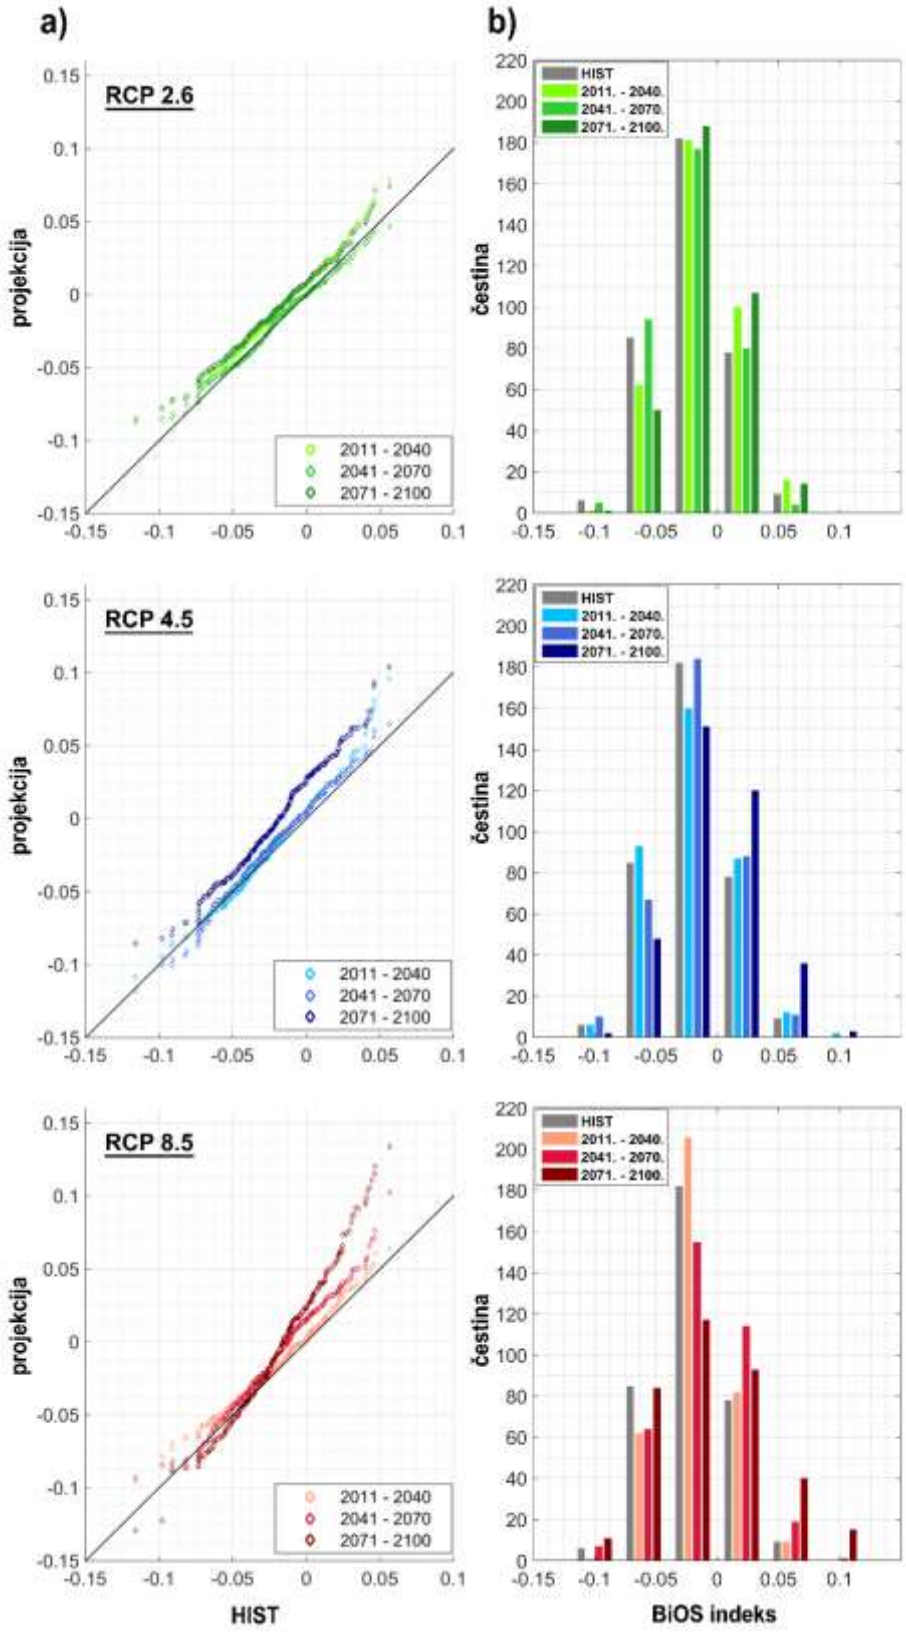
Ponašanje BiOS-a u budućoj klimi se analiziralo pomoću pojednostavljenog BiOS indeksa. Kontrolna simulacija bilježi veoma slab i neznačajan pozitivan trend BiOS indeksa (0.02 cm/100 godina).

Oscilacije vremenskih nizova BiOS indeksa su nasumičnog karaktera, te se ne mogu jasno razabrati razlike među pojedinim razdobljima (slika 55). Međutim, scenarij RCP4.5 vidljivo predviđa povećanje indeksa prema kraju 21. stoljeća, što upućuje na učestaliju pojavu anticiklonalne cirkulacije u sjevernom Jonskom moru i veću advekciju manje slanih voda iz zapadnog Sredozemlja u Jadran. Varijabilnost BiOS indeksa se pojačava u scenariju RCP8.5 prema kraju 21. stoljeća, dok je varijabilnost indeksa najmanja u RCP2.6 scenariju.



Slika 55. Vremenski nizovi godišnje usrednjenog BiOS indeksa za povijesnu simulaciju (HIST), te za tri scenarija (RCP2.6, RCP4.5 i RCP8.5). Na slici je prikazan i vremenski niz kontrolne simulacije (CTRL).

QQ-graf svih vrijednosti BiOS indeksa u scenarijima RCP4.5 i RCP2.6 te odgovarajući histogrami (slika 56) ukazuju na pomak BiOS-indeksa prema anticiklonalnoj cirkulaciji (učestalije pozitivne vrijednosti BiOS indeksa), posebice u dalekoj budućnosti. To bi značilo da će advekcija vodenih masa nižeg saliniteta iz zapadnog Sredozemlja prema Jadranu biti snažnija i učestalija u budućnosti nego li advekcija Levantinske intermedijarne vode. Scenarij RCP8.5 predviđa slično ponašanje BiOS indeksa u razdobljima bliske i srednje budućnosti. No u razdoblju daleke budućnosti (2071. - 2100.) uočava se izrazito jačanje anticiklonalne cirkulacije BiOS-a, uz istovremeno blago jačanje ciklonalne cirkulacije. Rast BiOS indeksa i učestalija pojavljivanja pozitivnih vrijednosti se vide i na histogramima (slika 56b), posebice u razdoblju daleke budućnosti kod svih scenarija.



Slika 56. a) QQ-grafovi BiOS indeksa projiciran za tri scenarija (RCP2.6, RCP4.5 i RCP8.5) naspram referentnog razdoblja (HIST, 1976. - 2005.), za tri razdoblja (bliska, srednja i daleka budućnost) te b) odgovarajući histogrami. Vrijednosti indeksa u histogramima su podijeljene u klase širine 0.04, čija su središta naznačena na x-osi.

5.5. Diskusija

U ovom poglavlju napravljena je analiza buduće klime Jadranskog mora za tri scenarija porasta stakleničkih plinova do kraja 21. stoljeća modelom CNRM-RCSM4: RCP2.6, RCP4.5 i RCP8.5 (IPCC, 2013). Za čitav Jadran očekivan je postupan porast površinske temperature mora tijekom cijele godine i za sve scenarije, od kojih RCP8.5 daje najveće prosječne vrijednosti temperature na kraju 21. stoljeća (20.05 ^{o}C). Rast temperature u Jadranskom moru u svim scenarijima je gotovo homogen. S druge strane, predviđeni porast saliniteta je heterogen, s većim porastom u priobalnim područjima Jadrana. Najviši porast saliniteta koncem 21. stoljeća je simuliran scenarijem RCP8.5.

Kombinacija projekcija temperature i saliniteta je rezultirala zanimljivim projekcijama maksimalne dubine miješanja, koja je indikator procesa duboke konvekcije u južnom Jadranu. Razdioba promjena maksimalne dubine miješanja je različita za scenarije RCP2.6 i RCP4.5, te RCP8.5. Prva dva scenarija daju najveći porast maksimalne dubine miješanja u razdoblju srednje budućnosti (2041. - 2070.), kad su zabilježene intenzivnije i učestalije zimske konvekcije u južnom Jadranu, nešto jače na južnom rubnom dijelu. S druge strane, klimatski signal u scenariju RCP8.5 daje tek slabije povećanje južnojadranske konvekcije na samom kraju 21. stoljeća, također na južnom rubnom dijelu Južnojadranske kotline. Povećanje maksimalne dubine miješanja na rubnom dijelu može biti uzrokovano smanjenjem zimske stratifikacije tog područja i/ili povećanjem zimskih gubitaka topline s površine mora zbog snažnijih zimskih bura. Za kvalitetniju procjenu prostornih promjena duboke konvekcije u južnom Jadranu u budućnosti, potrebno je napraviti analizu koja bi uključivala procjenu evolucije termohalinih parametara dubokih slojeva južnog Jadrana, te procjenu površinskih protoka topline. Također je potrebno naglasiti da je maksimalna dubina miješanja niska u referentnom razdoblju, te mnogo viša u razdoblju koji mu prethodi, što bitno umanjuje vjerodostojnost iznesenih zaključaka.

Što se tiče BiOS-a, RCP4.5 predviđa jačanje anticiklonalnog režima do kraja 21. stoljeća (povećanje pozitivnog BiOS indeksa), što bi moglo pogodovati jačoj advekciji voda nižeg saliniteta iz zapadnog Sredozemlja prema Jadranu. Posljedično, intenzitet duboke konvekcije u južnom Jadranu bi mogao oslabiti. S druge strane, scenarij RCP8.5 ukazuje na sveukupno jačanje mehanizma BiOS-a, manje izraženo u ciklonalnoj a više u anticiklonalnoj fazi.

Treba napomenuti, da se u ovom poglavlju istraživao samo jedan oblik nepouzdanosti klimatskog modela CNRM-RCSM4; odnos scenarija i kontrolne simulacije. Stoga je složenost

analiza i rezultata ograničena, a zaključci su tek preliminarni. Za bolju procjenu projekcija buduće klime Jadranskog mora potrebno je napraviti usporedbu s drugim regionalnim klimatskim modelima koja uključuju područje Jadranskog mora, čime bi se mogla kvantificirati i vjerodostojnost samih promjena. Na žalost, za vrijeme izrade ovog rada, izlazna polja drugih klimatskih modela ovog tipa nisu bila dostupna.

6. ZAKLJUČCI

U ovoj disertaciji je napravljena detaljna analiza sedam simulacija temeljenih na oceanskom modelu NEMOMED, koje se međusobno razlikuju u nekoliko modelskih postavki (prostornoj rezoluciji, atmosferskom i riječnom forsiranju, uključivanju ili ne trenda aerosola, te spregnutost/nespregnutost sustava atmosfera-more). Cilj analiza je bila detekcija glavnih nedostataka modela, te pronalazak optimalnog konfiguracijskog modelskog sustava koji kvalitetno reproducira termohalinu dinamiku jadransko-jonskog bazena.

Analize su pokazale da grublja horizontalna i vertikalna rezolucija oceanskog modela utječe na miješanje, dinamiku i širenje vodenih masa, posebice u plićim područjima kao što je sjeverni Jadran. Veća prostorna i vremenska rezolucija atmosferskog forsiranja ALDERA (~ 13 km, 3-satno) je rezultirala realističnijom bilancom topline na površini mora, a time i nižim temperaturnim odstupanjima u cijelom vodenom stupcu. Veća prostorna rezolucija oceanskog modela je dovela do bolje reprodukcije dinamike i svojstava Levantinske intermedijarne vode, što je u kombinaciji s poboljšanom riječnom klimatologijom smanjilo odstupanje saliniteta u simulacijama. Međutim, najbolja reprodukcija stvaranja guste vode u plitkom sjevernom Jadranu je ostvarena sa spregnutim modelima, u kojima su površinski gubici topline za 20 - 30% viši nego li je kod nespregnutih modela.

Veća horizontalna rezolucija, posebice u donjim slojevima mora, može popraviti reprodukciju dinamike kompleksne mezoskalne ciklonalne/anticiklonalne cirkulacije koja kontrolira konvektivne procese u sjevernom Jadranu, a što je zapaženo kod simulacije MED12F3. Ta simulacija nepravilno reproducira termohalina svojstva Jadrana, vjerojatno zbog podcijenjene bilance vode, definirane evaporacijom, oborinama i riječnim protocima, kao i kratkim trajanjem perioda prilagodbe (6 godina). Međutim, zbog svoje visoke horizontalne rezolucije koja u Jadranskom moru iznosi oko 2 km, MED12F3 se pokazala uspješnijom od ostalih simulacija u reprodukciji dinamike vodenih masa na otvorenom dijelu sjevernog Jadrana.

Kad je u pitanju stvaranje guste vode u južnom Jadranu, treba imati na umu dva bitna čimbenika. Jedan od čimbenika pravilne reprodukcije stvaranja Južnojadranske vode je i sposobnost reprodukcije stvaranja Sjevernojadranske vode, kao i njeno širenje prema pridnenim slojevima dubokih jadranskih kotlina. Visoke temperature, zabilježene u svim simulacijama, su smanjile stabilnost vodenog stupca u dubokim dijelovima Južnojadranske kotline, stoga je maksimalna dubina miješanja u pojedinim godinama i simulacijama dosizala samo dno kotline.

U stvarnosti, procijenjena maksimalna dubina miješanja nije išla dublje od 900 m (Gačić i sur., 2002). Nestabilnosti vertikalnog stupca mora u kojem se odvija proces miješanja je doprinijela i nepravilna reprodukcija svojstava i advekcije Levantinske intermedijarne vode u srednjim slojevima Jadrana, posebice vidljivo u nespregnutim modelima sa smanjenim salinitetom. Drugi bitan čimbenik stvaranja Južnojadranske vode je njezin okidač, tj. snažni prodori hladne zimske bure (Grisogono i Belušić, 2009). Uz visoku rezoluciju atmosferskog forsiranja, pravilna reprodukcija pokretanja procesa duboke konvekcije u južnom Jadranu zahtijeva i realističnu reprezentaciju interakcije između mora i atmosfere. U ovom slučaju, spregnuti modeli, zbog svoje sposobnosti eksplicitnog rješavanja spregnutosti sustava atmosfera-more, se bolje ponašaju nego nespregnuti.

Spregnuti modeli su bolji odabir za reprodukciju BiOS-a, koji je odgovoran za opažene dekadske oscilacije cirkulacije sjevernog Jonskog mora. Međutim, kako analizirani modeli neadekvatno simuliraju prostorna obilježja BiOS-a, veza između BiOS indeksa i dinamičkih varijabli BiOS-a (npr. transport Južnojadranske vode kroz Otrantska vrata, ili maksimalna dubina miješanja u Južnojadranskoj kotlini) nije značajna kod svih simulacija. Stoga, da bi se BiOS preciznije opisao u simulacijama, potrebno je primijeniti kompleksnije metode analiza (Reale i sur., 2017).

Važno je istaknuti da ansambl od sedam NEMOMED-simulacija nije napravljen ciljano za istraživanje utjecaja pojedinih postavki modela na reprodukciju dinamike Jadranskog mora, što ograničava mogućnost donošenja kvalitetnih zaključaka o pojedinim razlikama simulacija. Također, treba napomenuti da su analizirane simulacije spregnutim i nespregnutim modelima različitih prostornih rezolucija. Stoga, nije bilo moguće kvantificirati stvarni utjecaj spregnutosti/nespregnutosti sustava na termohaline procese i dinamiku u Jadranskom moru. Međutim, obzirom na sveukupne analize, može se zaključiti da je za simulaciju mezoskalnih procesa u jadransko-jonskom bazenu potreban numerički model visoke rezolucije u spregnutom obliku, s pravilno predstavljenom ukupnom bilancom vode. To je posebno važno za regionalne klimatske modele koji simuliraju buduću klimu Jadrana, s obzirom da je otvoreno pitanje budućnosti jadranske termohaline cirkulacije i BiOS-a, a na temelju opaženih trendova postoje naznake da bi ona mogla oslabiti (Vilibić i sur., 2013).

U ovom radu su napravljene preliminarne analize projekcija buduće klime Jadranskog mora pomoću potpuno spregnutog regionalnog klimatskog modela CNRM-RCSM4 (poglavlje 5.). Do kraja 21. stoljeća svi scenariji daju postupan rast površinske temperature mora u cijelom

Jadranu, najviše izražen u scenariju RCP8.5, koji predviđa porast površinske temperature od ~ 2.7 ^{o}C na kraju 21. stoljeća (daleka budućnost) u odnosu na sadašnju klimu. Također, kroz cijelo 21. stoljeće svi scenariji prognoziraju porast površinskog saliniteta, posebice u priobalnim područjima Jadrana, s najvećim porastom u scenariju RCP8.5. Na kraju 21. stoljeća, tj. u razdoblju daleke budućnosti, porast BiOS indeksa koji ukazuje na anticiklonalnu cirkulaciju u sjevernom Jonskom moru je dobiven u scenariju RCP4.5. Takvi uvjeti bi pogodovali advekciji manje slanih vodenih masa iz zapadnog Sredozemnog mora prema Jadranu. Jačanje oba režima BiOS-a do kraja 21. stoljeća, ciklonalnog i naročito anticiklonalnog, je dobiveno samo u scenariju RCP8.5. Svi scenariji u dalekoj budućnosti predviđaju smanjivanje intenziteta stvaranja guste vode u južnom Jadranu.

Važno je naglasiti da su se u ovom radu analizirale projekcije buduće klime Jadrana samo jednog modela. Da bi se napravila bolja procjena buduće klime Jadrana, potrebno je napraviti analize ansambla klimatskih projekcija, što bi omogućilo kvantifikaciju vjerodostojnosti promjena.

7. POPIS LITERATURE

Artegiani, A., Azzolini, R., Paschini, E., 1981. Seasonal thermocline evolution in the northern and middle Adriatic Sea, FAO Fish. Rep. 253, 55–64.

Artegiani, A., Salusti, E., 1987. Field observation of the flow of dense water on the bottom of the Adriatic Sea during the winter of 1981. Oceanol. Acta 10, 387–391.

Artegiani, A., Bregant, D., Paschini, E., Pinardi, N., Raicich, F., Russo, A., 1997a. The Adriatic Sea general circulation, part I: air– sea interactions and water mass structure. J. Phys. Oceanogr. 27, 1492–1514.

Artegiani, A., Bregant, D., Paschini, E., Pinardi, N., Raicich, F., Russo, A., 1997b. The Adriatic Sea general circulation, part II: baroclinic circulation structure. J. Phys. Oceanogr. 27, 1515–1532.

Beg-Paklar, G., Isakov, V., Koračin, D., Kourafalou, V., Orlić, M., 2001. A case study of bora-driven flow and density changes on the Adriatic shelf (January 1987). Cont. Shelf Res. 21, 1751–1783. https://doi.org/10.1016/S0278-4343(01)00029-2.

Benetazzo, A., Bergamasco, A., Bonaldo, D., Falcieri, F.M., Sclavo, M., Langone, L., Carniel, S., 2014. Response of the Adriatic Sea to an intense cold air outbreak: dense water dynamics and wave induced transport. Prog. Oceanogr. 128, 115–138. https://doi.org/10.1016/j.pocean.2014.08.015.

Bensi, M., Cardin, V., Rubino, A., Notarstefano, G., Poulain, P.M., 2013. Effects of winter convection on the deep layer of the Southern Adriatic Sea in 2012. J. Geophys. Res. 118, 6064–6075. https://doi.org/10.1002/2013JC009432.

Bergamasco, A., Oguz, T., Malanotte-Rizzoli, P., 1999. Modelling dense water mass formation and winter circulation in the northern and central Adriatic Sea. J. Mar. Syst. 20, 279–300. https://doi.org/10.1016/S0924-7963(98)00087-6.

Bessieres, L., Rio, M., Dufau, C., Boone, C., Pujol, M., 2013. Ocean state indicators from MyOcean altimeter products. Ocean Sci. 9, 545–560. https://doi.org/10.5194/osd-9-2081-2012.

Beuvier, J., Sevault, F., Herrmann, M., Kontoyiannis, H., Ludwig, W., Rixen, M., Stanev, E., Béranger, K., Somot, S., 2010. Modelling the Mediterranean Sea interannual variability during 1961–2000: focus on the Eastern Mediterranean Transient. J. Geophys. Res. 115, C0817. https://doi.org/10.1029/2009JC005950.

Beuvier, J., Béranger, K., Lebeaupin-Brossier, C., Somot, S., Sevault, F., Drillet, Y., Bourdalle-Badie, R., Ferry, N., Lyard, F., 2012. Spreading of the Western Mediterranean deep water after winter 2005: time scales and deep cyclone transport. J. Geophys. Res. 117, C07022. https://doi.org/10.1029/2011JC007679.

Blanke, B., Delecluse, P., 1993. Variability of the tropical Atlantic Ocean simulated by a general circulation model with two different mixed layer physics. J. Phys. Oceanogr. 23, 1363–1388. https://doi.org/10.1175/1520-0485(1993)023<1363:VOTTAO>2.0.CO;2.

Borzelli, G.L.E., Gačić, M., Cardin, V., Civitarese, G., 2009. Eastern Mediterranean transient and reversal of the Ionian Sea circulation. Geophys. Res. Lett. 36, L15108. https://doi.org/10.1029/2009GL039261.

Bosse, A., P. Testor, L. Mortier, L. Prieur, V. Taillandier, F. d'Ortenzio, Coppola, L., 2015. Spreading of Levantine intermediate waters by submesoscale coherent vortices in the northwestern Mediterranean Sea as observed with gliders. J. Geophys. Res. Oceans 120, 1599–1622. https://doi.org/10.1002/2014JC010263.

Boucher, O., Pham, M., 2002. History of sulfate aerosol radiative forcings. Geophys. Res. Lett., 1308. https://doi.org/10.1029/2001GL014048.

Brodeau, L., Koenigk, T., 2015. Extinction of the northern oceanic deep convection in an ensemble of climate model simulations of the 20th and 21st centuries. Clim. Dyn. 46, 2863–2882. https://doi.org/10.1007/s00382-015-2736-5.

Bryden, H.L., Candela, J., Kinder, T.H., 1994. Exchange through the Strait of Gibraltar. Prog. Oceanogr. 33, 201-248. https://doi.org/10.1016/0079-6611(94)90028-0.

Buljan, M., 1953. Fluctuations of salinity in the Adriatic, Izvještaj Republičke ribarstvenobiološke ekspedicije "Hvar" 1948–1949. Acta Adriat. 2, 1–64.

Buljan, M., Zore-Armanda, M., 1976. Oceanographic properties of the Adriatic Sea. Oceanogr. Mar. Biol. Ann. Rev. 14, 11–98.

Cardin, V., Gačić, M., 2003. Long term heat flux variability and winter convection in the Adriatic Sea. J. Geophys. Res. 108 (C9), 8103. https://doi.org/10.1029/2002JC001645.

Carniel, S., Benetazzo, A., Boero, B., Boldrin, A., Falcieri, F.M., Langone, L., Sclavo, M., Taviani, M., Trincardi, F., Bonaldo, D., 2016. Interdisciplinary investigation of offshelf

transporting the southern Adriatic Sea: the role of Bari canyon. CIESM Monograph 47, 145–156.

Castellari, S., Pinardi, N., Leaman, K., 2000. Simulation of water mass formation processes in the Mediterranean Sea: Influence of the time frequency of the atmospheric forcing. J. Geophys. Res. 105, 24157–24181. https://doi.org/10.1029/2000JC900055.

Cavaleri, L., Bertotti, L., Tescaro, N., 1997. The modelled wind climatology of the Adriatic Sea. Theoret. Appl. Climatol. 56, 231–254. https://doi.org/10.1007/BF00866430.

Chiggiato, J., Bergamasco, A., Borghini, M., Falcieri, F.M., Falco, P., Langone, L., Miserocchi, S., Russo, A., Schroeder, K., 2016. Dense-water bottom currents in the Southern Adriatic Sea in spring 2012. Mar. Geol. 375, 134–145. https://doi.org/10.1016/j.margeo.2015.09.005.

Chronis, T., Papadopoulos, V., Nikolopoulos, E., 2011. QuickSCAT observations of exstreme wind events over Mediterranean and Black Seas during 2000-2008. Int. J. Climatol. 31, 2068–2077. https://doi.org/10.1002/joc.2213.

Colin, J., Déqué, M., Radu, R., Somot, S., 2010. Sensitivity study of heavy precipitations in Limited Area Model climate simulation: influence of the size of the domain and the use of the spectral nudging technique. Tellus, 62A, 591–604. https://doi.org/10.1111/j.1600-0870.2010.00467.x.

Cushman-Roisin, B., Korotenko, K.A., 2007. Mesoscale-resolving simulations of summer and winter bora events in the Adriatic Sea. J. Geophys. Res. 112, C11S91. https://doi.org/10.1029/2006JC003516.

Daget, N., Weaver, A.T., Balmaseda, M.A., 2008. An Ensemble Three-Dimensional Variational Data Assimilation System of the Global Ocean: Sensitivity to the Observation and Background-Error Variance Formulation. European Centre for Medium-Range Weather Forecasts (ECMWF), United Kingdom Technical Memorandum 562.

Danabasoglu, G., 2004. A comparison of global ocean general circulation model solutions obtained with synchronous and accelerated integration methods. Ocean Model 7, 323–341. https://doi.org/10.1016/j.ocemod.2003.10.001.

Darmaraki, S., Somot, S., Sevault, F., Nabat, P., Cabos, W., Cavicchia, L., Djurdjević, V., Li, L., Sannino, G., Sein, D., 2019. Future evolution of Marine Heatwaves in the Mediterranean Sea. Clim. Dyn. https://doi.org/10.1007/s00382-019-04661-z.

Davolio, S., Stocchi, P., Benetazzo, A., Bohm, E., Riminucci, F., Ravaioli, M., Li, X.M., Carniel, S., 2015. Exceptional Bora outbreak in winter 2012: validation and analysis of high-resolution atmospheric model simulations in the northern Adriatic area. Dyn. Atmos. Oceans 71, 1–20. https://doi.org/10.1016/j.dynatmoce.2015.05.002.

Dobričić, S., 2002. Sensitivity of an ocean-atmosphere model of Adriatic Sea to coupling scheme and resolution of the atmospheric model. Ph.D. thesis.

Dorman, C.E., Carniel, S., Cavaleri, L., Chiggiato, J., Doyle, J., Haack, T., Grbec, B., Janeković, I., Lee, C., Malačič, V., Orlić, M., Paschini, E., Pullen, J., Russo, A., Sclavo, M., Vilibić, I., 2007. Winter 2003 marine atmospheric conditions and the Bora over the northern Adriatic. J. Geophys. Res. 112, C03S03. https://doi.org/10.1029/2005JC003134.

Drobinski, P., Flamant, C., Dusek, J., Flamant, P., Pelon, J., 2001. Observational evidence and modelling of an internal hydraulic jump at the atmospheric boundary-layer top during a tramontane event. Bound. Layer Meteorol. 98 (3), 497–515. https://doi.org/10.1023/A:1018751311924.

Emery, W.J., Thomson R.E., 2001. Data Analysis Methods in Physical Oceanography, Elsevier B.V. pp. 654.

Estournel, C., Testor, P., Damien, P., D'Ortenzio, F., Marsaleix, P., Conan, P., Kessouri, F., de Madron, X.D., Coppola, L., Lellouche, J.-M., Belamari, S., Mortier, L., Ulses, C., Bouin, M.-N., Prieur, L., 2016. High resolution modeling of dense water formation in the north-western Mediterranean during winter 2012–2013: Processes and budget. J. Geophys. Res. Oceans 121, 5367–5392. https://doi.org/10.1002/2016JC011935.

Franco, P., Jeftić, L., Malanotte-Rizzoli, P., Michelato, A., Orlić, M., 1982. Descriptive model of the northern Adriatic. Ocean. Acta, 5, 379-389.

Franco, P., Michelato, A., 1992. Northern Adriatic Sea: oceanography of the basin proper and of the western coastal zone. Sci. Total Environ. Suppl. 1992, 35–62. https://doi.org/10.1016/B978-0-444-89990-3.50013-4.

Gačić, M., Kovačević, V., Manca, B., Papageorgiou, E., Poulain, P.M., Scarazzato, P., Vetrano, A., 1996. Thermohaline properties and circulation in the Otranto Strait. Bull. Institut Oceanographie Monaco 17, 117–145.

Gačić, M., Civitarese, G., Miserocchi, S., Cardin, V., Crise, A., Mauri, E., 2002. The open ocean convection in the Southern Adriatic: a controlling mechanism of the spring phytoplankton bloom. Cont. Shelf. Res. 22, 1897–1908. https://doi.org/10.1016/S0278-4343.

Gačić, M., Borzelli, G.L.E., Civitarese, G., Cardin, V., Yari, S., 2010. Can internal processes sustain reversals of the ocean upper circulation? The Ionian Sea example. Geophys. Res. Lett. 37, L09608. https://doi.org/10.1029/2010GL043216.

Gačić, M., Civitarese, G., Borzelli, G.L.E., Kovačević, V., Poulain, P.M., Theocharis, A., Catucci, A., Zarokanellos, N., 2011. On the relationship between the decadal oscillations of the northern Ionian Sea and the salinity distributions in the eastern Mediterranean. J. Geophys. Res. 116, C12002. https://doi.org/10.1029/2011JC007280.

Gačić, M., Schroeder, K., Civitarese, G., Cosoli, S., Vetrano, A., Borzelli, G.L.E., 2013. Salinity in the Sicily Channel corroborates the role of the Adriatic–Ionian Bimodal Oscillating System (BiOS) in shaping the decadal variability of the Mediterranean overturning circulation. Ocean Sci. 9, 83–90. https://doi.org/10.5194/os-9-83-2013.

Gačić, M., Civitarese, G., Kovačević, V., Ursella, L., Bensi, M., Menna, M., Cardin, V., Poulain, P.M., Cosoli, S., Notarstefano, G., Pizzi, C., 2014. Extreme winter 2012 in the Adriatic. An example of climatic effect on the BiOS rhythm. Ocean Sci. 10, 513–522. https://doi.org/10.5194/os-10-513-2014.

Grbec, B., Morović, M., Zore-Armanda, M., 2003. Mediterranean Oscillation and its relationship to salinity fluctuation in the Adriatic Sea. Acta Adriat. 44(1), 61–76.

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

Grilli, F., Pinardi, N., 1998. The computation of Rossby radii of deformation for the Mediterranean Sea. MTP News 6 (4), 4-5.

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. https://doi.org/10.1111/j.1600-0870.2008.00369.x.

Grubišić, V., 2006. Bora-driven potential vorticity banners over the Adriatic. Q. J. R. Meteorol. Soc. 130, 2571–2603. https://doi.org/10.1256/qj.03.71.

Gunduz, M., Dobričić, S., Oddo, P., Pinardi, N., Guarnieri, A., 2013. Impact of Levantine Intermediate Water on the interannual variability of the Adriatic Sea based on simulations with a fine resolution ocean model. Ocean Model. 72, 253–263. https://doi.org/10.1016/j.ocemod.2013.10.002.

Hamon, M., Beuvier, J., Somot, S., Lellouche, J.M., Greiner, E., Jordà, G., Bouin, M.N., Arsouze, T., Béranger, K., Sevault, F., Dubois, C., Drevillon, M., Drillet, Y., 2016. Design and validation of MEDRYS, a Mediterranean Sea reanalysis over 1992–2013. Ocean Sci. 12, 577–599. https://doi.org/10.5194/os-12-577-2016.

Heimann, D., 2001. A model-based wind climatology of the eastern Adriatic coast. Meteorol. Z. 10, 5–16. https://doi.hr/10.1127/0941-2948/2001/0010-0005.

Hendershott, M.C., Rizzoli, P., 1976. The winter circulation of the Adriatic Sea. Deep Sea Res. 23, 353–370. https://doi.org/10.1016/0011-7471(76)90834-2.

Herrmann, M., Somot, S., 2008. Relevance of ERA40 dynamical downscaling for modelling deep convection in the Mediterranean Sea. Geophys. Res. Lett. 35, L04607. https://doi.org/10.1029/2007GL032442.

Herrmann, M., Estournel, C., Déqué, M., Marsaleix, P., Sevault, F., Somot, S., 2008. Dense water formation in the Gulf of Lion shelf: impact of atmospheric interannual variability and climate change. Cont. Shelf. Res. 28, 2092–2112. https://doi.org/doi:10.1016/j.csr.2008.03.003.

Herrmann, M., Sevault, F., Beuvier, J., Somot, S., 2010. What induced the exceptional 2005 convection event in the northwestern Mediterranean basin? Answers from a modelling study. J. Geophys. Res. 115, C12051. https://doi.org/10.1029/2010JC006162.

Herrmann, M., Somot, S., Calmanti, S., Dubois, C., Sevault, F., 2011. Representation of daily wind speed spatial and temporal variability and intense wind events over the Mediterranean Sea using dynamical downscaling: impact of the regional climate model configuration. Nat. Hazards Earth Syst. Sci. 11, 1983–2001. https://doi.org/10.5194/nhess-11-1983-2011.

IPCC, 2013. Climate change 2013: the physical science basis. Working group I contribution to the fifth assessment report of the intergovernmental panel on climate change. Cambridge University Press, Cambridge.

IPCC, 2014. Climate change 2014: synthesis report. Contribution of working groups I, II and III to the fifth assessment report of the intergovernmental panel on climate change. IPCC, Geneva, Switzerland, 151 pp.

Ivanov, V.V., Shapiro, G.I., Huthnance, J.M., Aleynik, D.L., Golovin, P.N., 2004. Cascades of dense water around the world ocean. Prog. Oceanogr. 60, 47–98. https://doi.org/10.1016/j.pocean.2003.12.002.

Janeković, I., Dutour Sikirić, M.A., Tomažić, I., Kuzmić, M., 2010. Hindcasting the Adriatic Sea surface temperature and salinity: a recent modeling experience. Geofizika 27, 85–100.

Janeković, I., Mihanović, H., Vilibić, I., Tudor, M., 2014. Extreme cooling and dense water formation estimates in open and coastal regions of the Adriatic Sea during the winter of 2012. J. Geophys. Res. 119, 3200–3218. https://doi.org/10.1002/2014JC009865.

Josey, S.A., 2003. Changes in the heat and freshwater forcing of the eastern Mediterranean and their influence on deep water formation. J. Geophys. Res. 108, 3237. https://doir.org/10.1029/2003/JC001778.

Klein, B., Roether, W., Manca, B.B., Bregant, D., Beitzel, V., Kovačević, V., Luchetta, A., 1999. The large deep water transient in the Eastern Mediterranean. Deep-Sea Res. 46, 371–414. https://doir.org/10.1016/S0967-0637(98)00075-2.

Kohonen, T., 1982. Self-organized formation of topologically correct feature maps. Biol. Cybern. 43, 59–69. https://doi.org/10.1007/BF00337288.

Kohonen, T., 1998. The SOM Methodology. In: Deboeck, G., Kohonen, T., (eds) Visual explorations in finance with self-organizing maps. Springer, London, pp 159–167.

Kohonen, T., 2001. Self-organizing maps. Springer, Berlin

Kokkini, Z., Gerin, R., Poulain, P.M., Mauri, E., Pasarić, Z., Janeković, I., Pasarić, M., Mihanović, H., Vilibić, I., 2017. A multiplatform investigation of Istrian Front dynamics (north Adriatic Sea) in winter 2015. Mediterranean Marine Science. 18, 344-354. http://dx.doi.org/10.12681/mms.1895.

Kovač, Ž., Morović, M., Matić, F., 2014. Uncovering spatial and temporal patterns of the Adriatic Sea color with self-organizing maps. Int. J. Remote Sens. 35, 2105–2117. https://doi.org/10.1080/01431161.2014.885667.

Kourafalou, V.H., 1999. Process studies on the Po River plume, North Adriatic Sea. J. Geophys. Res. 104, 29963–29985. https://doi.org/10.1029/1999JC900217.

Kršinić, F., Grbec, B., 2002. Some distributional characteristics of small zooplankton at two stations in the Otranto Strait (Eastern Mediterranean). Hydrobiologia 482, 119–136. https://doi.org/10.1023/A:1021212431253.

Kuzmić, M., Janeković, I., Book, J.W., Martin, P.J., Doyle, J.D., 2006. Modelling the northern Adriatic double-gyre response to intense bora wind: a revisit. J. Geophys. Res. 111, C03S13. https://doi.org/10.1029/2005JC003377.

Kuzmić, M., Grisogono, B., Li, X., Lehner, S., 2015. Examining deep and shallow Adriatic bora events. Q. J. R. Meteorol. Soc. 141, 3434–3438. https://doi.org/10.1002/qj.2578.

Langone, L., Conese, I., Miserocchi, S., Boldrin, A., Bonaldo, D., Carniel, S., Chiggiato, J., Turchetto, M., Borghini, M., Tesi, T., 2016. Dynamics of particles along the western margin of the Southern Adriatic: processes involved in transferring particulate matter to the deep basin. Mar. Geol. 375, 28–43. https://doi.org/10.1016/j.margeo.2015.09.004.

Lascaratos, A., Williams, R., Tragou, E., 1993. A mixed layerstudy of the formation of Levantine Intermediate Water. J. Geophys. Res. 98, 739–749. https://doi.org/10.1029/93JC00912.

Legates, D.R., McCabe, G.J., 1999. Evaluating the Use of "Goodness-of-Fit" Measures in Hydrologic and Hydroc-limatic Model Validation. Water Resources Research, 35, 233-241. http://dx.doi.org/10.1029/1998WR900018.

Leloup, J.A., Lachkar, Z., Boulanger, J.P., Thiria, S., 2007. Detecting decadal changes in ENSO using neural networks. Clim. Dyn. 28, 147-162. https://doi.org/10.1007/s00382-006-0173-1.

Li, L., Casado, A., Congedi, L., Dell'Aquila, A., Dubois, C., Elizalde, A., L'Hévéder, B., Lionello, P., Sevault, F., Somot, S., Ruti, P., Zampieri, M., 2012. Modelling of the Mediterranean climate system. Clim. Mediterr. Reg., Amsterdam, pp 419–448. https://doi.org/10.1016/B978-0-12-416042-2.00007-0.

Ličer, M., Smerkol, P., Fettich, A., Ravdas, M., Papapostolou, A., Mantziafou, A., Strajnar, B., Cedilnik, J., Jeromel, M., Jerman, J., Petan, S., Malačič, V., Sofianos, S., 2016. Modelling ocean response to an extreme Bora event in Northern Adriatic using oneway and two-way atmosphere-ocean coupling. Ocean Sci. 12, 71–86. https://doi.org/10.5194/os-12-71-2016.

Lipizer, M., Partescano, E., Rabitti, A., Giorgetti, A., and Crise, A., 2014. Qualified temperature, salinity and dissolved oxygen climatologies in a changing Adriatic Sea. Ocean Sci. 10, 771-797. https://doi.org/10.5194/os-10-771-2014.

Liu, Y., Weisberg, R.H., 2005. Patterns of ocean current variability on the West Florida Shelf using the self-organizing map. J. Geophys. Res. 110, C06003. https://doi.org/10.1029/2004JC002786.

Liu, Y., Weisberg, R.H., 2007. Current patterns on the West Florida Shelf from joint self-organizing map analyses of HF radar and ADCP data. J. Atmos. Ocean Technol. 24, 702–712. https://doi.org/10.1175/JTECH1999.1.

Liu, Y., Weisberg, R.H., 2011. A review of self-organizing map applications in meteorology and oceanography. Self-organizing maps: applications and novel algorithm design. InTech, Rijeka, pp 253–272.

Liu, Y., Weisberg, R.H., Mooers, C.N.K., 2006. Performance evaluation of the self-organizing map for feature extraction. J. Geophys. Res. 111, C05018. https://doi.org/10.1029/2005JC003117.

Liu, Y., Weisberg, R.H., Vignudelli, S., Mitchum, G.T., 2016. Patterns of the loop current system and regions of sea surface height variability in the eastern Gulf of Mexico revealed by the self-organizing maps. J. Geophys. Res. 121, 2347–2366. https://doi.org/10.1002/2015JC011493.

Lučić, D., Ljubešić, Z., Babić, I., Bosak, S., Cetinić, I., Vilibić, I., Mihanović, H., Hure, M., Njire, J., Lučić, P., Kružić, P., 2017. Unusual winter zooplankton bloom in the open southern Adriatic Sea. Turk. J. Zool. 41, 1024–1035. https://doi.org/10.3906/zoo-1702-17.

Ludwig, W., Dumont, E., Meybeck, M., Heussner, S., 2009. River discharges of water and nutrients to the Mediterranean and Black Sea: major drivers for ecosystem changes during past and future decades?. Prog. Oceanogr. 80, 199–217. https://doi.org/10.1016/j.pocean.2009.02.001.

L'Hévéder, B., Li, L., Sevault, F., Somot, S., 2013. Interannual variability of deep convection in the Northwestern Mediterranean simulated with a coupled AORCM. Clim. Dyn. 41 (3-4), 937–960. https://doi.org/10.1007/s00382-012-1527-5.

Madec, G., 2008. NEMO ocean engine. Note Pole de Modélisation, Inst. Pierre-Simon Laplace 27, Paris.

Madec, G., 2012. NEMO ocean engine. Note Pole de Modélisation, Inst. Pierre-Simon Laplace 27, Paris.

Malanotte-Rizzoli, P., 1977. Winter oceanographic properties of Northern Adriatic Sea. Cruise January-February 1972. Arch. Oceanogr. Limnol. 19 (1), 1–45.

Malanotte-Rizzoli, P. and Bergamasco, A., 1983. The dynamics of the coastal region of the northern Adriatic Sea, J. Phys. Oceanogr. 13, 1105-1130.

Malanotte-Rizzoli, P., Robinson, A.R., 1988 POEM: Physical Oceanography of the Eastern Mediterranean, Eos 69, 194–203. https://doi.org/10.1029/88EO00125.

Malanotte-Rizzoli, P., Manca, B.B., D'Alcala, M.R., Theocharis, A., Bergamasco, A., Bregant, D., Budillon, G., Civitarese, G., Georgopoulos, D., Michelato, A., Sansone, E., Scarazzato, P., Souvermezoglou, E., 1997. A synthesis of the Ionian Sea hydrography, circulation and water mass pathways during POEM-Phase I. Prog. Oceanogr. 39, 153–204. https://doi.org/10.1016/S0079-6611(97)00013-X.

Malanotte-Rizzoli, P., Artale, V., Borzelli, G.L.E., Brenner, S., Crise, A., Gačić, M., Kress, N., Marullo, S., Ribera d'Alcalà, M., Sofianos, S., Tanhua, T., Theocharis, A., Alvarez, M., Ashkenazy, Y., Bergamasco, A., Cardin, V., Carniel, S., Civitarese, G., D'Ortenzio, F., Font, J., Garcia-Ladona, E., Garcia-Lafuente, J.M., Gogou, A., Gregoire, M., Hainbucher, D., Kontoyannis, H., Kovačević, V., Kraskapoulou, E., Kroskos, G., Incarbona, A., Mazzocchi, M.G., Orlić, M., Ozsoy, E., Pascual, A., Poulain, P.M., Roether, W., Rubino, A., Schroeder, K., Siokou-Frangou, J., Souvermezoglou, E., Sprovieri, M., Tintoré, J., Triantafyllou, G., 2014. Physical forcing and physical/biochemical variability of the Mediterranean Sea: a review of unresolved issues and directions for future research. Ocean Sci. 10, 281–322. https://doi.org/10.5194/os-10-281-2014.

Manca, B., Bregant, D., 1998. Dense water formation in the Southern Adriatic Sea during winter 1996. Rapp. Comm. Int. Mer. Médit. 35, 176–177.

Manca, B.B., Kovačević, V., Gačić, M., Viezzoli, D., 2002. Dense water formation in the Southern Adriatic Sea and spreading into the Ionian Sea in the period 1997–1999. J. Mar. Syst. 33, 133–154. https://doi.org/10.1016/S0924-7963(02)00056-8.

Mantziafou, A., Lascaratos, A., 2004. An eddy resolving numerical study of the general circulation and deep-water formation in the Adriatic Sea. Deep-Sea Res. I 51, 251–292. https://doi.org/10.1016/j.dsr.2004.03.006.

Mantziafou, A., Lascaratos, A., 2008. Deep-water formation in the Adriatic Sea: interannual simulations for the years 1979-1999. Deep-Sea Res. I Oceanogr. Res. Pap. 55, 1403–1427. https://doi.org/10.1016/j.dsr.2008.06.005.

Marini, M., Maselli, V., Campanelli, A., Foglini, F., Grilli, F., 2016. Role of the Mid-Adriatic deep in dense water interception and modification. Mar. Geol. 375, 5–14. https://doi.org/10.1016/j.margeo.2015.08.015.

Martin, P.J., Book, J.W., Burrage, D.M., Rowley, C.D., Tudor, M., 2009. Comparison of model-simulated and observed currents in the central Adriatic during DART. J. Geophys. Res. 114, C01S05. https://doi.org/10.1029/2008JC004842.

Marullo, S., Nardelli, B.B., Guarracino, M., Santoleri, R., 2007. Observing the Mediterranean Sea from space: 21 years of Pathfinder—AVHRR sea surface temperatures (1985 to 2005): re-analysis and validation. Ocean Sci. 3, 299–310. https://doi.org/10.5194/os-3-299-2007.

Matić, M., Kalinić, H., Vilibić, I., 2018. Interpreting Self-Organizing Map errors in the classification of ocean patterns. Comp. & Geosc. 119, 9-17. https://doi.org/10.1016/j.cageo.2018.06.006.

May, P.W., 1982. Climatological flux estimates in the Mediterranean Sea: Part I. Wind and wind stresses. NORDA Rep. 54, 56.

MEDAR/MEDATLAS Group, 2002. MEDAR/MEDATLAS 2002 Database: Cruise inventory, Observed and Analysed Data of Temperature and Bio-Chemical Parameters [4 CDROMs]. Inst. FR. De Rech. Pour l'Esploit, de la Mer, Brest, France.

Messinger, F., Arakawa, A., 1976. Numerical Methods Used in Atmospheric Models. Geneva, World Meteorological Organization..

Mihanović, H., Cosoli, S., Vilibić, I., Ivanković, D., Dadić, V., Gačić, M., 2011. Surface current patterns in the northern Adriatic extracted from high-frequency radar data using self-organizing map analysis. J. Geophys. Res. 116, C0803. https://doi.org/10.1029/2011JC007104.

Mihanović, H., Vilibić, I., Carniel, S., Tudor, M., Russo, A., Bergamasco, A., Bubić, N., Ljubešić, Z., Viličić, D., Boldrin, A., Malačić, V., Celio, M., Comici, C., Raicich, F., 2013.

Exceptional dense water formation on the Adriatic shelf in the winter of 2012. Ocean Sci. 9, 561–572. https://doi.org/10.5194/os-9-561-2013.

Mihanović, H., Vilibić, I., Dunić, N., Šepić, J., 2015. Mapping of decadal middle Adriatic oceanographic variability and its relation to the BiOS regime. J. Geophys. Res. 120, 5615–5630. https://doi.org/10.1002/2015JC0725.

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

Nabat, P., Somot, S., Mallet, M., Sevault, F., Chiacchio, M., Wild, M., 2015. Direct and semi-direct aerosol radiative effect on the Mediterranean climate variability using a Regional Climate System Model. Clim. Dyn. 44, 1127–1155. https://doi.org/10.1007/s00382-014-2205-6.

Najdek, M., Paliaga, P., Šilović, T., Batistić, M., Garić, R., Supić, N., Ivančić, I., Ljubimir, S., Korlević, M., Jasprica, N., Hrustić, E., Dupčić-Radić, I., Blažina, M., Orlić, S., 2014. Picoplankton community structure before, during and after convection event in the offshore waters of the Southern Adriatic Sea. Biogeosciences, 11, 2645 - 2659. https://doi.org/10.5194/bg-11-2645-2014.

Nof, D., 1983. The translation of isolated cold eddies along a sloping bottom. Deep-Sea Res. 30, 171–182. https://doi.org/10.1016/0198-0149(83)90067-5.

Noilhan, J., Mahfouf, J.F., 1996. The ISBA land surface parameterisation scheme. Global Planet. Change 13, 145–159. https://doi.org/10.1016/0921-8181(95)00043-7.

Oddo, P., Guarnieri, A., 2011. A study of the hydrographic conditions in the Adriatic Sea from numerical modelling and direct observations (2000–2008). Ocean Sci. 7, 549–567. https://doi.org/10.5194/os-7-549-2011.

Oki, T., Sud, Y.C., 1998. Design of total runoff integrating pathways (TRIP). A global river channel network. Earth Interact. 2, 1–36. https://doi.org/10.1175/1087-3562(1998)002<0001:DOTRIP>2.3.CO;2.

Orlić, M., Gačić, M., La Violette, P.E., 1992. The currents and circulation of the Adriatic Sea. Oceanol. Acta 15, 109–124.

Orlić, M., Kuzmić, M., Pasarić, Z., 1994. Response of the Adriatic Sea to the Bora and Sirocco forcing. Cont. Shelf Res. 14, 91–116. https://doi.org/10.1016/0278-4343(94)90007-8.

Orlić, M., Dadić, V., Grbec, B., Leder, N., Marki, A., Matić, F., Mihanović, H., Beg-Paklar, G., Pasarić, M., Pasarić, Z., Vilibić, I., 2006. Wintertime buoyancy forcing, changing seawater properties, and two different circulation systems produced in the Adriatic. J. Geophys. Res. 111, C03S07. https://doi.org/10.1029/2005JC003271.

Ovchinnikov, I.M., Zats, V.I., Krivosheya, V.G., Udodov, A.I., 1985. Formation of deep eastern Mediterranean waters in the Adriatic Sea. Oceanology 25(6), 704–707.

Peharda, M., Black, B.A., Purroy, A., Mihanović, H., 2016. The bivalve Glycymeris pilosa as a multidecadal environmental archive for the Adriatic and Mediterranean Seas. Mar. Environ. Res. 119, 79–87. https://doi.org/10.1016/j.marenvres.2016.05.022.

Peharda, M., Vilibić, I., Black, B.A., Markulin, K., Dunić, N., Džoić, T., Mihanović, H., Gačić, M., Puljas, S., Waldman, R., 2018. Using bivalve chronologies for quantifying environmental drivers in a semi-enclosed temperate sea. Sci. Rep. 8 (5559). https://doi.org/10.1038/s41598-018-23773-w.

Pennel, R., Arsouze, T., Akuetevi, C.Q., Waldman, R., 2016. Small-scale processes in the Mediterranean Sea deep convection areas: a numerical study through nesting approach. Rapp. Comm. Int. Mer Médit. 41 (89).

Pinardi, N., Baretta, J., De Mey, P., Haine, K., Bassini, S., Lascaratos, A., Roether, W., Brasseur, P., Krestenitis, S., Crise, S., Pierini, S., Allen, I., Williams, R., Vested, J., LeTraon, P.Y., 1996. Mediterranean eddy resolving modelling and interdisciplinary studies—II (MERMAIDS-EUProject)—final scientific and management report—IMGA. Research Activity Note 1/1996 (December 1996).

Pinardi, N., Zavatarelli, M., Adani, M., Coppini, G., Fratianni, C., Oddo, P., Simoncelli, S., Tonani, M., Lyubartsev, V., Dobricic, S., Bonaduce, A., 2015. Mediterranean Sea large-scale low-frequency ocean variability and water mass formation rates from 1987 to 2007: A retrospective analysis, Prog. Oceanogr. 132, 318–332. https://doi.org/10.1016/j.pocean.2013.11.003.

Poulain, P.M., Raicich, F., 2001. Forcings. In: Cushman-Roisin, B., Gačić, M., Poulain, P.M., Artegiani, A. (Eds.), Physical Oceanography of the Adriatic Sea: Past, Present and Future. Kluwer Academic Pub, pp. 45–65.

Radu, R., Déqué, M., Somot, S., 2008. Spectral nudging in a spectral regional climate model. Tellus A 60, 898–910. https://doi.org/10.1111/j.1600-0870.2008.00341.x.

Raicich, F., 1996. On the fresh water balance of the Adriatic Sea. J. Mar. Syst. 9, 305–319. https://doi.org/10.1016/S0924-7963(96)00042-5.

Raicich, F., Malačič, V., Celio, M., Giaiotti, D., Cantoni, C., Colucci, R.R., Čermelj, B., Pucillo, A. 2013. Extreme air–sea interactions in the Gulf of Trieste (North Adriatic) during the strong Bora event in winter 2012. J. Geophys. Res. 118, 5238–5250. https://doi.org/10.1002/jgrc.20398.

Reale, M., Crise, A., Farneti, R., Mosetti, R., 2016. A process study of the Adriatic-Ionian System baroclinic dynamics. J. Geophys. Res. Oceans 121, 5872–5887. https://doi.org/10.1002/2016JC011763.

Reale, M., Salon, S., Crise, A., Farneti, R., Mosetti, R., Sannino, G., 2017. Unexpected covariant behavior of the Aegean and Ionian Seas in the period 1987–2008 by means of a nondimensional sea surface height index. J. Geophys. Res. Oceans 122 (10), 8020–8033. https://doi.org/10.1002/2017JC012983.

Reynaud, T., Legrand, P., Mercier, H., Barnier, B., 1998. A new analysis of hydrographic data in the Atlantic and its application to an inverse modelling study. Int World Ocean Circ. Exp. Newsl. 32, Natl Oceanogr Data Cent, Silver Spring, MD.

Rio, M.H., Pascual, A., Poulain, P.M., Menna, M., Barcelo, B., Tintore, J., 2014. Computation of a new mean dynamic topography for the Mediterranean Sea from model outputs, altimeter measurements and oceanographic in situ data. Ocean Sci. 10, 731–744. https://doi.org/10.5194/os-10-731-2014.

Rixen, M., Beckers, J.M., Levitus, S., Antonov, J., Boyer, T., Maillard, C., Fichaut, M., Balopoulos, E., Iona, S., Dooley, H., Garcia, M.J., Manca, B., Giorgetti, A., Manzella, G., Mikhailov, N., Pinardi, N., Zavatarelli, M., 2005. The Western Mediterranean Deep Water: a proxy for climate change. Geophys Res Lett 32, L12608. https://doi.org/10.1029/2005GL022702.

Robinson, A.R., Leslie, W.G., Theocharis, A., Lascaratos, A., 2001. Mediterranean Sea circulation. Encyclopedia of Ocean Sciences. Academic Press. San Diego, CA, pp. 1689–1706. https://doi.org/10.1006/rwos.2001.0376.

Roether, W., Schlitzer, R., 1991. Eastern Mediterranean deep water renewal on the basis of chlorofluoromethane and tritium. Dyn. Atmos. Oceans 15, 333–354. https://doi.org/10.1016/0377-0265(91)90025-B.

Roether, W., Klein, B., Manca, B., Theocharis, A., Kioroglou, S., 2007. Transient Eastern Mediterranean deep waters in response to the massive dense-water output of the Aegean Sea in the 1990s. Prog. Oceanogr. 74, 540–571. https://doi.org/10.1016/j.pocean.2007.03.001.

Roullet, G., Madec, G., 2000. Salt conservation, free surface, and varying levels: a new formulation for ocean general circulation models. J. Geophys. Res. 105, 23927–23942. https://doi.org/10.1029/2000JC900089.

Scinocca, J.F., Kharin, V.V., Jiao, Y., Qian, M.W., Lazare, M., Solheim, L., Flato, G.M., 2016. Coordinated global and regional climate modeling. J. Clim. 29, 17–35. https://doi.org/10.1175/JCLI-D-15-0161.1.

Schlitzer, R., Roether, W., Hausmann, M., Junghans, H.-G., Oster, H., Johannsen, H., Michelato, A., 1991. Chlorofluoromethane and oxygen in the Eastern Mediterranean. Deep-Sea Res. I 38, 1531–1551. https://doi.org/10.1016/0198-0149(91)90088-W.

Schroeder, K., Ribotti, A., Borghini, M., Sorgente, R., Perilli, A., Gasparini, G.P., 2008. An extensive western Mediterranean deep water renewal between 2004 and 2006. Geophys. Res. Lett. 35, L18605. https://doi.org/10.1029/2008GL035146.

Sevault, F., Somot, S., Déqué, M., 2002. Couplage ARPEGE-Médias - OPA-Méditerranée: Les étapes. Note de centre GMGEC. CNRM 84, Météo-France, France.

Sevault, F., Somot, S., Beuvier, J., 2009. A regional version of the NEMO ocean engine on the Mediterranean Sea: NEMOMED8 user's guide. Note Cent 107, Groupe de Météorol. De Grande Echelle et Climat, CNRM, Toulouse, France.

Sevault, F., Somot, S., Alias, A., Dubois, C., Lebeaupin-Brossier, C., Nabat, P., Adloff, F., Déqué, M., Decharme, B., 2014. A fully coupled Mediterranean regional climate system model: design and evaluation of the ocean component for the 1980–2012 period. Tellus A 66, 23967. https://doi.org/10.3402/tellusa.v66.23967.

Smith, W., Sandwell, D., 1997. Global sea floor topography from satellite altimetry and ship depth sounding. Science 277, 1957–1962. https://doi.org/10.1126/science.277.5334.1956.

Somot, S., 2005. Modélisation climatique du bassin méditerranéen: variabilité et scénarios de changement climatique. Ph.D. thesis, Université Paul Sabatier, Toulouse, France.

Somot, S., Sevault, F., Déqué, M., 2006. Transient climate change scenario simulation of the Mediterranean Sea for the twenty-first century using a high-resolution ocean circulation model. Clim. Dyn. 27, 851–879. https://doi.org/10.1007/s00382-006-0167-z.

Somot, S., Sevault, F., Déqué, M., Crépon, M., 2008. 21st century climate change scenario for the Mediterranean using a coupled Atmosphere-Ocean Regional Climate Model. Global Planet. Change 63 (2-3), 112-126. https://doi.org/10.1016/j.gloplacha.2007.10.003.

Somot, S., Houpert, L., Sevault, F., Testor, P., Bosse, A., Taupier-Letage, I., Bouin, M.N., Waldman, R., Cassou, C., Sanchez-Gomez, E., Durrieu de Madron, X., Adloff, F., Nabat, P., Herrmann, M., 2018. Characterizing, modelling and understanding the climatevariability of the deep water formation in the North-Western Mediterranean Sea. Clim. Dyn. 51(3), 1179-1210. https://doi.org/10.1007/s00382-016-3295-0.

Soto-Navarro, J., Somot, S., Sevault, F., Beuvier, J., Criado-Aldeanueva, F., Garcia-Lafuente, J., Beranger, K., 2015. Evaluation of regional ocean circulation models for the Mediterranean Sea at the Strait of Gibraltar: volume transport and thermohaline properties of the outflow. Clim. Dyn. 44, 1277–1292. https://doi.org/10.1007/s00382-014-2179-4.

Stanev, E.V., Peneva, E.L., 2002. Regional sea level response to global climate change: Black Sea examples. Glob. Planet Changes 32, 33–47. https://doi.org/10.1016/S0921-8181(01)00148-5.

Stanev, E.V., Le Traon, P.Y., Peneva, E.L., 2000. Sea level variations and their dependency on meteorological and hydrological forcing: analysis of altimeter and surface data for the Black Sea. J. Geophys. Res. 105, 17203–17216. https://doi.org/10.1029/1999JC900318.

Supić, N., Grbec, B., Vilibić, I., Ivančić, I., 2004. Long-term changes in hydrographic conditions in northern Adriatic and its relationship to hydrological and atmospheric processes. Ann. Geophys. 22, 733–745. https://doi.org/10.5194/angeo-22-733-2004.

Supić, N., Kraus, R., Kuzmić, M., Paschini, E., Precali, R., Russo, A., Vilibić, I., 2012. Predictability of northern Adriatic winter conditions. J. Mar. Syst. 90, 42–57. https://doi.org/10.1016/j.jmarsys.2011.08.008.

Tegen, I., Hollrig, P., Chin, M., Fung, I., Jacob, D., Penner, J., 1997. Contribution of different aerosol species to the global aerosol extinction optical thickness: Estimates from model results. J. Geophys. Res. 102, 23895–23915. https://doi.org/10.1029/97JD01864.

Turner, J.S., 1973. Buoyancy effects in fluids. Cambridge University Press, London.

Ursella, L., Kovačević, V., Gačić, M., 2011. Footprints of mesoscale eddy passages in the Strait of Otranto (Adriatic Sea). J. Geophys. Res. 116, C04005. https://doi.org/10.1029/2010JC006633.

Valcke, S., 2013. The OASIS3 coupler: a European climate modelling community software. Geosci. Model Dev. 6, 3–388. https://doi.org/10.5194/gmd-6-373-2013.

Verri, G., Pinardi, N., Oddo, P., Ciliberti, S.A., Coppini, G., 2018. River runoff influences on the Central Mediterranean overturning circulation. Clim. Dyn. 50, 1675–1703. https://doi.org/10.1007/s00382-017-3715-9.

Vesanto, J., Himberg, J., Alhoniemi, E., Parhankangas, J., 2000. SOM toolbox for Matlab 5, technical report. Helsinki University of Technology, Helsinki.

Vested, H.J., Berg, P., Uhrenholdt, T., 1998. Dense water formation in the Northern Adriatic. J. Mar. Syst. 18, 135–160. https://doi.org/10.1016/S0924-7963(98)00009-8.

Vilibić, I., Orlić, M., 2001. An estimation of water mass fractions in the South Adriatic. Rapports et proces-verbaux des réunions CIESMM, 36, 87.

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

Vilibić, I., 2003. An analysis of dense water production on the North Adriatic shelf. Estuar. Coast Shelf Sci. 56, 697–707. https://doi.org/10.1016/S0272-7714(02)00277-9.

Vilibić, I., Grbec, B., Supić, N., 2004. Dense water generation in the north Adriatic in 1999 and its recirculation along the Jabuka Pit. Deep-Sea Res. I 51, 1457–1474. https://doi.org/10.1016/j.dsr.2004.07.012.

Vilibić, I., Supić, N., 2005. Dense water generation on a shelf: the case of the Adriatic Sea. Ocean Dyn. 1-13, 1616–7228. https://doi.org/10.1007/s10236-005-0030-5.

Vilibić, I., Šantić, D., 2008. Deep water ventilation traced by Synechococcus cyanobacteria. Ocean Dyn. 58, 119–125. https://doi.org/10.1007/s10236-008-0135-8.

Vilibić, I., Mihanović, H., Šepić, J., Matijević, S., 2011. Using self-organising maps to investigate long-term changes in deep Adriatic water patterns. Cont. Shelf Res. 31, 695–711. https://doi.org/10.1016/j.csr.2011.01.007.

Vilibić, I., Matijević, S., Šepić, J., Kušpilić, G., 2012. Changes in the Adriatic oceanographic properties induced by the Eastern Mediterranean Transient. Biogeosciences 9, 2085–2097. https://doi.org/10.5194/bg-9-2085-2012.

Vilibić, I., Mihanović, H., 2013. Observing the bottom density current over a shelf using an Argo profiling float. Geophys. Res. Lett. 40, 910–915. https://doi.org/10.1002/grl.50215.

Vilibić, I., Šepić, J., Proust, N., 2013. Weakening of the thermohaline circulation in the Adriatic Sea. Clim. Res. 55, 217–225. https://doi.org/10.3354/cr01128.

Vilibić, I., Pištalo, D., Šepić, J., 2015. Long-term variability and trends of relative geostrophic currents in the middle Adriatic. Cont. Shelf. Res. 93, 70–80. https://doi.org/10.1016/j.csr.2014.12.003.

Vilibić, I., Mihanović, H., Janeković, I., Šepić, J., 2016. Modelling the formation of dense water in the northern Adriatic: sensitivity studies. Ocean Modell. 101, 17–29. https://doi.org/10.1016/j.ocemod.2016.03.001.

Voldoire, A., Sanchez-Gomez, E., Salas y Mélia, D., Decharme, B.,Cassou, C., Sénési, S., Valcke, S., Beau, I., Alias, A., Cheval-lier, 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. https://doi.org/10.1007/s00382-011-1259-y.

Vörösmarty, C., Fekete, B., Tucker, B., 1996. Global River Discharge Database. RivDis. U.N. Educ. Sci. and Cult. Organ., Paris. http://www.rivdis.sr.unh.edu/.

Waldman, R., Somot, S., Herrmann, M., Testor, P., Estournel, C., Sevault, F., Prieur, L., Mortier, L., Coppola, L., Taillandier, V., Conan, P., Dausse, D., 2016. Estimating dense water volume and its evolution for the year 2012–2013 in the North-western Mediterranean Sea: an observing system simulation experiment approach. J. Geophys. Res. Oceans 121, 6696–6716. https://doi.org/10.1002/2016JC011694.

Waldman, R., Somot, S., Herrmann, M., Bosse, A., Caniaux, G., Estournel, C., Houpert, L., Prieur, L., Sevault, F., Testor, P., 2017. Modeling the intense 2012–2013 dense water formation event in the northwestern Mediterranean Sea: Evaluation with an ensemble simulation approach. J. Geophys. Res. Oceans 122, 1297–1324. https://doi.org/10.1002/2016JC012437.

Wu, P., Haines, K., 1996. Modeling the dispersal of Levantine Intermediate Water and its role in Mediterranean deep water formation. J. Geophys. Res. 101, 6591-6607. https://doi.org/10.1029/95JC03555.

Zavatarelli, M., Pinardi, N., Kourafalou, V.H., Maggiore, A., 2002. Diagnostic and prognostic model studies of the Adriatic Sea general circulation: seasonal variability. J. Geophys. Res. 107, 3004. https://doi.org/10.1029/2000JC000210.

Zore-Armanda, M., 1956. On gradient currents in Adriatic Sea, Acta Adriat. 8, 1–38.

Zore-Armanda, M., 1963. Les masses d'eau de la mer Adriatique. Acta Adriat. 10, 5–88.

Zore-Armanda, M., 1969. Water exchange between the Adriatic and the eastern Mediterranean. Deep-Sea Res. 16, 171–178.

Zore-Armanda, M., Gačić, M., 1987. Effects of Bora on the circulation in the North Adriatic. Ann. Geophys. 5B, 93–102.

8. ŽIVOTOPIS – NATALIJA DUNIĆ, mag. phys.

Natalija Dunić je diplomirala u listopadu 2014. godine na PMF-u, Sveučilište u Splitu, smjer „Fizika okoliša“. Titulu magistre fizike je stekla obranom diplomskog rada pod naslovom „Mapping of oceanographic profiles on Palagruža Sill by using neural networks“. Nedugo nakon, se zaposlila na Institutu za oceanografiju i ribarstvo u Splitu, te upisala doktorski studij geofizike na Sveučilište u Zagrebu.

Tijekom diplomskog studija, Natalija je aktivno popularizirala znanost, temeljem čega je 2013. godine dobila Rektorovu nagradu za posebna postignuća: 3 godine je bila član organizacijskog odbora „Festival znanosti“, Split (2012. - 2014.), te je 2 godine bila član organizacijskog odbora „Ljetna Tvornice Znanosti“, Split i Preko (2011. i 2012.).

Njeno dosadašnje područje znanstvenog istraživanja uključuje analizu reprodukcije termohaline cirkulacije i varijabilnosti u Jadranskom moru, stvaranja gustih voda i Jadransko-jonske bimodalne oscilacije (engl. *Adriatic-Ionian Bimodal Oscillating System*, BiOS), pomoću regionalnih klimatskih modela za Sredozemlje. Ta istraživanja su važna za pouzdano kvantificiranje navedenih procesa u budućnosti, kako bi se što preciznije procijenile potencijalne promjene svojstava Jadranskog mora, koje u određenim scenarijima mogu dovesti do izuzetno negativnih utjecaja na morski živi svijet u cjelini.

U dosadašnjoj znanstvenoj karijeri Natalija je objavila 7 izvornih znanstvenih radova, od kojih su 6 u Q1 rangiranim svjetskim časopisima (vidi „Popis objavljenih radova“). Dva Q1 rada u kojima je vodeći autor publicirani su u časopisima Climate Dynamics i Ocean Modelling. Svoja istraživanja je i usmeno predstavila na 2 svjetski poznate konferencije (EGU-General Assembly, Beč; IAPSO-IAMAS-IAGA, Cape Town), te na 4 međunarodne znanstvene radionice (HyMeX, Barcelona; THEMES, Venecija; MedCORDEX, Rim; MedCLIVAR, Beograd). Završila je 5 međunarodnih znanstvenih škola (FixO3, MARUM; EuroFleets, IOR; School on Climate Modelling, ICTP; EOS-COST DAAM, EU COST; Advanced Training School on Sustainable Growth in the Mediterranean and Black Sea countries, OGS), te 2 stručne specijalizacije (CNRM - UMR3589, CNRS/Météo-France, Toulouse, Francuska).

Osim toga, sudjeluje i u provedbi nekoliko projekata: ADIOS (engl. „The Adriatic interannual to decadal oscillations: observations, modelling and consequences“, projekt Hrvatske zaklade za znanost), te ECOSS i CHANGE WE CARE (projekti programa Interreg Hrvatska-Italija).

9. POPIS OBJAVLJENIH RADOVA – NATALIJA DUNIĆ

Izvorni znanstveni radovi (WoSCC):

1. **Dunić, N.,** Vilibić, I., Šepić, J., Mihanović, H., Sevault, F., Somot, S., Waldman, R., Nabat, P., Arsouze, T., Pennel, R., Jordà, J., Precali, R. 2019. Performance of multi-decadal ocean simulations in the Adriatic Sea. Ocean Modelling, 134, 84-109.

2. Vilibić, I., Šepić, J., **Dunić, N.,** Sevault, F., Monserrat, S., Jordà, G., 2018. Proxy-based assessment of strength and frequency of meteotsunamis in future climate. Geophysical Research Letters 45. 10501-10508.

3. Peharda, M., Vilibić, I., Black, B.A., Markulin, K., **Dunić, N.,** Džoić, T., Mihanović, H., Gačić, M., Puljas, S., Waldman, R., 2018. Using bivalve chronologies for quantifying environmental drivers in a semi-enclosed temperate sea. Scientific Reports, 8, 5559, doi: 10.1038/s41598-018-23773-w.

4. **Dunić, N.,** Vilibić, I., Šepić, J., Somot, S., Sevault, F., 2018. Dense water formation and BiOS-induced variability in the Adriatic Sea simulated using an ocean regional circulation model. Climate Dynamics 51, 1211-1236.

5. Vilibić, I., Mihanović, H., Janeković, I., Denamiel, C., Poulain, P.-M., Orlić, M., **Dunić, N.,** Dadić, V., Pasarić, M., Muslim, S., Gerin, R., Matić, F., Šepić, J., Mauri, E., Kokkini, Z., Tudor, M., Kovač, Ž., Džoić, T., 2018. Wintertime dynamics in the coastal northeastern Adriatic Sea: the NAdEx 2015 experiment. Ocean Science 14, 237-258.

6. Šepić, J., Međugorac, I., Janeković, I., **Dunić, N.,** Vilibić, I., 2016. Multi-meteotsunami event in the Adriatic Sea generated by atmospheric disturbances of 25–26 June 2014. Pure and Applied Geophysics, 173, 4117-4138.

7. Mihanović, H., Vilibić, I**., Dunić, N.,** Šepić, J., 2015. Mapping of decadal middle Adriatic oceanographic variability and its relation to the BiOS regime, Journal of Geophysical Research Oceans 120, 5615-5630.

Međunarodna kongresna priopćenja:

1. Vilibić, I. Zemunik, P., **Dunić, N.,** Marzouk, O., Šepić, J., Mihanović, H., Denamiel, C., Precali, R., Djakovac, T., 2018. Long-term trends and variability in thermohaline properties of the northern Adriatic. THEMES 2018 Workshop, Venice, 28-30 November 2018.

2. Vilibić, I., Mihanović, H., Šepić, J., **Dunić, N.**, Denamiel, C., Peharda, M., Somot, S., Sevault F., Gačić, M., 2018. The Adriatic-Ionian Bimodal Oscillating System: relevance, phenomenology, reproducibility. AGU 100 Fall Meeting, Washington DC, 10-14 December 2018.

3. **Dunić, N.,** Vilibić, I., Šepić, J., Mihanović, H., Sevault, F., Somot, S., Waldman, R., Arsouze, T., Pennel, R., Nabat, P., 2018. Present and future climate and variability of the Adriatic dense water formation and the BiOS: Assessment of climate models. MedCLIVAR 2018 Conference, Belgrade, 17-21 September 2018, Book of Abstracts, 68.

4. Vilibić, I., **Dunić, N.**, Mihanović, H., Šepić, J., 2018. The Adriatic-Ionian Bimodal Oscillating System (BiOS) and the Adriatic Oceanography, MedCLIVAR 2018 Conference, Belgrade, 17-21 September 2018, Book of Abstracts, 10.

5. Peharda, M., Vilibić, I., Džoić, T., Markulin, K., **Dunić, N.,** Mihanović, H., Gačić, M., Black, B., Uvanović, H., Ezgeta-Balić, D., Šepić, J., Kovač, Ž., Župan, I., 2017. Sclerochronology: tool for uncovering environmental drivers in a semi-enclosed sea. Workshop THEMES 2017 - Physics and Biogeochemistry of Marine Environments: Multiscale Analysis of Past and Present Variability, 15-17 November 2017, Venice.

6. **Dunić, N.,** Vilibić, I., Šepić, J., Sevault, F., Somot, S., Waldman, R., Arsouze, T., Pennel, R., Nabat, P., Jorda, G., Precali, R., 2017. Multi-model analysis of the Adriatic-Ionian thermohaline circulation using multi-decadal regional ocean simulations. Workshop THEMES 2017 - Physics and Biogeochemistry of Marine Environments: Multiscale Analysis of Past and Present Variability, 15-17 November 2017, Venice.

7. **Dunić, N.,** Vilibić, I., Šepić, J., Sevault, F., Somot, S., Waldman, R., Arsouze, T., Pennel, R., Nabat, P., Jordà, G., 2017. Multi-model analysis of the Adriatic-Ionian thermohaline circulation using an ensemble of multi-decadal regional ocean simulations. IAPSO-IAMAS-IAGA Joint Assembly, 27 August-1 September 2017, Cape Town.

8. **Dunić, N.,** Vilibić, I., Šepić, J., Sevault, F., Somot, S., Waldman, R., Arsouze, T., Pennel, R., Nabat, P., Jordà, G., 2017. Multi-model analysis of the Adriatic-Ionian thermohaline

circulation using an ensemble of multi-decadal regional ocean simulations. 10th HyMeX Workshop, 4-7 July 2017, Barcelona.

9. Vilibić, I., Mihanović, H., Janeković, I., Denamiel, C., Poulain, P.-M., Orlić, M., **Dunić, N.,** Dadić, V., Pasarić, M., Muslim, S., Gerin, R., Matić, F., Šepić, J., Mauri, E., Kokkini, Z., Tudor, M., Kovač, Ž., Džoić, T., 2017. Dense water formation in the coastal northeastern Adriatic Sea: the NAdEx 2015 experiment. 10th HyMeX Workshop, 4-7 July 2017, Barcelona.

10. Darmaraki, S., Somot, S., Sevault, F., Nabat, P., Sannino, G., Djurdjevic, V., Li, L., Cavicchia, L., William, C., Sein, D., Bensoussan, N., Bensi, M., Cardi, V., Siena, G., **Dunić, N.,** Garrabou, J., Vassilios, V., 2017. Future evolution of marine heat waves in the Mediterranean: Coupled regional climate projections, 10th Hymex Workshop, 4-7 July 2017, Barcelona.

11. **Dunić, N.,** Vilibić, I., Šepić, J., Sevault, F., Somot, S., Waldman, R., Jorda, G., 2016. Long-term climate variability of the Adriatic Sea thermohaline properties using an ensemble of regional ocean hindcast simulations. Geophysical Research Abstracts, 18, EGU2016-826, Beč.

12. Vilibić, I., Mihanović, H., Šepić, J., **Dunić, N.,** 2015. Modes of the Adriatic long-term variability as seen on half-centurial Palagruža Sill series. Workshop THEMES-Teleconnections and Hemispheric-scale Impacts on the Mediterranean Sea, 25-26 November 2015, Venice.

13. **Dunić, N.,** Vilibić, J., Šepić, J., 2015. NEMOMED8 performance in the Adriatic Sea: the first results. Workshop THEMES-Teleconnections and Hemispheric-scale Impacts on the Mediterranean Sea, 25-26 November 2015, Venice.

14. Šepić, J., Vilibić, I., Međugorac, I., Telišman-Prtenjak, M., Janeković, I., **Dunić, N.,** 2015. Adriatic meteotsunami events of 25-26 June 2014: observations, numerical modelling and assessment of atmospheric processes. 26th IUGG General Assembly, Prague, 22 June – 2 July 2015.

Domaća kongresna priopćenja:

1. Vilibić, I., Šepić, J., **Dunić, N.,** 2015. Klimatske promjene u Jadranu: status i perspektive. Meteorološki izazovi 4 - Klimatske promjene - odgovornosti današnje generacije, Zagreb, 24.-25. studeni 2015.