Numeričko modeliranje disperzije u Jadranskom moru primjenom lagrangeovskih metoda

Džoić, Tomislav

Doctoral thesis / Disertacija

2018

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:475567

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet
Geofizički odsjek

Tomislav Džoić

NUMERIČKO MODELIRANJE DISPERZIJE U JADRANSKOM MORU PRIMJENOM LAGRANGEOVSKIH METODA

DOKTORSKI RAD

Mentor:
dr.sc. Gordana Beg Paklar

Zagreb, 2018.

University of Zagreb

Faculty of Science
Department of Geophysics

Tomislav Džoić

APPLICATION OF LAGRANGIAN METHODS IN NUMERICAL MODELLING OF DISPERSION IN THE ADRIATIC SEA

DOCTORAL DISSERTATION

Supervisor:
Dr. Gordana Beg Paklar

Zagreb, 2018

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

Dr. sc. Gordana Beg Paklar je viši znanstveni suradnik na Institutu za oceanografiju i ribarstvo u Splitu. U siječnju 1989. godine diplomirala je fiziku, smjer geofizika s meteorologijom na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu. Na istom fakultetu obranila je 1992. godine magistarski rad iz područja fizičke oceanografije, a 2000. godine i doktorsku disertaciju pd naslovom 'Djelovanje bure na sjeverni Jadran – simulacije meteorološkim i oceanografskim modelima'. Od kolovoza 1989. radi u Laboratoriju za fiziku mora Instituta za oceanografiju i ribarstvo u Splitu, gdje se trenutno kao viši znanstveni suradnik bavi analizom međudjelovanja atmosfere i mora, te numeričkim modeliranjem čitavog spektra procesa u moru. Na dodiplomskom studiju Odjela za studije mora Sveučilišta u Splitu vodi kolegij iz područja fizičke oceanografije, a sudjeluje i u nastavi poslijediplomskog doktorskog studija Fizike – smjer geofizika na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu, te poslijediplomskog doktorskog studija Primijenjene znanosti o moru Sveučilišta u Splitu. Objavila je četrdesetak stručnih i znanstvenih radova iz područja fizike mora i numeričkog modeliranja, te niz kongresnih priopćenja. Član je Komiteta za fiziku Međunarodne komisije za znanstveno istraživanje Mediterana (CIESM), Europskog geofizičkog društva (European Geophysical Society), Hrvatskog meteorološkog društva (HMD) te Izvršnog odbora Hrvatskog povjerenstva za geodeziju i geofiziku.

ZAHVALE

Zahvaljujem se mentorici dr. sc. Gordani Beg Paklar na iscrpnim savjetima, prenešenom znanju, sveukupnoj pomoći, podršci i povjerenju tijekom izrade ovog rada. Također se zahvaljujem predsjedniku stručnog povjerenstva za ocjenu doktorskog rada dr. sc. Ivici Vilibiću na konstruktivnim kritikama i idejama, te članovima povjerenstva akademiku Mirku Orliću i dr. sc. Nedi Vrgoču na korisnim komentarima.

Posebnu zahvalnost dugujem dr. sc Barbari Zorici, dr. sc. Vanji Čikeš Keč i dr. sc. Tanji Šegvić Bubić na ustupljenim biološkim podacima i iznimnoj pomoći u razumijevanju bioloških koncepata. Također zahvaljujem Philippeu Verleyu i dr. sc. Christopheu Lettu s Institute de Recherche pour le Developpement iz Francuske na programskoj implementaciji modula plivanja čestica u individualno temeljeni model Ichthyop. Zahvalan sam i mr. sc. Stjepanu Ivatek-Šahdanu s Državnog hidrometeorološkog zavoda na ustupljenim poljima atmosferskog modela ALADIN.

Veliko hvala ide dr. sc. Hrvoju Mihanoviću, dr. sc Frani Matiću, dr. sc Žarku Kovaču i dr. sc Jadranki Šepić na praktičnim savjetima u znanstvenom radu tijekom ovih 6 godina.

I na kraju, zahvala ocu Ivi, majci Lizi te bratu Krešimiru na pruženoj potpori.

SAŽETAK

Jedan od nedovoljno istraženih problema u morskoj ekologiji je mehanizam transporta čestica prirodnog odnosno antropogenog podrijetla. U rješavanju problema rasprostiranja tvari u moru danas se sve više koriste lagrangeovske metode. Lagrangeovski stohastički disperzijski modeli koriste veliki broj čestica kako bi simulirali transport i disperziju tvari iz izvora pod utjecajem trodimenzionalnih polja izračunatih oceanografskim modelima. Langrangeovske koherentne strukture (eng. Lagrangian coherent structures; LCS) su analitički alat koji otkriva, ne uvijek očite, mehanizme transporta u fluidima.

Upotrebom numeričkog oceanografskog modela ROMS, lagrangeovskog individualno temeljenog modela (ITM) Ichthyop i proračuna LCS-ova metodom Ljapunovljevog eksponenta konačnog vremena (eng. finite-time Lyapunov exponent; FTLE) pokazala se povezanost jedinki riba ulovljenih u srednjem i južnom Jadranu s pretpostavljenim lokacijama mrijesta vezanim uz uzgajališta. Navedena metodologija primijenjena je na dva slučaja u kojima je prethodno utvrđena genetska povezanost. Prvi slučaj je potraga za mogućom lokacijom mrijesta jedinki tune koje su uhvaćene južno od otoka Mljeta 1. rujna 2011. godine. Ljeto 2011. je bilo karakterizirano obratom istočnojadranske struje u površinskom sloju i opaženim spontanim mrijestom odraslih tuna u uzgajalištima. Drugi slučaj je povezivanje lokacije mrijesta s lokacijama rastilišta ranih stadija komarče tijekom prvih pet mjeseci 2016. godine. Lokacije mrijesta su u blizini uzgajališta uz obale Brača i Ugljana, dok su rastilišta u boćatim područjima Neretve, Pantana i Raše. Prostorna raspodjela čestica u obje simulacije je pratila dinamiku strujanja u Jadranskom moru koje je prevladavalo u analiziranom razdoblju. Privlačni i odbojni LCS-ovi su se podudarali s područjima najvećih koncentracija čestica, odnosno omeđivali su ih od područja do kojih čestice nisu mogle biti transportirane. Korištenje ITM-ova i LCS-ova omogućuje prepoznavanje područja u kojem se odvija najveći dio transporta ihtioplanktona.

EXTENDED ABSTRACT

Understanding and modelling of particle transport has been recognized as a challenge in state-of-the-art marine ecology research. Number of applications based on Lagrangian methods in describing the dynamics of the ocean particles, either of natural or antropogenic origin, is increasing nowdays. Lagrangian stochastic dispersion models are, by calculating trajectories of a large number of particles, attempting to simulate transport and dispersion of a matter in oceans. Among other, Lagrangian coherent structures (LCS) may be used as a proxy for assessment of the transport in a fluid.

Application of numerical oceanographic model ROMS, Lagrangian individual-based model Ichthyop and finite-time Lyapunov exponent (FTLE) method used for LCS showed the connectivity between the locations of Atlantic bluefin tuna (ABFT) and gilthead sea bream (GSB) catches and their spawning areas located near fish farm cages. Numerical oceanographic model ROMS was used to provide three-dimensional fields for the Lagrangian individual-based model Ichthyop. To assess a reliability of simulations, ROMS model has been verified on available physical measurements: satellite sea surface temperature (SST) measurements, SST measured at climatological stations, SST measured at tuna farm, vertical salinity and temperature profiles measured by CTD probe, Argo drifter pathways and vertical salinity and temperature profiles, and high-frequency (HF) sea surface current measurements. Attractive and repulsive LCS were used to mark pathways and boundaries for particle transport.

During routine monitoring of commercial purse seine catches in 2011, 87 fingerling specimens of scombrids were collected in the southern Adriatic Sea, near Mljet Island. DNA analysis showed that 29 specimens belonged to the ABFT. The age of collected tuna specimens was estimated at approximately 30-40 days. It has been hypothesized that small ABFT originated from the tuna farms located near islands Brač, Ugljan, Gira and Fulija located along the eastern Adriatic coast, as spawning in cages was observed at tuna farm located near Ugljan in summer months of 2011. A coupled modelling system ROMS-Ichthyop was set up and run, to verify connectivity between ABFT catch and spawn locations. Simulated current fields revealed an Eastern Adriatic Current (EAC) reversal, i.e. currents reversed from NW to SE flow along the eastern Adriatic coast, that was previously observed from direct current measurements and obtained by numerical models. Both backward and forward dispersion simulations were carried out. In the backward

simulations, starting point was near Mljet and all particles were released on 1 September. In the forward simulations, sources of particles were located near fish farms. Particles in the forward simulations were released each day between 17 July and 5 August. Results of forward and backward numerical dispersion simulations demonstrated that the most probable origin of collected specimens was tuna farm near the island of Brač. Upon spawning, ABFT ichthyoplankton was transported southward with prevailing SE current toward the locations south of Island Mljet. Furthermore, forward experiments indicated that particles from Brač could be carried away as passive particles near the location of catch in 20 days. Particles from Ugljan and Gira could not reach location of catch because of presence of repulsive barrier near Cape Planka visible in FTLE fields, which blocked their pathway toward south. Vertical temperature and salinity profiles measured with Argo drifter matched modeled ones (temperature BIAS range was between -1.252 and -0.749 °C, salinity BIAS ranged from -0.029 to 0.14). Argo drifter trajectory was also in good agreement with simulated virtual particles trajectories. Because of the relatively small number of Argo drifter positions (the float was surfacing every five days), visual evaluation was used to assess the realism of the trajectory instead of the statistical methods. Modelled and measured time series of seawater temperature at 1 m depth within the fish farm cage near the island of Ugljan had significant corelation ($r = 0.73,\ \alpha = 0.01$). High temperatures recorded at the beginning of measurements at Ugljan tuna farm was a probable trigger for spontaneous tuna spawning. Introduction of new swimming parametrization into Ichthyop model did not improve results, because in each time step swimming direction was randomly chosen. Introduction of vertical diel movement resulted in particle advection towards western Adriatic coast. Vertical diel movement was implemented from research results obtained in the western Mediterranean Sea, because similar data from Adriatic Sea are missing. Possibility of particle arrivals from the Ionian Sea, secondary potential spawning ground, was rejected with two tests: by assessing velocities and directions of prevailing currents in the Ionian Sea from the Mediterranean numerical model and by releasing particles in the Strait of Otranto during Adriatic Ichthyop simulation. High FTLE values clearly marked boundaries of possible particle transport, being quite useful in mapping coherent structures in which particles are free to drift.

A significant increase of wild GSB population has been documented in coastal areas of Adriatic Sea in recent years. A rapid expansion of aquaculture has been offered as

a culprit, which presumably influenced Adriatic wild populations in many ways. In the presented case, tuna fish farms in front of islands of Brač and Ugljan were food sources for wild GSB population. In May 2016 wild GSB offsprings in three natural nursery grounds were collected in brackish areas of Neretva, Pantan and Raša. Genetic analysis showed their connection with species sampled near two aquaculture areas Brač and Ugljan. A coupled modelling system ROMS-Ichthyop was set up to test correlation between genetic and transport connectivity of GSB. Two different ROMS setups were used: one for the whole Adriatic Sea with resolution of 2.5 km and one for smaller domain encompassing eastern coastal area of the middle Adriatic Sea with resolution of 1 km. Currents calculated by both ROMS setups matched with HF radar measurements. Current jets and wakes were observed in HF radar surface current fields. Small anticyclone gyre observed in radar surface current field was reproduced in ASHELF-2 field, but with the shift to the south. Vertical homogeneity of temperature profile during winter and appearance of stratification in water column during spring months were observed in measured CTD profiles. Same structures were successfully modeled too (Argo temperature BIAS range was between -1.308 and -0.66 °C, Argo salinity BIAS ranged from -0.384 to -0.22). ASHELF-2 temperature and salinity profiles matched measured profiles better than profiles obtained by Adriatic ROMS which is confirmed by lower RMSE and BIAS. Visual comparison indicates that virtual drifter trajectory matched Argo drifter trajectory along the edge of south Adriatic pit. Forward and backward simulations were used to test connectivity between nursery and fish farms considered as spawning grounds. In the forward simulations, particles were released each day during the first two months of 2016 at the locations of tuna farms at Brač and Ugljan. In the backward simulation particles were released on 15 May 2016 from nursery areas. Spatial distributions in both backward and forward simulations showed connectivity between nurseries and spawning areas. Most of the passive particles were transported with the EAC, which strengthened during February presumably under the influence of the sirocco wind. Introduction of lethal temperature parametrisation in Ichthyop model demonstrated negative impact which environment may have on ichthyoplankton transport and its survival during strong bora events. Introduction of particle beaching behavior resulted in more realistic results. Particle distribution boundaries were highlighted with repulsive LCS, whereas attractive LCS pointed to the areas where most of the transport occured.

In this thesis, coupled modelling system ROMS-Ichthyop was used to investigate connectivity for two fish species in short time span. Results of multiyear simulations with coupled models could serve to study success of transport from spawning areas toward nurseries in different environmental conditions. Trends obtained by modelling can be compared with trends from long term series of biological measurements. The matching of modelled and measured trends would enable, taking into consideration climate projections, to answer the questions about adjustment of different species to environmental changes. Use of LCS on multiyear oceanographic model simulations could resolve variations of ichtyoplankton pathways during climate changes and shifts in ocean and atmosphere. Obtained knowledge can be used to determine marine protected areas, which play an important role in fish recruitment.

Ključne riječi: transport u moru, disperzija ihtioplanktona, numerički model, lagrangeovski disperzijski model, individualno temeljeni model, lagrangeovske koherentne strukture, Ljapunovljev eksponent konačnog vremena

Keywords: ocean transport, ichthyoplankton dispersion, numerical model, Lagrangian dispersion model, individual-based model, Lagrangian coherent structures, finite-time Lyapunov exponent

Sadržaj

TEMELJNA DOKUMENTACIJSKA KARTICA xi

BASIC DOCUMENTATION CARD xii

1. UVOD 1
1.1. Lagrangeovski modeli 1
1.2. Individualno temeljeni modeli 3
1.3. Lagrangeovske koherentne strukture 5
1.4. Kratki opis doktorskog rada 6

2. MATERIJALI I METODE 8
2.1. Podaci 8
2.1.1. Biološki podaci o atlantskoj plavoperajnoj tuni 8
2.1.2. Biološki podaci o komarči 10
2.1.3. Oceanografski podaci 10
2.1.4. Radarska mjerenja 13
2.2. Oceanografski numerički hidrodinamički model ROMS 15
2.2.1. Osnovne značajke modela ROMS 15
2.2.2. Opis konfiguracije modela ROMS 20
2.3. Individualno temeljeni model Ichthyop 23
2.4. Ljapunovljev eksponent konačnog vremena 26
2.4.1. Teorijski uvod 26
2.4.2. Odabir FTLE parametara 33

3. DISPERZIJA IHTIOPLANKTONA ATLANTSKE PLAVOPERAJNE TUNE U JADRANSKOM MORU 40
3.1. Motivacija za istraživanje 40
3.2. Opis modelskog sustava 41
3.3. Rezultati 45
3.3.1. Meteorološki i oceanografski uvjeti 45
3.3.2. Rezultati lagrangeovskih izračuna 57
3.4. Diskusija 70

4. DISPERZIJA IHTIOPLANKTONA KOMARČE U JADRANSKOM MORU 75
4.1. Motivacija za istraživanje 75
4.2. Opis modelskog sustava 77
4.3. Rezultati 80
4.3.1. Meteorološki i oceanografski uvjeti 80
4.3.2. Rezultati lagrangeovskih izračuna 96

4.4. Diskusija 112
4.4.1. Ovisnost o danu ispuštanja čestica, tj. danu mrijesta 112
4.4.2. Ovisnost o sinoptičkoj situaciji.....114
4.4.3. Utjecaj letalne temperature.....120
4.4.4. Prostorna razdioba koherentnih struktura.....122

5. ZAKLJUČCI 125

6. LITERATURA 130

7. ŽIVOTOPIS 152

8. POPIS OBJAVLJENIH RADOVA 153

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geofizički odsjek

Doktorski rad

NUMERIČKO MODELIRANJE DISPERZIJE U JADRANSKOM MORU PRIMJENOM LAGRANGEOVSKIH METODA

Tomislav Džoić

Institut za oceanografiju i ribarstvo, Šetališe Ivana Meštrovića 63, 21000 Split, Hrvatska

Jedan od nedovoljno istraženih problema u morskoj ekologiji je mehanizam transporta čestica prirodnog odnosno antropogenog podrijetla. U rješavanju problema rasprostiranja tvari u moru danas se sve više koriste lagrangeovske metode. Lagrangeovski stohastički disperzijski modeli koriste veliki broj čestica kako bi simulirali transport i disperziju tvari iz izvora pod utjecajem trodimenzionalnih polja izračunatih oceanografskim modelima. Langrangeovske koherentne strukture (LKS) su analitički alat koji otkriva, ne uvijek očite, mehanizme transporta u fluidima. Upotrebom numeričkog oceanografskog modela ROMS, lagrangeovskog individualno temeljenog modela (ITM) Ichthyop i proračuna LKS-ova metodom Ljapunovljevog eksponenta konačnog vremena pokazala se povezanost jedinki riba ulovljenih u srednjem i južnom Jadranu s pretpostavljenim lokacijama mrijesta vezanim uz uzgajališta. Navedena metodologija primijenjena je na dva slučaja u kojima je prethodno utvrđena genetska povezanost. Prvi slučaj je potraga za mogućom lokacijom mrijesta jedinki tune, *Thunnus thynnus* (Linnaeus, 1758), koje su uhvaćene južno od otoka Mljeta 1. rujna 2011. godine. Drugi slučaj je povezivanje lokacije mrijesta s lokacijama rastilišta ranih stadija komarče, *Sparus aurata* (Linnaeus, 1758), tijekom prvih pet mjeseci 2016. godine. Prostorna raspodjela čestica u obje simulacije je pratila dinamiku strujanja u Jadranskom moru koje je prevladavalo u simuliranom razdoblju. Privlačni i odbojni LKS-ovi su se podudarali s područjima najvećih koncentracija čestica, odnosno omeđivali su ih od područja do kojih čestice nisu mogle biti transportirane. Korištenje ITM-ova i LKS-ova omogućuje prepoznavanje područja u kojem se odvija najveći dio transporta ihtioplanktona.

Rad sadrži: 153 stranice; 62 slike; 9 tablica; 191 literaturni navod

Jezik izvornika: hrvatski

Rad je pohranjen u: Središnjoj geofizičkoj knjižnici Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Horvatovac 95, 10000 Zagreb, Hrvatska

Ključne riječi: transport u moru, disperzija ihtioplanktona, numerički model, lagrangeovski disperzijski model, individualno temeljeni model, lagrangeovske koherentne strukture, Ljapunovljev eksponent konačnog vremena

Mentor: dr. sc. Gordana Beg Paklar, viši znanstveni suradnik

Ocjenjivači: dr. sc. Ivica Vilibić, znanstveni savjetnik; akademik Mirko Orlić, redoviti profesor u trajnom zvanju; dr. sc. Nedo Vrgoč, znanstveni savjetnik

Rad prihvaćen: 4. prosinca 2018. godine na sjednici Vijeća Geofizičkog odsjeka Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu

University of Zagreb
Faculty of Science
Department of Geophysics

Doctoral Thesis

APPLICATION OF LAGRANGIAN METHODS IN NUMERICAL MODELLING OF DISPERSION IN THE ADRIATIC SEA

Tomislav Džoić

Institute of Oceanography and Fisheries, Šetališe Ivana Meštrovića 63, 21000 Split, Croatia

Understanding and modelling of particle transport has been recognized as a challenge in state-of-the-art marine ecology research. Number of applications based on Lagrangian methods in describing the dynamics of the ocean particles, either of natural or antropogenic origin, is increasing nowdays. Lagrangian stochastic dispersion models are, by calculating trajectories of a large number of particles, attempting to simulate transport and dispersion of a matter in oceans. Among other, Lagrangian coherent structures (LCS) may be used as a proxy for assessment of the transport in a fluid. Application of numerical oceanographic model ROMS, Lagrangian individual-based model (IBM) Ichthyop and finite-time Lyapunov exponent method used for LCS calculation showed the connectivity between the locations of Atlantic bluefin tuna and gilthead sea bream catches and their spawning areas located near fish farm cages. Proposed methodology was applied to two specific cases in which genetic connectivity was confirmed by DNA analysis first. The first case is search for the possible Atlantic bluefin tuna, *Thunnus thynnus* (Linnaeus, 1758), spawning location during summer 2011, and the second case comprises connectivity between spawning and nursery location of the gilthead sea bream, *Sparus aurata* (Linnaeus, 1758), during first five months in 2016. In both cases attractive LCS matched areas with highest particle concentrations, whereas negative LCS enveloped areas where particles could not be transported. Use of IBM and LCS enables detection of the areas where most of the ichthyoplankton transport occurs.

Thesis contains: 153 pages; 62 figures; 9 tables; 191 references

Original in: Croatian

Thesis deposited in: Central Geophysical Library of the Faculty of Science, University of Zagreb, Horvatovac 95, 10000 Zagreb, Croatia

Keywords: ocean transport, ichthyoplankton dispersion, numerical model, Lagrangian dispersion model, individual-based model, Lagrangian coherent structures, finite-time Lyapunov exponent

Supervisor: Dr. Gordana Beg Paklar, Senior scientific associate

Reviewers: Dr. Ivica Vilibić, Scientific adviser; F.C.A. Mirko Orlić, Full professor tenure; Dr. Nedo Vrgoč, Scientific Advisor

Thesis accepted: on 4 December 2018 by the Council of the Department of Geophysics, Faculty of Science, University of Zagreb

1. UVOD

Život u moru je zavisan o hidrodinamičkom okruženju u kojem se nalazi, pri čemu je strujanje jedan od fundamentalnih čimbenika (Fossette i sur., 2012). Struje najveći utjecaj ostvaruju na organizme koji ne mogu samostalno plivati ili je njihova brzina plivanja nedovoljna da se odvoje od hidrodinamičke okoline. U takve organizme spada i ihtioplankton, koji čine riblja jaja i larve. Transportom ranih stadija riba morske struje utječu na rasprostranjenost i obilje pojedinih vrsta (Munk i sur., 2010; Putman i sur., 2010).

Lagrangeovski modeli su često korišteni u istraživanjima fizikalno-biološkog međudjelovanja u morskom okolišu, a jedan od razloga je taj što se u lagrangeovske modele mogu relativno jednostavno ugraditi biološka svojstva i procesi. Lagrangeovski modeli su temeljeni na individualnim česticama kojima se potom mogu pridjeliti biološka svojstva (Christensen i sur.; 2018). Individualno temeljeni modeli (eng. individual-based model; IBM) primijenjeni na ihtioplankton su lagrangeovski disperzijski modeli koji povezuju fizikalne procese s dinamikom ihtioplanktona (Lett i sur., 2008). U IBM modelima se populacija promatra kao zbir individua čiji položaj, svojstva i ponašanje odražavaju lokalne interakcije s okolišem.

Analiza, ne uvijek očitih, mehanizama koji organiziraju transport u fluidima (Peacock i Haller, 2013) i time utječu na konačnu raspodjelu čestica dobivenu u simulacijama lagrangeovskim modelima je moguća korištenjem Lagrangeovskih koherentnih struktura (eng. Lagrangian coherent structures; LCS).

1.1. Lagrangeovski modeli

Lagrangeovsko stohastičko modeliranje je tehnika koja je prije primjene na morski ekosustav uvelike korištena u modeliranju atmosferskog graničnog sloja. Modeliranje onečišćenja u zraku su Collett i Oduyemi (1997) definirali kao pokušaj predviđanja odnosno simulacije, fizikalnim ili numeričkim putem, prostorne koncentracije polutanata unutar atmosferske domene. Modele koji se koriste za simulaciju koncentracija polutanata u atmosferi nazivamo modelima kvalitete zraka. Postoji nekoliko osnovnih tipova determinističkih numeričkih modela kvalitete zraka (Collett i Oduyemi, 1997; Kos i sur., 2004). "Box" modeli računaju koncentraciju

polutanata unutar pravokutnog prostora, koristeći jednadžbu očuvanja mase uz pretpostavku homogenih uvjeta. Eulerovski modeli također rješavaju jednadžbu očuvanja mase za dani polutant u eulerovskom sustavu na ekvidistantnoj mreži. Gaussovi modeli koriste pretpostavku da se disperzija polutanta može opisati modificiranom Gaussovom ili normalnom raspodjelom. U lagrangeovskim modelima referentni sustav slijedi prevladavajući vektor atmosferskog gibanja. Lagrangeovski modeli su iznimno moćan računalni alat koji numeričkim diskretnim izračunom omogućuje rješavanje različitih fizikalnih problema. Konačan broj infinitezimalnih čestica ispuštenih u kratkim intervalima oponaša izvor polutanta. Izračunom lagrangeovskih putanja velikog broja čestica se simulira disperzija. Svaka čestica se giba pod utjecajem srednje brzine fluida i turbulentne brzine na skalama manjim od rezolucije modela. Turbulentne brzine se računaju stohastički (zasnovano na Langevinovoj jednadžbi) ili deterministički.

U razvoju disperzijskih modela za primjene u moru najviše se teorijskog i empirijskog napora ulaže u poboljšanja prediktabilnih svojstava (Haza i sur., 2012). Istraživanja s ciljem dobivanja pouzdanijih prognostičkih disperzijskih modela su rađena i u Jadranskom moru (Haza i sur., 2008; Rixen i sur., 2008). Glavni problem u modeliranju disperzije je njezina zavisnost o procesima koji pokrivaju različite prostorne i vremenske skale primjerice poput Ekmanovog transporta, morskih mijena, incercijalnih oscilacija, površinskih valova, itd. Prognoza lagrangeovskih putanja zavisi o točnosti modela, oceanografskog te atmosferskog, čiji se rezultati koriste posredno odnosno neposredno kao podloga pri izračunu putanja. Upravo zbog toga veliki broj pogrešaka iz eulerovskih polja brzina se prenosi u lagrangeovski proračun transporta (Haza i sur., 2007; Haza i sur., 2008; Schroeder i sur., 2012).

Detaljan uvod u lagrangeovsko stohastičko modeliranje primijenjeno u oceanografiji su dali Brickman i Smith (2002). Postoje tri glavna razloga zašto je Lagrangeovsko stohastičko modeliranje u moru različito od onog u atmosferi. Prvi je taj što je turbulentni granični sloj smješten na dnu atmosfere, odnosno na površini zemlje, dok je u moru turbuletni sloj i na vrhu (zbog napetosti vjetra) i na dnu. Stoga je u moru izraženija nehomogenost vertikalne turbulentne strukture u usporedbi s atmosferom, što čini modeliranje zahtjevnijim. Drugi razlog je taj da lagrangeovski stohastički modeli (LSM) u donjim dijelovima atmosfere obično koriste površinsku turbulentnu varijablu (brzinu trenja u_*) i analitičke funkcije vertikalne turbulentne strukture (varijancu brzine $\sigma^2 = \sigma^2(z, u_*)$). U oceanografiji, korištenje

oceanografskih modela visoke rezolucije s ugrađenim turbulentnim shemama zatvaranja (Mellor i Yamada, 1974) rezultira time da su turbulentne veličine korištene u LSM-u zapravo diskretni izlazi oceanografskog modela u vremenu i prostoru. Treće, korištenje LSM-a u atmosferi najčešće spada u kategoriju istraživanja transporta u graničnom sloju na kraćim udaljenostima gdje je visoka preciznost u vremenu i prostoru važna, pa su pojednostavljenja vezana uz prostorne dimenzije i turbulentne korelacije opravdana. Proračun LSM-om u moru spada u kategoriju određivanja transporta na velikim udaljenostima, s obično nižim zahtjevima za preciznost, ali s potrebom za trodimenzionalnim stohastičkim modeliranjem koje potom zahtijeva drugačiji tip LSM-a: model slučajnog pomaka. Cilj LSM-a prema radu Thomsona i Wilsona (2012) je izračunati ansambl slučajnih putanja čestica fluida u turbulentnom toku, temeljenih na statistici polja brzine. Najjednostavnija klasa LSM-a je model slučajnog pomaka (nulti LSM), koji prikazuje putanju čestice nizom slučajnih inkremenata u položaju. Sljedeća klasa (prva klasa LSM-a) po složenosti je karakterizirana općim langevinskim pristupom. U njoj se putanje čestica kreiraju integracijom niza slučajnih inkremenata u brzini, tako da položaj čestice $\boldsymbol{X}$ i brzina $\boldsymbol{U}$ zajedno čine Markovljevu varijablu stanja. Generalni zapis modela prvog reda je:

$$dU_i = a_i dt + b_{ij} d\xi_j \,, \tag{1}$$

$$dX_i = U_i dt \tag{2}$$

gdje je t vrijeme, $a_i = (\boldsymbol{X}, U, t)$ je sistematski dio ubrzanja, dok je b_{ij} koeficijent koji skalira slučajno Gaussovo forsiranje ξ_j. Jednadžbe (1) i (2) mogu biti integrirane numerički zamjenom infinitezimalnog dt s konačnim vremenskim korakom Δt, čiji iznos je razmjeran vremenskoj skali lokalne turbulencije i pri tome može varirati duž trajektorije.

1.2. Individualno temeljeni modeli

Ihtioplankton čine rani razvojni stadiji riba – jaja i larve, koji slobodno plutaju u vodenom stupcu. Na dinamiku ihtioplanktona utječe advekcija, koja uvelike određuje transport, a time i okolišne čimbenike u kojima će se naći (Lett i sur., 2008).

Zbog snažne povezanosti transporta ihtioplanktona i morskih strujanja, u zadnjih 20-ak godina proveden je veliki broj istraživanja u kojima su se, uz in situ mjerenja za proučavanje dinamike ihtioplanktona, koristili individualno temeljeni modeli (eng. individual-based model; IBM). Jedan od tih modela je Ichthyop (Lett i sur. 2008), koji je u ovom radu primijenjen na jedinke atlantske plavoperajne tune i komarče.

IBM modeli simuliraju populaciju sastavljenu od diskretnih jedinki, omogućuju visoki nivo kompleksnosti jedinke kao i interakciju između jedinki (DeAngelis i Grimm, 2014). Svaka jedinka je karakterizirana varijablama stanja, odlikama i ponašanjem. Varijable stanja su položaj u prostoru, fiziološke osobine i osobine ponašanja. Te varijable zavise o jedinki i mogu varirati u vremenu. Ponašanje uključuje rast, razmnožavanje, reprodukciju, odabir staništa i hranjenje. IBM-ovi su modeli u kojima ponašanje na nivou populacije proizlazi iz interakcije između jedinki jednih s drugima i s okolinom ('bottom-up'). U modelu fizikalni faktori iz okoliša (morske struje, temperatura, gustoća) imaju jednako važnu ulogu kao i biološki faktori (smrtnost, rast, vertikalna migracija). Uz uzgon jaja (Catalán i sur., 2013; Ospina-Álvarez i sur., 2012) veliki utjecaj na transport može imati i dnevna vertikalna migracija (Ospina-Álvarez i sur., 2012). Pri računanju horizontalne disperzije Ichthyop modelom koriste se jednostavnije parametrizacije (Peliz i sur. 2007), koje ostavljaju prostor za daljnje usavršavanje formulacije disperzije. Procjene disperzije ihtioplanktona provode se na temelju karakteristika morskih struja koje usvajamo kao fizikalni doprinos iz oceanografskog modela i vremena unutar kojeg je ihtioplankton dominatno pasivni plivač, to jest dok ne postane sposoban da vlastitom brzinom nadvlada strujanje okoliša. Trodimenzionalni numerički oceanografski modeli se najčešće koriste kao podloga za IBM. Dobro vrednovan hidrodinamički model je uvjet za realistične simulacije u IBM modelu. Horizontalna rezolucija hidrodinamičkog modela može utjecati na trajektorije ihtioplanktona (Gallego i sur., 2007). Različito parametrizirane opcije plivanja larvi temeljene na zadanim biološkim pretpostavkama poput rasta, duljine i drugih faktora su dosad dokumentirane (Willis, 2011), no nisu uvedene u model Ichthyop.

Modeliranje disperzije ithioplanktona korištenjem IBM-a je metoda koja se koristila za proučavanje dinamike ihtioplanktona u Sredozemnom moru za nekoliko vrsta riba: inćuna *Engraulis encrasicolus* (Linnaeus, 1758) (Catalán i sur., 2013), plavoperajne tune *Thunnus thynnus* (Linnaeus, 1758) (Mariani i sur., 2010) i srdele *Sardina pilchardus* (Walbaum, 1792) (Ospina-Álvarez i sur., 2013). U Jadranskom

moru IBM Ichthyop je korišten u sljedećim znanstvenim istraživanjima: istraživanje utjecaja gradnje u otvorenom moru na povezanost populacija meduza (Vodopivec i sur., 2017), istraživanje utjecaja izgradnje vjetroelektrana na povezanost larvi bentoskih populacija (Bray i sur., 2017) te istraživanju utjecaja prirodnih fenomena poput stvaranja guste vode u sjevernom Jadranu 2012. godine na transport dijatomeja (Bernardi Aubry i sur., 2018).

1.3. Lagrangeovske koherentne strukture

Lagrangeovske koherentne strukture su analitički alat iz dinamičke teorije sistema. U oceanografiji služe kao metrika pri vizualizaciji granica odnosno obrazaca po kojima se transport u moru odvija (d'Ovidio i sur., 2004; Shadden i sur., 2005). LCS akronim je prvi put spomenut u radu Hallera i Yuana (2000) pri opisivanju privlačnih i odbojnih područja koja formiraju kostur lagrangeovske dinamike fluida. Dva su ključna načina izračuna LCS-ova: Ljapunovljev eksponent konačnog vremena (eng. finite-time Lyapunov exponent; FTLE) i Ljapunovljev eksponent konačne veličine (eng. finite-size Lyapunov exponent; FSLE). FTLE je evolucija skupine trajektorija čestica kroz vrijeme (traži se udaljenost za dani vremenski interval), dok je FSLE evolucija skupine trajektorija čestica u prostoru (traži se vrijeme za dani skup udaljenosti). U radu su LCS-ovi izračunati FTLE metodom. U oceanografskim istraživanjima LCS-ovi dobiveni računanjem FTLE-ova korišteni su za identifikaciju privlačnih i odbojnih transportnih barijera (Haller i Yuan, 2000; Boffetta i sur., 2001; Harrison i Glatzmaier, 2012; Peacock i Haller, 2013; Ourmieres i sur., 2018). U Jadranskom moru analize LCS-ova su korištene u teorijskom proučavanju transporta u idealiziranim vrtlozima (Rypina i sur., 2009). LCS su u Jadranu računati također pri istraživanju širenja pasivnih polutanata u poluzatvorenom Riječkom zaljevu (Ivić i sur., 2017), u analizi utjecaja bure i juga na transport u Tršćanskom zaljevu korištenjem visokofrekventih radarskih mjerenja površinskih polja morskih struja (Berta i sur., 2014), kao i u analizi transporta u blizini poluotoka Gargano tijekom projekta DART (eng. Dynamics of the Adriatic in Real Time) korištenjem izlaza numeričkog modela visoke rezolucije (Haza i sur., 2007).

1.4. Kratki opis doktorskog rada

U ovom radu su predstavljeni rezultati dobiveni multidisciplinarnim istraživanjem u kojem se pokušala potvrditi hipoteza o genetičkoj i hidrodinamičkoj povezanosti dviju ribljih vrsta u Jadranskom moru: atlantske plavoperajne tune i komarče. Mlade jedinke navedenih vrsta su uhvaćene na otvorenom moru 1. rujna 2011. godine (tune), odnosno na lokacijama ribljih rastilišta 15. svibnja 2016. godine (komarče). Genetska i fenotipska analiza pokazala je povezanost između uhvaćenih jedinki s roditeljskim populacijama koje obitavaju u uzgajalištima, odnosno uz uzgajališta. Potvrđena genetska korelacija je bila motivacija da se potvrdi i hipoteza o hidrodinamičkoj povezanosti. U tu svrhu pokrenut je združeni modelski sustav sastavljen od numeričkog oceanografskog modela ROMS (Shchepetkin i McWilliams, 2005; Shchepetkin, 2003) i IBM-a Ichthyop (Lett i sur., 2008). S ciljem dobivanja što kvalitetnije analize, u verifikaciji ROMS modela iskorišteni su svi dostupni fizikalni podaci, koji su opisani u 2. poglavlju rada. Fizikalni podaci su uključivali putanje i profile Argo plovka, satelitska mjerenja površinske temperature mora, klimatološka mjerenja površinske temperature mora i vertikalne profile saliniteta i temperature mjerene na klimatološkim postajama Instituta za oceanografiju i ribarstvo. Za verifikaciju rezultata ROMS modela upotrijebljeni su i podaci o morskim strujama dobiveni pomoću radara, koji se nalaze na Braču i Visu. U istom se poglavlju nalazi i kratki pregled bioloških podataka koji daju kvalitetnu pozadinu za objašnjavanje motiva i rezultata rada premda oni ne čine okosnicu samog doktorata. Teorijski opis modela ROMS i Ichthyop je dan u potpoglavljima 2.2 i 2.3. Metoda Ljapunovljevog eksponenta konačnog vremena (eng. finite-time Lyapunov exponent; FTLE) je po prvi put primijenjena u analizi transporta ihtioplanktona u kompleksnom obalnom području istočnog dijela Jadranskog mora. Njen opis dan je u potpoglavlju 2.4. U trećem dijelu je opisan modelski sustav ROMS-Ichthyop pokrenut s ciljem povezivanja jedinki malih tuna s lokacijama uzgajališta. Istraživanje je obuhvatilo ljeto 2011. godine obilježeno obratom istočnojadranske struje u površinskom sloju koji je već ranije zabilježen mjerenjima (Zore-Armanda, 1968) i dobiven rezultatima POM modela (Orlić i sur., 2006a). Ljapunovljevi eksponenti konačnog vremena su omogućili otkrivanje barijera koje su usmjeravale transport čestica. U četvrtom poglavlju je isti sustav, proširen ugnježđenim ASHELF-2 modelom, upotrijebljen za

povezivanje jedinki komarče s rastilišta smještenih u boćatim područjima Neretve, Pantane i Raše s roditeljskim populacijama oko uzgajališta tuna na Braču i Ugljanu. Istraživanje je obuhvatilo cijelu obalu istočnog Jadrana kroz dinamički aktivno vremensko razdoblje prvih pet i pol mjeseci 2016. godine.

2. MATERIJALI I METODE

2.1. Podaci

2.1.1. Biološki podaci o atlantskoj plavoperajnoj tuni

Za vrijeme rutinskog nadzora izlova mrežama potegačama u Jadranskom moru 1. rujna 2011. godine uhvaćeno je 87 jedinki riba iz porodice skušovke (*Scombridae*). Uhvaćene su južno od otoka Mljeta (42°38’55.32’’N, 17°44’31.00’’E) (slika 1.a). Napravljena je molekularna analiza DNA i izmjerene su duljine uhvaćenih jedinki s ciljem procjene starosne dobi istih (Džoić i sur., 2017). Genetičkom analizom je utvrđeno da su prikupljene jedinke pripadale slijedećim vrstama: atlantska plavoperajna tuna (N=29; u daljnjem tekstu tuna), *Thunnus thynnus* (Linnaeus, 1758), trupa, *Auxis Rochei* (Risso, 1810) (N=30) i luc, *Euthynnus alletteratus* (Rafinesque, 1810) (N=28). Izračunuta je prosječna starosna dob od 29.5±7.02 dana za sve analizirane jedinke, dok se starosni raspon jedinki tune kretao od 28 do 46 dana (slika 2.).

U 2011. godini su bila aktivna 4 komercijalna uzgajališta tuna, od toga su tri bila smještena u zadarskom otočju: uz zapadnu obalu otoka Ugljana (44°2'27.00"N, 15°10'48.45"E), kod otočića Fulije (44°1’23.00’’N, 15°6'31.55"E) i kod otočića Gire (43°50'11.37"N, 15°29'34.54"E) (slika 1.a). Četvrto uzgajalište je uz zapadnu obalu otoka Brača (43°17'19.93"N, 16°28'53.23"E) (slika 1.a). Na uzgajalištu uz otok Ugljan tijekom srpnja 2011. godine je zabilježen spontani mrijest tune, te su 19. srpnja prikupljena jaja (Grubišić i sur., 2013).

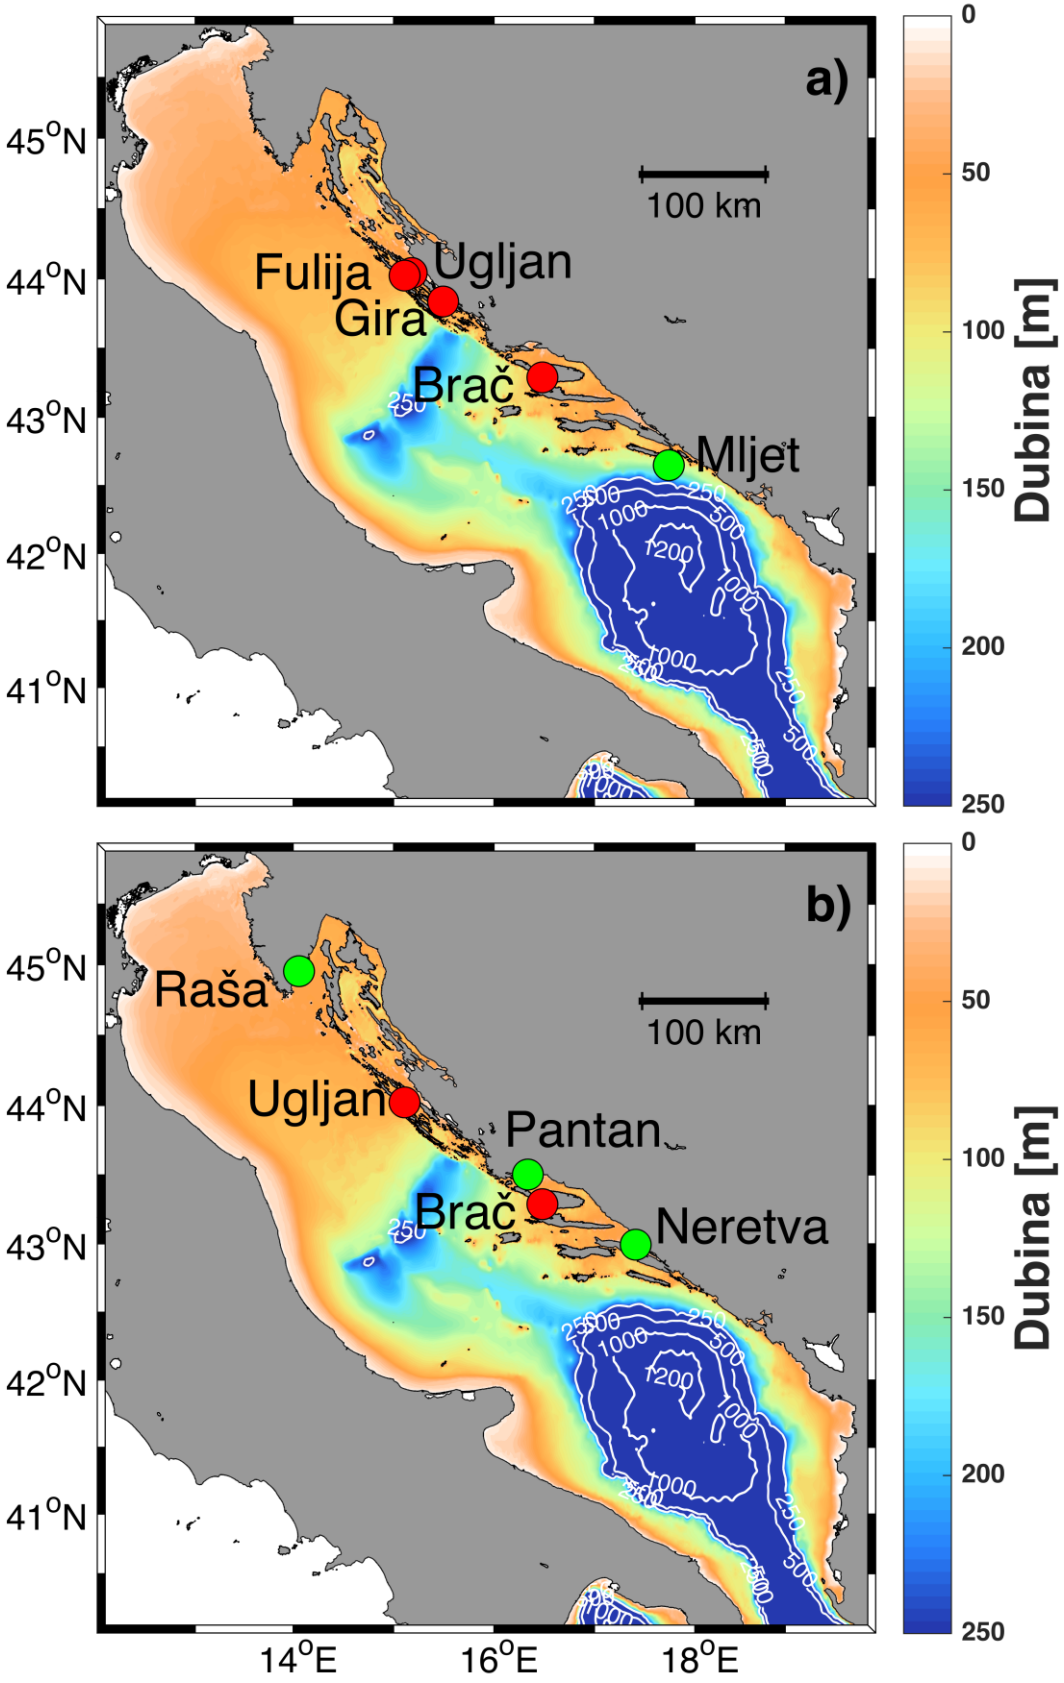

Slika 1. Batimetrija Jadranskog mora s lokacijama ulova (zeleni krugovi) i uzgajališta (crveni krugovi) za tunu u 2011. godini (a), odnosno komarču u 2016. godini (b).

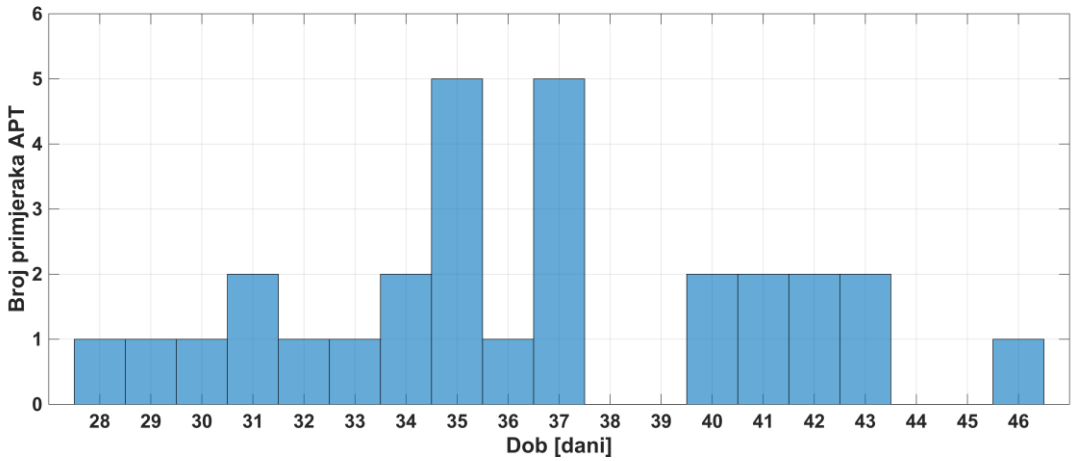

Slika 2. Distribucija izračunate starosne dobi tune ulovljene južno od Mljeta 2011. godine.

2.1.2. Biološki podaci o komarči

U razdoblju između srpnja 2015. godine i rujna 2016. godine 1546 jedinki komarče (*Sparis Aurata*) je uhvaćeno na 24 različite lokacije u istočnom dijelu Jadranskog mora. Na ušćima rijeka Raše (44°57'15.32"N, 14°3'35"E), Neretve (43°1'4.8"N, 17°26'45.6"E) i Rike (močvara Pantan) (43°30'11.88"N, 16°20'15.14"E) (slika 1.b), područje rastilišta ranih stadija, 15. svibnja je uhvaćena mlađ divlje komarče koja je imala genetsku strukturu sličnu roditeljima (rad u pripremi za objavu) uhvaćenim oko uzgajališta kod otoka Brača (43°17'19.93"N, 16°28'53.23"E) i Ugljana (44°2'27.00"N, 15°10'48.45"E). Srednja vrijednost duljine tijela komarče se kretala oko 3.5 cm, dok je prosječna dob uhvaćene komarče bila oko 100 dana (rad u pripremi za objavu). Inače, komarča se mrijesti od početka siječnja do kraja veljače (Ibarra-Zatarain i Duncan, 2015).

2.1.3. Oceanografski podaci

Površinska temperatura mora (eng. sea surface temperature; SST) je mjerena u kavezima Adriatic Tuna uzgajališta uz zapadnu obalu otoka Ugljana (slika 3.) tijekom 2011. (Grubišić i sur., 2013) pomoću uređaja AQUA Logger 520T s točnošću mjerenja od ±0.05 °C. Površinska temperatura mora na obalnim postajama Split, Hvar i Komiža (slika 3.) je mjerena u razdoblju od 1959. godine do 2015. godine od strane Pomorskog meteorološkog centra Državnog hidrometorološkog zavoda. In situ

površinska temperatura mora je mjerena tri puta na dan (u 7, 14 i 21 sati) korištenjem zaštićenog termometra, na dubini od 30 cm pri dubini mora većoj od 1.8 m po smjernicama Svjetske meteorološke organizacije (World Meteorological Organization – WMO) (Grbec i sur., 2018). Godišnja i sezonska svojstva površinske temperature mora te pripadajući trendovi su istraženi u više znanstvenih publikacija (Zore-Armanda 1969; Supić i Orlić, 1992; Vilibić i sur., 2013).

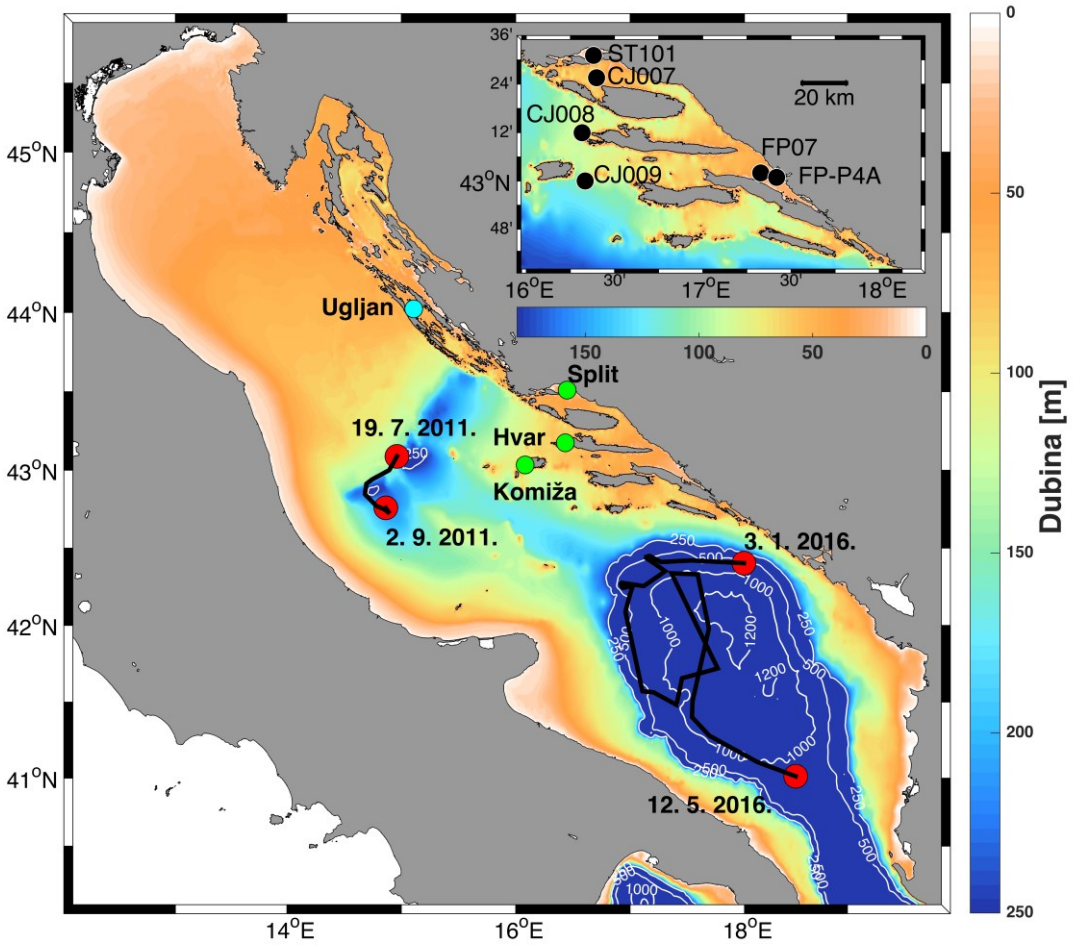

Slika 3. Batimetrija Jadranskog mora s lokacijama fizikalnih mjerenja u 2011. i 2016 godini koja su korištena u doktoratu. Mjerenja iz 2011. godine: površinska temperatura mora na uzgajalištu kod Ugljana (svijetlo plavi krug), površinska temperatura na obalnim postajama Split, Hvar, Komiža (zeleni krugovi) i putanja Argo plovka (crna linija) s početkom 19. srpnja i završetkom 2. rujna 2011. (crveni krugovi). Mjerenja iz 2016. godine: CTD postaje CJ007, CJ008, CJ009, ST101, FP-07 i FP-P4A (crni krugovi na maloj slici u gornjem desnom kutu) i putanja Argo plovka (crna linija) s početkom 3. siječnja i završetkom 12. svibnja 2016. (crveni krugovi).

Podaci o putanji Argo plovka i vertikalni profili temperature i saliniteta izmjereni prilikom izranjanja plovka 1900848 (Arvor Iridium model plovka) u

razdoblju 19. srpnja - 2. rujna 2011. godine (Vilibić i Mihanović, 2013) korišteni su za verifikaciju ROMS modela. Plovak se tijekom navedenog razdoblja nalazio u srednjem dijelu Jadranskog mora na rubu Jabučke kotline (slika 3.). Tlak na kojem je plovak plutao, dok nije vršio profiliranje (parkirna dubina), je iznosio 150 dbar.

U razdoblju od 1. siječnja do 16. svibnja 2016. godine Argo plovak 6901827 se nalazio u području Južnojadranske kotline (slika 3.). Parkirna dubina mu je iznosila 350 dbar. Svakih pet dana Argo plovci su u Jadranu mjerili vertikalne profile temperature, saliniteta i tlaka. Podaci vertikalnih profila skupljeni pomoću Argo plovka su korišteni u proučavanju mehanizma bimodalnog jadransko-jonskog oscilatornog sustava (BiOS) (Gačić i sur., 2014) i analizi pridnene struje duž podine Jadranskog mora (Vilibić i Mihanović, 2013). Podaci Argo plovaka su preuzeti s www.argo.ucsd.edu/Argo_GE.html.

Vrijednosti površinske temperature mora dobivene satelitskim mjerenjem su preuzete s Coperinicus Marine Enviroment Monitoring Service baze podataka (marine.copernicus.eu). Iznosi SST-a su usrednjeni po danu, a potom prostorno interpolirani po cijelom bazenu Jadranskog mora. Prostorna interpolacija je napravljena u institutu CNR (Consiglio Nazionale delle Richerce) za cijelo Sredozemno more reprocesiranjem Pathfinder V5.2 (PFV52) AVHRR podataka u razdoblju od studenog 1981. godine do prosinca 2015. godine (Buongiorno Nardelli i sur., 2013). Prostorna rezolucija novodobivenih podataka je jednaka izvornoj PFV52 rezoluciji od 0.0417°x0.0417° i pritom nema praznina u podacima.

Seabird-25 CTD sonda je korištena za mjerenje temperature i saliniteta na postajama u istočnom dijelu Jadrana (slika 3.). Točnost mjerenja temperature je bila ±0.003°C, saliniteta ±0.002, a ±0.1% za puni raspon mjerenja tlaka (Mihanović i sur., 2015). Vertikalni profili temperature i saliniteta su mjereni na postajama ST101 (16°22'54"N, 43°31'6"E), CJ007 (16°19'0"N, 43°12'0"E), CJ008 (16°20'0"N, 43°0'0"E), CJ009 (17°19'42.6"N, 43°2'0"E) jednom mjesečno u prva četiri mjeseca 2016. godine. Na postajama FP07 (17°19'42.6"N, 43°2'0"E) i FP-P4A (17°25'4.92"N, 43°0'53.28"E) u Malostonskom zaljevu temperatura i salinitet su mjereni samo početkom svibnja 2016. godine.

Iznosi srednjih dnevnih vrijednosti morskih struja u Sredozemnom moru izračunati su reanalizom pomoću Mediteranskog prognostičkog sustava (http://marine.copernicus.eu) za razdoblje od 1987. godine do 2016. godine. Rezultati reanaliza za razdoblje od 1. srpnja do 1. kolovoza 2011. godine preuzeti su također s

Coperinicus Marine Enviroment Monitoring Service baze podataka (Simoncelli i sur., 2011).

2.1.4. Radarska mjerenja

Podaci visokofrekventnih (VF) radara korišteni su za verifikaciju ROMS modela u prvoj polovini 2016. godine za jadransku i ASHELF-2 domenu. VF oceanografski radari (eng. high-frequency radars; HF radars) su uređaji prvenstveno namijenjeni za daljinsko mjerenje površinskih morskih struja. Radari se postavljaju na kopnene lokacije ili fiksne platforme, a odabirom dviju ili više fiksnih lokacija određuje se i područje mjerenja. Na ovaj način je moguće mjeriti površinske morske struje i do 200 km od obale, u ovisnosti o frekvenciji korištenih uređaja.

Princip rada VF radara se temelji na koherentnom povratku raspršenih elektromagnetskih valova emitiranih u svim smjerovima koji rezultira maksimumom energije na točno određenim valnim duljinama. Navedeni princip je poznat i kao Braggova frekvencija raspršenja (Crombie, 1955; Rubio i sur., 2017). Braggovo raspršenje prvog reda događa se na površinskim težinskim valovima u moru. Emitirani elektromagnetski signal se raspršuje na površinskim valovima, čija je valna duljina točno polovica valne duljine emitiranog vala. Dopplerov pomak povratnog signala određuje faznu brzinu valova na kojima se signal raspršuje. Teorijski je utvrđeno da se fazna brzina sastoji od doprinosa morskih struja i površinskih valova u mirnoj vodi. Razlika između izmjerene i teorijske fazne brzine se pripisuje radijalnoj komponenti površinske struje relativno u odnosu na radar. Dakle, jedan radar mjeri radijalnu brzinu struja u odnosu na svoj položaj pa su stoga za određivanje dvodimenzionalnog vektora morske struje potrebne najmanje dvije radarske postaje. Dva VF radara su postavljena u ožujku 2014. godine u istočnom obalnom dijelu Jadranskog mora u okviru projekta HAZADR (http://jadran.izor.hr/hazadr/) - jedan na rt Ražanj na Braču, a drugi na rt Stončica na Visu (slika 4.). Postavljeni VF radari su tipa WERA (Wellen Radar) (Gurgel i sur., 1999), te rade na frekvencijama u rasponu od 25.35 do 26.20 MHz i pokrivaju područje od otprilike 2500 km^2, s prostornom rezolucijom od 1.5 km. U razdoblju između ožujka i svibnja 2014. godine obavljena su testna mjerenja i ugađanje opreme, a od svibnja 2014. godine dostupna su kvalitetna mjerenja, osim u razdobljima kada je oprema bila oštećena ili u kvaru.

Tako je primjerice krajem siječnja 2015. godine došlo do znatnog oštećenja radarskih antena na rtu Ražanj zbog olujne lebićade koja je pogodila to područje. Instrument je popravljen i ponovno je počeo mjeriti u svibnju 2015. godine. U radu su korištena mjerenja iz razdoblja od 1. siječnja do 1. lipnja 2016. godine.

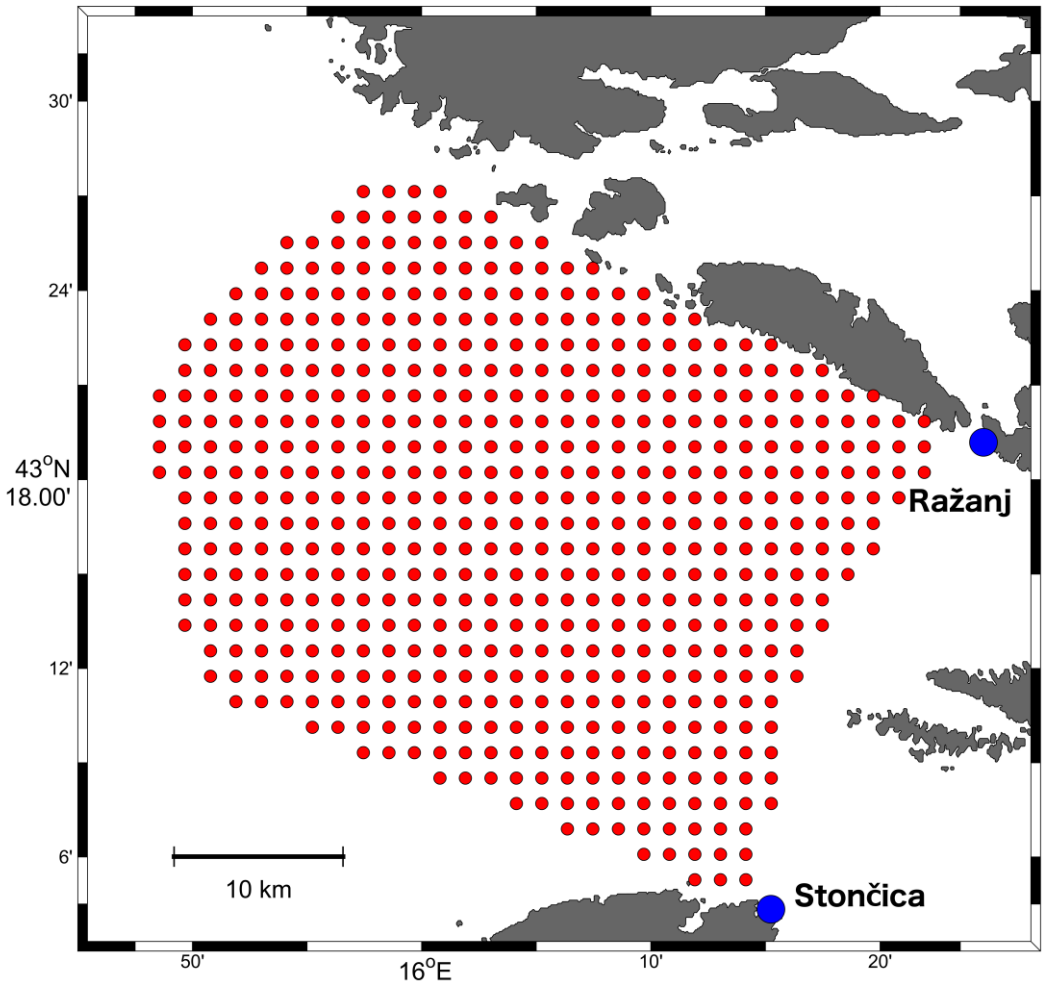

Slika 4. Područje istočne obale Jadranskog mora između otoka Šolte i Visa koje je pokriveno VF radarskim mjerenjima (crveni krugovi). Položaji radara na rtu Stončica na Visu i rtu Ražanj na Braču su označeni plavim krugovima.

Radijalne komponente i pripadajući totalni vektori u Kartezijevom sustavu dobiveni su pomoću standardnog WERA-inog programskog paketa i spremljeni su s vremenskom rezolucijom od pola sata. Tijekom mapiranja vektora isključeni su oni vektori koji su imali veliko geometrijsko smanjenje preciznosti uzrokovano lošom geometrijom presjecanja zraka (Chapman i Graber, 1997). Od ukupno 7248 mogućih polusatnih zapisa u analiziranom intervalu nedostaje njih 545, pri čemu je najduže

razdoblje nedostupnosti od 16. do 26. travnja 2016. godine posljedica problema s radarom na Ražnju. Uz površinske morske struje, VF radari tipa WERA mjere također visinu i smjer valova (http://jadran.izor.hr/hazadr/geoserver_en2.html) te je posredno moguće odrediti i smjer vjetra. Postavljeni radari predstavljaju dio sustava praćenja površinskih struja i valova mora u sjevernom (Tršćanski zaljev) i srednjem (Viški kanal) dijelu Jadranskog mora.

2.2. Oceanografski numerički hidrodinamički model ROMS

2.2.1. Osnovne značajke modela ROMS

Regionalni oceanografski modelski sustav (eng. Regional Oceanographic Modelling System; ROMS) je numerički trodimenzionalni nelinearni hidrodinamički model koji koristi s koordinatni sustav u kojem je gornja ploha slobodna površina mora, a donja koordinatna ploha je morsko dno. Model je nastao unaprijeđivanjem SCRUM (eng. S-Coordinate Rutgers University Model) modela (Song i Haidvogel, 1994), kojeg su Shchepetkin i McWilliams nadogradili, što su opisali u svoja dva rada (Shchepetkin, 2003; Shchepetkin i McWilliams, 2005). ROMS se i dalje razvija zaslugom šire suradnje više autora (Arango, Warner, Hedström i ostali) pri tome uključujući kompenente poput biogeokemijskog modula (Fennel i sur., 2006), modula interakcije s morskim ledom (Budgell, 2005) ili sa sedimentom (Warner i sur., 2008). Model je javno dostupan na http://www.myroms.org i koristi ga veliki broj znanstvenika. Ponajviše se koristi verzija modela sa Sveučilišta Rutgers (Wilkin i sur., 2005). Primjene modela pokrivaju različite prostorne skale: od simulacija dinamike sjeveroistočnog dijela Tihog ocena (Di Lorenzo i sur., 2008), sjeverozapadnog dijela Sredozemnog mora (Renault i sur., 2012) do simulacija dinamike unutrašnjih mora poput Mramornog (Chiggiato i sur., 2012). ROMS je također uspješno primijenjen i u Jadranskom moru, primjerice u simulacijama procesa formiranja guste vode u sjevernom i srednjem dijelu Jadranskog mora (Janeković i sur., 2014; Vilibić i sur., 2016).

Model riješava Reynoldsove jednadžbe uvažavajući hidrostatsku i Boussinesqovu aproksimaciju (Hedström, 2009). Pod hidrostatskom aproksimacijom pretpostavljamo ravnotežu uzgona i vertikalnog gradijenta tlaka, dok su s

Boussinesqovom aproksimacijom promjene gustoće zanemarene u jednadžbama gibanja, osim u slučaju gdje doprinose sili uzgona u vertikalnoj jednadžbi gibanja. Pri rješavanju jednadžbi zasebno se računaju brzi barotropni i spori baroklini modovi. U jednom vremenskom koraku baroklinog moda se rješava određeni broj vremenskih koraka barotropnog moda. U barotropnom modu se računaju denivelacije površine mora i vertikalno usrednjene brzine, a u baroklinom modu trodimenzionalna polja brzine, temperature i saliniteta.

Model se temelji na jednadžbama gibanja:

$$\frac{\partial u}{\partial t} + \vec{v}\,\nabla u - fv = -\frac{\partial \phi}{\partial x} - \frac{\partial}{\partial z}\left(\overline{u'w'} - v\frac{\partial u}{\partial z}\right) + F_u + D_u, \tag{3}$$

$$\frac{\partial v}{\partial t} + \vec{v}\,\nabla u + fu = -\frac{\partial \phi}{\partial y} - \frac{\partial}{\partial z}\left(\overline{v'w'} - v\frac{\partial v}{\partial z}\right) + F_v + D_v, \tag{4}$$

$$\frac{\partial \phi}{\partial z} = -\frac{\rho g}{\rho_0}, \tag{5}$$

na jednadžbi kontinuiteta:

$$\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} + \frac{\partial w}{\partial z} = 0, \tag{6}$$

jednadžbama očuvanja :

$$\frac{\partial C}{\partial t} + \vec{v}\,\nabla C = -\frac{\partial}{\partial z}\left(\overline{C'w'} - v_\theta\frac{\partial C}{\partial z}\right) + F_C + D_C, \tag{7}$$

i jednadžbi stanja:

$$\rho = \rho(T, S, P). \tag{8}$$

Sustav jednadžbi je zatvoren parametriziranjem Reynoldsovih napetosti i turbulentnih protoka skalarnih veličina:

$$\overline{u'w'} = -K_M\frac{\partial u}{\partial z}; \quad \overline{v'w'} = -K_M\frac{\partial v}{\partial z}; \quad \overline{C'w'} = -K_C\frac{\partial C}{\partial z}. \tag{9}$$

Varijable korištene u modelu su skalarne vrijednosti $C(x,y,z,t)$ poput temperature, saliniteta, koncentracije nutrijenata; horizontalni difuzni članovi D_u, D_v, D_C; članovi prisile ili izvora F_u, F_v, F_C; Coriolisov parametar $f(x,y)$; ubrzanje sile teže g; dubina morskog dna ispod srednje razine mora $h(x,y)$; vertikalna udaljenost s slojeva $H_z(x,y,z)$; molekularna viskoznost i difuznost ν, ν_θ; vertikalna turbulentna viskoznost i difuznost K_M, K_C; ukupni tlak P; dinamički tlak $\phi(x,y,z,t)$; ukupna *in situ* gustoća $\rho_0 + \rho(x,y,z,t)$; salinitet $S(x,y,z,t)$; vrijeme t; potencijalna temperatura $T(x,y,z,t)$; u,v,w kao (x,y,z) komponente vektora brzine $\vec{v}$; x,y,z horizontalne i vertikalne koordinate; denivelacija površine mora $\zeta(x,y,t)$.

Transformacije u s koordinatni sustav se odvijaju po sljedećim pravilima:

$$\left(\frac{\partial}{\partial x}\right)_z = \left(\frac{\partial}{\partial x}\right)_\sigma - \left(\frac{1}{H_z}\right)\left(\frac{\partial z}{\partial x}\right)_\sigma \frac{\partial}{\partial \sigma}, \tag{10}$$

$$\left(\frac{\partial}{\partial y}\right)_z = \left(\frac{\partial}{\partial y}\right)_\sigma - \left(\frac{1}{H_z}\right)\left(\frac{\partial z}{\partial y}\right)_\sigma \frac{\partial}{\partial \sigma}, \tag{11}$$

$$\frac{\partial}{\partial z} = \left(\frac{\partial}{\partial z}\right)\frac{\partial}{\partial \sigma} = \frac{1}{H_z}\frac{\partial}{\partial \sigma}, \tag{12}$$

$$H_z \equiv \frac{\partial z}{\partial \sigma}. \tag{13}$$

Nakon transformacije dinamičke jednadžbe prelaze u:

$$\frac{\partial u}{\partial t} - fv + \vec{v}\,\nabla u = -\frac{\partial \phi}{\partial x} - \left(\frac{g\rho}{\rho_0}\right)\frac{\partial z}{\partial x} - g\frac{\partial \zeta}{\partial x} + \frac{1}{H_z}\frac{\partial}{\partial \sigma}\left[\frac{K_m}{H_z}\frac{\partial u}{\partial \sigma}\right] + F_u + D_u, \tag{14}$$

$$\frac{\partial v}{\partial t} + fu + \vec{v}\,\nabla v = -\frac{\partial \phi}{\partial y} - \left(\frac{g\rho}{\rho_0}\right)\frac{\partial z}{\partial y} - g\frac{\partial \zeta}{\partial x} + \frac{1}{H_z}\frac{\partial}{\partial \sigma}\left[\frac{K_m}{H_z}\frac{\partial v}{\partial \sigma}\right] + F_v + D_v, \tag{15}$$

$$\frac{\partial C}{\partial t} + \vec{v}\,\nabla C = \frac{1}{H_z}\frac{\partial}{\partial \sigma}\left[\frac{K_C}{H_z}\frac{\partial C}{\partial \sigma}\right] + F_C + D_C, \tag{16}$$

$$\rho = \rho(T,S,P), \tag{17}$$

$$\frac{\partial \phi}{\partial \sigma} = \left(\frac{-gH_z\rho}{\rho_0}\right), \tag{18}$$

$$\frac{\partial H_z}{\partial t} + \frac{\partial (H_z u)}{\partial x} + \frac{\partial (H_z v)}{\partial y} + \frac{\partial (H_z \Omega)}{\partial \sigma} = 0, \tag{19}$$

gdje su:

$$\vec{v} = (u, v, \Omega)\,, \tag{20}$$

$$\vec{v}\,\nabla = \mathrm{u}\frac{\partial}{\partial x} + \mathrm{v}\frac{\partial}{\partial y} + \mathrm{w}\frac{\partial}{\partial z}\,, \tag{21}$$

dok je vertikalna brzina:

$$\Omega(x, y, \sigma, t) = \frac{1}{H_z}\left[w - \left(\frac{z+h}{\zeta+h}\right)\frac{\partial \zeta}{\partial t} - u\frac{\partial z}{\partial x} - v\frac{\partial z}{\partial y}\right], \tag{22}$$

$$w = \frac{\partial z}{\partial t} + \mathrm{u}\frac{\partial z}{\partial x} + \mathrm{v}\frac{\partial z}{\partial y} + \Omega H_z\,. \tag{23}$$

Jednadžbe modela se rješavaju u C mreži prema Arakawi (slika 5.), pri čemu su primijenjene tradicionalne, centralne konačne razlike drugog reda. Konačne razlike drugog reda se također koriste i u vertikalnoj diskretizaciji. Vertikalna mreža je prikazana na slici 6. Dvodimenzionalne i trodimenzionalne jednadžbe modela su diskretizirane kombinacijom centralne i Adams-Moltonove sheme trećeg reda točnosti što omogućava visoku stabilnost i samim time korištenje dužih vremenskih koraka. Diskretizacija po vertikali primitivnih jednadžbi je napravljena korištenjem s-koordinate koja prati batimetriju. Zbog toga je moguće povećati vertikalnu rezoluciju u ciljanim slojevima poput pridnenog sloja ili sloja termokline. Obalna linija je definirana maskom "kopno-more" u diskretnoj mreži. U horizontalnom smjeru jednadžbe modela rješavaju se korištenjem ortogonalnih krivolinijskih koordinata na već spomenutoj C mreži prema Arakawi. Moguće je korištenje i Kartezijevih i sfernih koordinata. Za procese na skalama manjim od prostornog koraka mreže primjenjuje se nekoliko vrsta parametrizacija. Horizontalno miješanje skalarnih veličina i impulsa može se odvijati na tri načina: duž s-nivoa, geopotencijalnih ploha te ploha konstantne

gustoće. Vertikalno miješanje može biti parametrizirano lokalnim i nelokalnim shemama zatvaranja. Nelokalne sheme su zasnovane na formulaciji graničnog sloja korištenjem K-profila (Large i sur., 1994), a lokalne sheme se zasnivaju na ”level 2.5” jednadžbama za turbulentu kinetičku energiju (Mellor i Yamada, 1982) i ”Generic Length Scale (GLS)” parametrizaciji (Umlauf and Burchard, 2003). GLS je model turbulentnog zatvaranja i omogućuje korištenje niza shema: k-kl, k-e i k-w. GLS model je korišten i u ovom radu. Interakcija na granici atmosfera-more parametrizirana je prema COARE (Coupled Ocean-Atmosphere Response Experiment) algoritmu kojim se mogu izračunavati protoci impulsa, topline i vlage (Fairall i sur., 1996). Navedena parametrizacija se koristi u jednosmjernom i dvosmjernom združivanju atmosferskih i oceanskih modela. Kod ROMS modela je pisan u Fortranu 90 i Fortranu 95, i koristi C pretprocesiranje za uključivanje odnosno isključivanje različitih numeričkih i fizikalnih opcija.

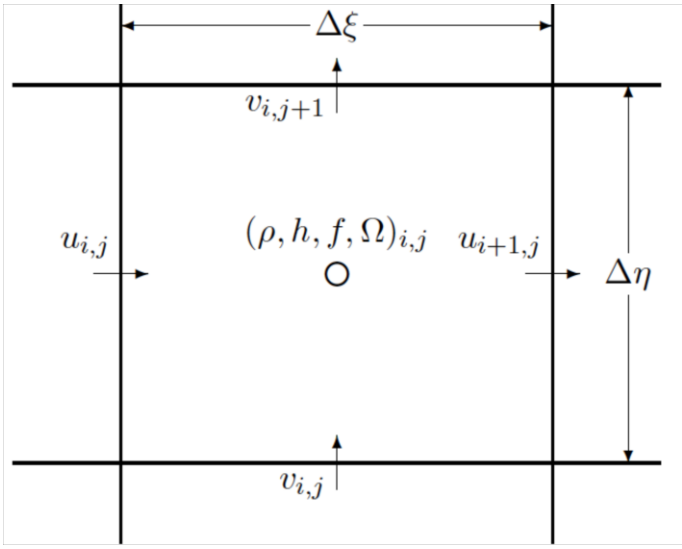

Slika 5. Položaj varijabli u horizontalnoj ravnini u razmaknutoj Arakawinoj C mreži (Hedström, 2009).

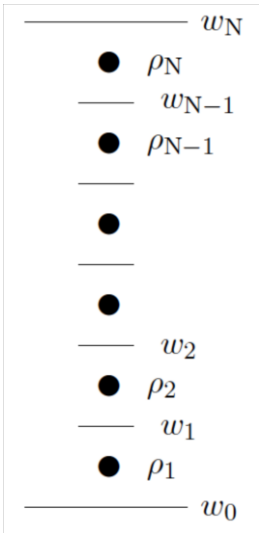

Slika 6. Položaj varijabli u vertikalnom smjeru u razmaknutoj Arakawinoj C mreži (Hedström, 2009).

2.2.2. Opis konfiguracije modela ROMS

Prostorna domena ROMS modela obuhvaća cijelo Jadransko more s pravokutnom horizontalnom mrežom rezolucije 2.5 km i 22 nejednako razmaknuta s-nivoa duž vertikale (slika 7.a). Horizontalna mreža se sastoji od 320x108 točaka. Batimetrija modela je zasnovana na polju dubina prostorne rezolucije od 7.5 sekundi dobivenom tijekom projekta DART (eng. Dynamics of the Adriatic in Real-Time) i interpoliranom korištenjem metode inverzne težinske udaljenosti (Rixen i sur., 2006). DART batimetrija visoke rezolucije je usrednjena na ROMS mrežu i potom zaglađena metodom prema Dutour Sikiriću i sur. (2009).

Površinski protoci impulsa, topline i vlage su izračunti korištenjem prizemnih atmosferskih polja operativnog modela ALADIN (Tudor i sur., 2013). Skalarna polja modela ALADIN korištena u proračunima protoka (tlak zraka, temperatura zraka, relativna vlažnost, naoblaka, oborina i kratkovalno zračenje) imaju prostornu rezoluciju od 8 km, dok polje vjetra ima rezoluciju od 2 km koja je dobivena dinamičkom adaptacijom s 8 km. Polja ALADIN-a s vremenskom rezolucijom od 3 sata su bilinearno interpolirana u mrežu jadranskog modela i napravljeni su proračuni površinskih protoka u jednosmjernom uparivanju modela ALADIN i ROMS. Osim atmosferskim poljima, ROMS model je forsiran i protocima rijeka. Duž obale Jadranskog mora korišteni su klimatološki protoci 41 rijeke (Raicich, 1994). Plimno

forsiranje je nametnuto na otvorenu južnu granicu uzimajući u obzir sedam plimnih harmonika bitnih za plimnu dinamiku u Jadranskom moru (M2, S2, N2, K2, K1, O1 i P1). Iz šireg jadranskog modela AREG koji je dio operativnog Jadranskog prognostičkog sustava (Adriatic Forecasting System – AFS (Oddo i sur., 2006)) su preuzeti rubni uvjeti na otvorenoj granici za slobodnu površinu mora, temperaturu, salinitet i brzinu. Za barotropni dio korištena je shema prema Flatheru (Flather, 1976). Za barokline brzine te salinitet i temperaturu korištena je kombinacija radijacijskih rubnih uvjeta prema Orlanskom s metodom prisilnog približavanja vrijednosti navedenih varijabli ka vrijednostima AREG modela s ciljem smanjenja iznosa greške – nudging (Marchesiello i sur., 2001).

Ugniježđena domena obuhvaća istočni obalni prostor srednjeg dijela Jadranskog mora (slika 7.b) s prostornom rezolucijom od 1 km na pravokutnoj mreži, koja se sastoji od 189x106 elemenata. Navedena domena je korištena u ugniježđenom modeliranju cirkulacije istočnog Jadrana pomoću POM modela u sklopu ADRICOSM projekta (Orlić i sur., 2006a). Za potrebe ADRICOSM projekta batimetrija područja u blizini obale i između otoka je izvedena iz nautičke mape korištenjem triangularne linearne interpolacije (Renka, 1984), a vanjsko područje je dobiveno bilinearnom interpolacijom iz standardnog seta podataka s prostornom rezulucijom od 1 min (DBDB-1). Pored atmosferskog forsiranja, koje je identično onome za jadransku domenu, u ASHELF-2 domeni su korišteni klimatološki protoci četiri rijeke: Jadro, Žrnovnica, Cetina i Neretva, te plimno forsiranje. Na otvorene granice ASHELF-2 domene nametnuta su srednja dnevna polja denivelacije, temperature i saliniteta.

Simulacije ROMS modelom za tunu su počele 1. siječnja 2011. godine i trajale su do 2. rujna 2011. godine, iako su rezultati simulacije korišteni tek od 15. srpnja. Početna polja za salinitet i temperaturu su bila homogena, dok je strujno polje inicirano stanjem mirovanja. Odabir dužeg razdoblja trajanja ROMS simulacija je imao za cilj omogućiti proračun realističnijih fizikalnih polja, smanjiti utjecaj umjetnih početnih uvjeta i povezanih generiranja nepoželjnih valova. S ciljem daljnjeg smanjenja nepoželjnih oscilacija, iznosi forsiranja postepeno su povećani od nule ka maksimalnom iznosu tijekom prvog dana simulacije.

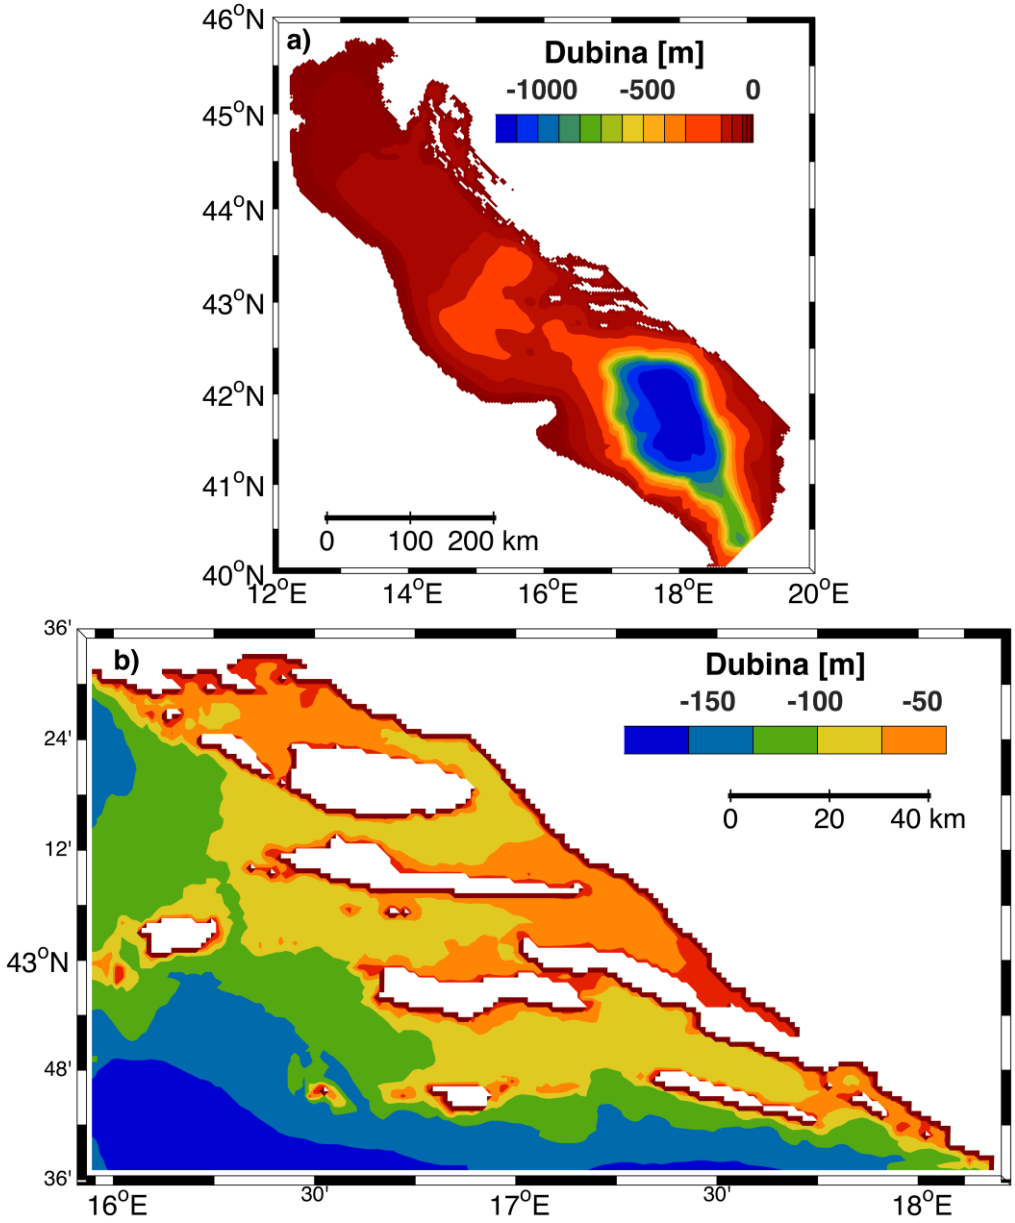

Slika 7. Prostorna domena s batimetrijom Jadranskog modela (a) i prostorna domena s batimetrijom ASHELF-2 modela (b).

Simulacije ROMS modelom na domeni Jadranskog mora za komarču su počele 1. kolovoza 2015. godine i trajale su do 1. lipnja 2016. godine, iako su rezultati simulacije korišteni od 1. siječnja do 15. svibnja 2016. godine. Polja strujanja su inicijalizirana stanjem mirovanja, a početna polja temperature i saliniteta su bila horizontalno homogena, dok im je vertikalna varijabilnost zadana prema klimatološkim vrijednostima za ljetnu sezonu (Artegiani i sur., 1997a). Za simulacije

vezane uz komarču pokrenut je i ROMS model na ASHELF-2 domeni. Na otvorenim granicama ASHELF-2 domene nametnute su vrijednosti iz jadranskog modela.

2.3. Individualno temeljeni model Ichthyop

Lagrangeovski disperzijski individualno temeljeni model Ichthyop v.3.3.a (eng. individual-based model; IBM) (Lett i sur., 2008) je alat koji korištenjem fizikalnih (temperatura, salinitet, morske struje) i bioloških parametara (gustoća jaja, dnevna vertikalna migracija, plivanje, rast larvi, smrtnost uvjetovana temperaturom) daje procjenu o dinamici ihtioplanktona. Ichthyop je besplatan i javno dostupan alat (http://www.ichthyop.org/downloads) koji omogućuje široku primjenu u simulacijima disperzijskih procesa na različitim vremenskim i prostornim skalama. Korišten je u istraživanju transporta invanzivnih vrsta iz Atlantskog oceana u Sredozemno more (Prieto i sur., 2015), utjecaja mezoskalnih procesa i sezonske varijabilnosti na distribuciju larvi u oceanu (Carolina Parada i sur., 2012), analizi povezanosti morskih rezervata s okolnim područjem (Andrello i sur., 2017), te procjeni glavnih hidrodinamičkih procesa vezanih uz transport ihtioplanktona tijekom višegodišnjeg razdoblja (Nicolle i sur., 2009). Ichthyop model je primijenjen i u Jadranskom moru u analizi povezanosti različitih dijelova bazena (Bray i sur., 2017; Vodopivec i sur., 2017; Bernardi i sur., 2018). IBM uključuje jedinke i njihovu fizikalnu okolinu. Jedinke su karakterizirane sljedećim varijablama stanja: dob [dan], duljina [mm], razvojna faza (jaje, larva s žumančanom vrećicom ili larva sa sposobnošću samostalnog hranjenja), položaj (geografska dužina [°E], geografska širina [°N] i dubina [m]) i status (živa ili mrtva). Fizikalne varijable okoliša su dobivene iz oceanografskog numeričkog modela ROMS: polja temperature, saliniteta i morskih struja. Vrijednosti navedenih polja su prostorno interpolirana za svaki položaj čestice u IBM-u. Polja su također interpolirana u vremenu za svaki vremenski korak u IBM-u pri čemu se mora zadovoljiti Courant-Friedrichs-Lewyev uvjet. Procesi na skali manjoj od rezolucije ROMS modela su parametrizirani. Simulacije IBM-om omogućavaju praćenja položaja i svojstava jedinki kroz neko zadano razdoblje. Gibanje unutar modela je simulirano sljedećim procesima: horizontalna advekcija, vertikalna advekcija, horizontalna disperzija, vertikalna disperzija, uzgon jaja, vertikalna migracija larvi te aktivno plivanje. Vertikalna migracija je promjena

položaja u vodenom stupcu zavisno o dobu dana. Komponenta uzgona se pribraja vertikalnoj brzini pri čemu uzgon ovisi o razlici između gustoće jaja i gustoće morske vode (Parada i sur., 2003). Gustoća jaja je proizvoljno zadana, dok je gustoća morske vode funkcija temperature i saliniteta. Shema uzgona u Paradi (2003) je zasnovana na jednadžbama koje je dao Denny (1993) u kojima je vertikalna brzina jaja izračunata izjedanačavanjem sile potrebne za pokretanje sferoida koji se giba paralelno velikoj poluosi s težinom tog izduženog sferoida. Vertikalna brzina čestica ograničena je Stokesovim tokom u kojem je Reynoldsov broj manji od 0.5, što govori da viskoznost dominira nad trenjem. Pretpostavka je napravljena tako da je vertikalno opterećenje čestice u ravnoteži sa silama uzgona, što rezultira time da je vertikalna brzina w_{part} funkcija ubrzanja sile teže g, gustoće morske vode ρ_w, kinematičke viskoznosti υ (0.01 m^2s^{-1}), male d i velike poluosi l izduženog sferoida gustoće čestice ρ_{part}:

$$w_{part} = w_{water} + \frac{1}{24} g d^2 \, \frac{\Delta\rho}{\rho_w} \, \nu^{-1} ln\left(\frac{2l}{d} + \frac{1}{2}\right), \tag{24}$$

gdje je $\Delta\rho = \rho_{part} - \rho_w$, a w_{water} je vertikalna brzina $\frac{dz}{dt}$ (gdje je z dubina a t vrijeme) iz hidrodinamičkog modela Plume (Penven i sur., 2001).

Horizontalna disperzija uvedena je prema (Peliz i sur., 2007). Izračun brzine plutanja u_f iz Pelizovog rada temelji se na:

$$u_f(x, y, z) = U_a(x, y, z) + u_r(x, y) + w_d(z) + w_r(z), \tag{25}$$

gdje je U_a trodimenzionalni vektor brzine iz eulerovskog modela, u_r je slučajna komponenta horizontalne komponente vektora brzine:

$$u_r = \delta \sqrt{\frac{2K_h}{\Delta t}}, \tag{26}$$

pri čemu je δ slučajni broj u intervalu $[-1, 1]$, K_h je zadana eksplicitna lagrangovska horizontalna difuzija oblika:

$$K_h = \epsilon^{\frac{1}{3}} l^{\frac{4}{3}}, \tag{27}$$

gdje je l skala manja od rezolucije modela, a $\epsilon = 10^{-9}\ \frac{m^2}{s^3}$ je iznos turbulentne disipacije (Monin i Ozmidov, 1981). U Ichthyop modelu skala l je jednaka horizontalnoj rezoluciji hidrodinamičkog modela. Iznos turbulentne disipacije se slaže s mjerenjima turbulentne kinetičke energije u Jadranskom moru (Falcieri i sur., 2016; Carniel i sur., 2012). Peliz i sur. (2007) su prikazali način zadavanja w_d , deterministčkog vertikalnog gibanja, gdje je unprijed zadana dubina zavisna o dobu dana, to jest satu t_h:

$$w_d = \begin{cases} -30\ \left[\frac{m}{h}\right]\ ako\ 4 < t_h < 6 \\ 30\ \left[\frac{m}{h}\right]\ \ ako\ 22 < t_h < 24 \\ 0\ \left[\frac{m}{h}\right]\ \ inače \end{cases} \tag{28}$$

U Ichthyopu vertikalna migracija je zadana tako da čestica provodi dan odnosno noć na dubinama koje su zadane u okviru simulacije. Vertikalna slučajna fluktuacija w_r je povezana s vertikalnim turbulentnim tokovima na maloj skali. U radu Peliz i sur. (2007) zadana je prema Rossu i Sharplesu (2004):

$$w_r = \delta \sqrt{\frac{2K}{\frac{1}{3}\Delta t} + K_z}, \tag{29}$$

gdje je K je vertikalna toplinska turbulentna difuznost preuzeta iz KPP modela turbulentnog zatvaranja, a K_z je njegova vertikalna derivacija. U Ichthyop modelu slučajni pomak je ugrađen u vertikalnu disperziju (Visser, 1997), korištenjem kubične spline interpolacije polja vertikalne difuzije učitanih iz polja varijabli okoliša. Vremenska integracija se računa korištenjem Eulerove sheme unaprijed ili Runge-Kutta metode četvrtog reda. Brzina aktivnog plivanja iznosi jednu, dvije ili četiri duljine tijela po sekundi. Duljina tijela je linearna funkcija dobi jedinke (Mariani i sur., 2010; Reglero i sur., 2015). Smjer plivanja je u svakom vremenskom koraku slučajno odabran. Dva su odabira vezana uz brzinu plivanja: konstantna ili slučajno odabrana brzina. Konstantna brzina implicira da čestice plivaju zadanim iznosom brzine koja je funkcija dobi, dok slučajno odabrana brzina implicira da čestice plivaju brzinom čiji je iznos slučajno odabran unutar raspona od nule do iznosa brzine koji je

zadan funkcijom dobi. Ponuđene su tri mogućnosti parametrizacije ponašanja čestica prigodom nailaska na obalnu liniju: naplavljivanje na plažu, odbijanje od obalne linije i zadržavanje čestica uz obalnu liniju. Unutar svakog diskretnog vremenskog koraka svaka individua se giba, raste ili je testirana na smrtnost ili novačenje. Početna raspodjela čestica je slučajno odabrana unutar zadanog područja.

2.4. Ljapunovljev eksponent konačnog vremena

2.4.1. Teorijski uvod

Procesi transporta su bitni u mnogim prirodnim fenomenima. Kao jedan od važnijih primjera u geofizici je i transport čestica morskim strujama. Poznavanje cirkulacije je važno kod proučavanja advekcije fitoplanktona i larvi obalnim strujama, te rješavanja problema pri ispuštanju polutanata u slučaju pomorskih nesreća ili nekontroliranih izljeva. Za kvalitetno istraživanje navedenih procesa lagrangeovski pristup se pokazao prikladnim. U njemu je putanja čestice $\boldsymbol{x}(t)$ advektirana eulerovskim poljem brzina $\boldsymbol{u}(x,t)$ što možemo prikazati diferencijalnom jednadžbom:

$$\frac{\boldsymbol{dx}}{dt} = \boldsymbol{u}(\boldsymbol{x},t) = \boldsymbol{v}(t), \tag{30}$$

gdje je $\boldsymbol{v}(t)$ lagrangeovska brzina (Haza i sur., 2010). Povezivanje eulerovskog i lagrangeovskog sustava, unatoč jednostavnom obliku jednadžbe koja ih spaja (30), zahtjevan je oceanografski problem. Sam proces mjerenja eulerovskog polja brzina $\boldsymbol{u}(x,t)$ vezan je uz velike iznose nepouzdanosti. Navedeno je posljedica velikog raspona skala gibanja u oceanu, što u formalnom zapisu možemo kvantificirati velikim iznosom Reynoldsovog broja. Uzimajući iznos od $U \cong 10^{-1}\ m/s$ za tipičnu brzinu u obalnom moru, skalu duljine $L \cong 10^{3}\ m$ te kinematičku viskoznost $\nu = 10^{-6}\ m^2 s^{-1}$, Reynoldsov broj za obalno more iznosi $Re = \frac{UL}{\nu} \cong 10^{8}$. Zbog toga, čak i s jednostavnim eulerovskim poljem brzina, možemo generirati neograničeni broj lagrangeovskih putanja koje je teško razlikovati od onih koje su dobivene u kompleksnom turbulentnom toku. Iz područja nelinearne dinamike uvodi se lagrangeovski opis fenomena transporta. Prognoza putanje pojedine čestice prestaje

biti cilj. Glavni fokus postaje lociranje dinamičkih prostornih struktura za koje je utvrđeno u teoriji dinamičkih sustava da mogu poslužiti kao predlošci za tok (d'Ovidio i sur., 2004). U kontekstu dinamike fluida, koherentne strukture (atraktori, mnogostrukosti,...) poprimaju fizikalno značenje, poput putanja ili barijera u transportu, rubova u vrtlogu ili linija jakog razdvajanja gdje se trajektorije dviju bliskih čestica brzo raziđu. Detekcija struktura je težak zadatak u poljima brzina karakteriziranim velikim iznosom Reynoldsovog broja. Koherentne strukture poput mlazova ili vrtloga ne nastaju samo kao posljedica kvazistacionarne termohaline dinamike, već su i pod utjecajem tranzijentnih prisila poput vjetra ili dotoka slatke vode. Navedeno odgovara karakteristikama dinamike Jadranskog mora gdje imamo jake kvazistacionarne struje po rubovima bazena i vrtloge u središnjim dijelovima bazena, ali i sezonski zavisne utjecaje vjetra i riječnih protoka (Haza i sur., 2010).

Lagrangeovske koherentne strukture možemo nazvati skrivenim kosturom koji organizira transport u fluidima (Peacock i Haller, 2013). Postoje dva tipa struktura, privlačni koji se mogu izračunati klasičnom vremenskom integracijom trajektorija i odbojni koji se dobivaju integracijom unazad u vremenu. Jedan od najjednostavnijih primjera lagrangeovskog transporta je hiperbolična sedlena točka čija je shema prikazana na slici 8. (Morel i sur., 2014). Česti fluida koje prilaze hiperboličnoj sedlenoj točki putem odbojne transportne barijere (naziva se također i stabilnom mnogostrukosti) bivaju advektirane od točke i to putem materijalne linije koja je zapravo privlačna transportna barijera (naziva se i nestabilnom mnogostrukosti).

U slučaju obrata vremenske osi odbojna barijera postaje privlačnom, odnosno privlačna odbojnom. U blizini sedlene točke, nestabilne mnogostrukosti organiziraju tok, privlačeći sve susjedne elemente fluida i potom ih prilagođavajući svom obliku. Navedene strukture dijele dinamička oceanska svojstva u područja s različitim asimptotskim ponašanjima. Primjerice, grupa čestica koja se ne nalazi na barijerima, odnosno biva zarobljena između mnogostrukosti, će imati tendenciju ostati unutar njih, dok će grupa čestica na odbojnoj barijeri imati tendenciju odmicati se. Nakon nekog vremena disperzija druge grupe će biti daleko veća od prve. Ovo svojstvo se može iskoristiti u procjeni pouzdanosti trajektorija čestica.

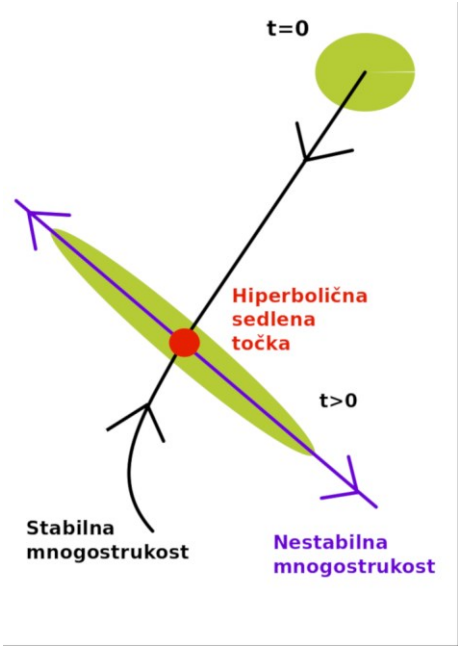

Slika 8. Ilustracija gibanja oko hiperbolične točke (Morel i sur., 2014)

Transportne barijere se proučavaju kvantifikacijskim metodama vezanim uz privlačna ili odbojna svojstva trajektorija. Postoje dvije vrste metoda koje se naslanjaju na Ljapunovljev eksponent (Goldhirsch i sur., 1987), indikator kaotičnosti sustava, koji kvantificira koliko se brzo dvije infinitezimalno bliske putanje razdvajaju jedna od druge (Hernández-Carrasco i sur., 2011). Prva je Ljapunovljev eksponent konačnog vremena (eng. finite-time Lyapunov exponent; FTLE), dok je druga Ljapunovljev eksponent konačne veličine (eng. finite-size Lyapunov exponent; FSLE). U oceanografiji je FSLE metoda bila češće korištena u analizama miješanja i transporta u oceanima (d'Ovidio i sur., 2004), ali se i FTLE metoda pokazala jednako kvalitetnom za navedene analize. Navedeno je pokazano korištenjem FTLE metode u istraživanju transportnih barijera u Zaljevu Monterey, s ciljem određivanja najpovoljnijeg vremena ispusta zagađivača (Coulliette i sur., 2007).

U prisustvu lagrangeovskog kaosa (kaotične advekcije), razmak između dviju bliskih trajektorija se eksponencijalno povećava u vremenu. Zbog toga je relativna disperzijska statistika prirodan odabir statistike za opis kaotičnog širenja čestica (Boffetta i sur., 2001). Relativno razdvajanje između dvije čestice $\boldsymbol{R}(t) = \boldsymbol{x}'(t) - \boldsymbol{x}(t)$ ovisi o razlikama njihovih brzina:

$$\frac{d\boldsymbol{R}}{dt} = \boldsymbol{u}(\boldsymbol{x}(t) + \boldsymbol{R}(t), t) - \boldsymbol{u}(\boldsymbol{x}(t), t). \tag{30}$$

Sve dok je razdvajanje čestica puno manje od tipične skale duljine L polja brzina, moguće je linearizirati jednadžbu (31) duž trajektorije x:

$$\frac{\boldsymbol{dR}}{dt} = \boldsymbol{u}(\boldsymbol{x}(t), t) + \lambda \boldsymbol{R}(t) - \boldsymbol{u}(\boldsymbol{x}(t), t), \tag{32}$$

odakle slijedi:

$$\frac{\boldsymbol{dR}}{dt} = \lambda \boldsymbol{R}(t). \tag{33}$$

Pri rješavanju diferencijalne jednažbe (33) očekujemo eksponencijalni rast razdvajanja između čestica $\boldsymbol{R}$: $R(t) \cong R(0)e^{\lambda t}$, gdje je λ Ljapunovljev eksponent zadan kao:

$$\lambda = \lim_{t\to\infty} \lim_{R(0)\to 0} \frac{1}{t} \ln \frac{R(t)}{R(0)}. \tag{34}$$

Definicija Ljapunovljevog eksponenta je ispravna samo u slučaju da linearizacija razdvajanja $\boldsymbol{R}(t)$ vrijedi za beskonačno vrijeme i ako je razdvajanje infinitezimalno u svakom trenutku. U realističnim situacijama gdje je $\boldsymbol{R}(t)$ jako malen, odnosno gdje je $\boldsymbol{R}(t)$ jako velik, asimptotski režimi se ne mogu izračunati. Razlog za prvo ograničenje je taj što prostorna rezolucija polja brzina zadaje donju granicu za početne iznose udaljenosti čestica, ispod kojih ne možemo ići. Razlog za drugo ograničenje je gornja granica zadana tipičnom skalom duljine L polja brzina koja je uvjetovana domenom. Zbog toga se dinamička svojstva opisuju neasimptotskom karakterizacijom transporta.

Zanemarivanjem limesa kad $t \to \infty$ dobivamo FTLE. Time dobivamo trenutni iznos povećanja razdvajanja na konačnom intervalu $t = \tau$ pri čemu je τ manji od vremenske skale sustava T

$$\lambda_\tau(t, \boldsymbol{x}) = \lim_{R(t)\to 0} \frac{1}{\tau} \ln \frac{R(t+\tau)}{R(t)} \tag{31}$$

Zanemarivanjem limesa kad $R(0) \to 0$ dobivamo FSLE. Na taj način inicijaliziramo čestice s početnim iznosom razdvajanja δ_i i dobivamo relaciju:

$$\lambda_\tau(\delta_i, \boldsymbol{x_i}) = \frac{1}{\tau(\delta_i, \boldsymbol{x_i}, r)} \ln r, \tag{32}$$

gdje je $r = \frac{\delta_f}{\delta_i}$ amplifikacija razdvajanja dobivena stavljanjem u omjer konačnog δ_f i početnog razdvajanja δ_i. Odabirom konačnog razdvajanja δ_f utječemo na vrijeme potrebno da par čestica zadovolji taj uvjet.

Rezultati koji se mogu dobiti upotrebom FSLE i FTLE metode uz određenu kalibraciju parametara r i T su visoko korelirani (Peikert i sur., 2014), no postoji konceptualna razlika između dvije metode. FSLE nam omogućava, odabirom parametra r, fokusiranje na lokalna razdvajanja iznad određene granice, pri čemu možemo dobiti i dodatnu informaciju vezanu uz karakterističnu vremensku skalu opaženog transporta, a samim time i miješanja. FTLE nam pak omogućava odabirom konačnog intervala τ prepoznavanje razdvajanja na svim prostornim skalama. Time dobivamo uzajamnu interakciju detektiranih struktura (Wiggins, 2005). Korištenjem FSLE kao i FTLE metode možemo uhvatiti efekte većih skala na skalama manjim od prostorne rezolucije eulerovskog polja brzina (Hernández-Carrasco i sur., 2011), ukoliko je mreža na kojoj se računaju LCS manja od mreže eulerovskog polja. No to ne znači da smo rekonstruirali efekte koji se odvijaju na malim skalama, već smo samo uhvatili efekte koji potječu od velikih struktura koje se mogu izračunati na rezoluciji eulerovskog polja brzina.

Zbog mogućnosti prepoznavanja razdvajanja na svim skalama i mogućnosti procjene uzajamne interakcije opaženih struktura odabrana je FTLE metoda za LCS detekciju u radu. Mogućnost prepoznavanja na svim skalama ima dodatnu težinu ako uzmemo u obzir raznovrsnost prostornih domena na kojima su istraživanja rađena i potrebe za metodom koja će se s minimalnim prilagodbama moći primijeniti na sve tri domene. Raspon domena na kojima je primijenjena FTLE metoda kreće se od lokalnog područja između otoka Šolte i Visa pokrivenog radarskim mjerenjem površinskih struja (slika 4.), istočnog obalnog prostora srednjeg dijela Jadranskog mora korištenog u simulacijama ugnježđenog modela do cijelog Jadranskog mora (slika 6.). Različite skale domena uvjetuju različite LCS-ove i njihovu međusobnu interakciju, počevši od struktura nastalih pod utjecajem velikih kvazistacionarnih vrtloga na prostornim dimenzijama Jadranskog mora pa do struktura koje su posljedica lokalnih karakteristika vjetra.

Za FTLE metodu je potvrđeno i analitički i eksperimentalno da ako su grebeni u FTLE polju oštri tad je tok preko njih zanemariv (Shadden i sur., 2005). Također, hiperboličke materijalne krivulje dobivene FTLE metodom će biti neosjetljive na pogrešku u mjerenim ili modeliranim poljima brzina ukoliko su iznimno privlačne ili odbojne ili postoje duže vrijeme (Harrison i Glatzmaier, 2012). Robustnost vrijedi čak i kad su pogreške po iznosu velike, a po vremenu trajanja kratke (Haller, 2002).

Visoke FTLE vrijednosti koje se pojavljuju kao grebenovi u skalarnom polju otkrivaju i granice između vodenih masa s dinamički različitim LCS-ovima. Možemo reći da LCS-ovi mogu mapirati dugotrajne fronte koje razdvajaju vodene mase s različitim svojstvima temperature, saliniteta, kisika. Dok pojava fronte u temperaturnom i polju gustoće ukazuje na transportnu barijeru, obrnuto ne vrijedi, jer LCS-ovi mogu ukazivati na transportne barijere koje su nevezane s frontama. Ali za tokove u oceanu u skoro geostrofičkoj ravnoteži, LCS-ovi i fronte će se podudarati (Harrison i sur., 2013). LCS-ovi su često i barijere u transportu planktona, larvi i drugih pasivnih čestica (Mitarai i sur., 2008; Siegel i sur., 2008), a mogu ukazivati i na mezoskalne konvergentne zone s velikim potencijalom nakupljanja zooplanktona (Maps i sur., 2015).

Izračuni FTLE vrijednosti u ovom radu su napravljeni u programskom okružju Matlab pomoću OceanFTLE paketa koji je napisao Denis L. Volkov. OceanFTLE paket je primijenjen u istraživanju utjecaja meteoroloških uvjeta i morskih struja na transport i naplavljivanje plutajućeg morskog otpada u sjeverozapadnom Sredozemnom moru na području Azurne obale (Ourmieres i sur., 2018).

Primjena FTLE metode zahtijeva početno podešavanje kombinacije parametara koji utječu na evoluciju trajektorija: početnog razmaka δ_i i ukupnog vremena proračuna T. Navedeno proizlazi iz prethodno napisanog objašnjenja da su FTLE zapravo skalari koji predstavljaju maksimalni iznos razdvajanja dva para čestica, početno razmaknutih δ_i i potom advektiranih u ukupnom vremenu proračuna T. Prigodom odabira spomenutih parametara δ_i i T moramo uzeti u obzir da njihov odabir ovisi o skali struktura koje analiziramo i njihovoj prostornoj varijabilnosti. Početna udaljenost δ_i mora biti manja od rezolucije polja brzina jer se nastoji zadovoljiti početni uvjet infinitezimalne udaljenosti između čestica.

Interval integracije T mora zadovoljiti sljedeća svojstva: mora biti dovoljno dug da FTLE grebenovi postanu jasno definirani i njegova vrijednost mora odgovarati

vremenskoj skali mezoskalnih procesa. Dobra procjena vrijednosti T je vrijeme koje je potrebno čestici da s jednog kraja domene dođe na drugi. U našem slučaju za FTLE proračune na domeni cijelog Jadranskog mora uz prosječnu brzinu toka 0.15 m/s dobivenu usrednjavanjem modelirane brzine i udaljenost od 750 km na osi Otrantska vrata – Venecija, vrijeme T iznosi 70 dana, što odgovara prosječnom vremenu koje provede površinska čestica u bazenu Jadranskog mora pod utjecajem mezoskalnih procesa (Falco i sur., 2000). Za FTLE proračune na domeni koja obuhvaća istočni obalni prostor srednjeg dijela Jadranskog mora T iznosi 16 dana što je vrijeme potrebno čestici da prijeđe 210 km (duljina duž osi sjeverozapad – jugoistok navedene domene) također prosječnom brzinom od 0.15 m/s, dok za domenu koja obuhvaća radarska mjerenja s prosječnom brzinom od 0.18 m/s potreban je T u iznosu od 3 dana da čestica prijeđe 35 km koliko iznosi duljina osi sjever – jug. Prosječne površinske brzine su izračunate prostorno-vremenskim usrednjavanjem po cijelom modeliranom bazenu odnosno području radarskog mjerenja, dok je vremenski period odgovarao vremenu trajanja disperzijskih simulacija. Što je iznos T veći detektirani LCS-ovi će biti finiji, ali će se i računalno vrijeme povećati. No što je δ_i manji, to će detektirani LCS-ovi biti finiji, jer će broj točaka FTLE mreže porasti, ali će se računalno vrijeme također smanjiti. Prostorne rezolucije od 2.5 km modela za cijelo Jadransko more, od 1 km modela za obalno područje istočnog Jadranskog mora te 1.5 km za radarsko polje su manje od unutarnjeg Rossbyjevog polumjera deformacije koji iznosi 3-5 km u sjevernom i srednjem Jadranskom moru (Bergamasco, 1996).

OceanFTLE paket nudi dvije mogućnosti algoritma integracije, jednu koja koristi bržu Euler metodu, te sporiju ali točniju Runge-Kutta metodu četvrtog reda. Integraciju je moguće napraviti na dva načina: klasično unaprijed u vremenu i unazad, pri čemu za klasični odabir program računa poziciju na koju će čestica biti advektirana za vrijeme vremenskog koraka, dok za drugi slučaj program računa poziciju s koje je čestica advektirana duž vremenskog koraka. Integracijom unazad proračunavaju se konvergentna područja koja se pojavljuju kao grebeni visoke FTLE vrijednosti, i koje nam govore da su čestice koje su sad skupljene zajedno na početku bile veoma udaljene. Niske FTLE vrijednosti ne upućuju nužno na to da se čestice nisu pomaknule s početne pozicije, već mogu značiti da su se čestice zajedno gibale pri čemu do razdvajanja nije došlo. Isti način razmišljanja se može primijeniti i za

integraciju naprijed, gdje visoke FTLE vrijednosti govore da su se čestice najviše razmaknule.

2.4.2. Odabir FTLE parametara

FTLE proračun je rađen na dnevnim srednjim vrijednostima površinskih polja struja s ciljem prepoznavanja što konzistentnijih struktura. Za datum proračuna proizvoljno je odabran 27. ožujak 2016. godine za sve tri domene (slika 9.a, 10.a, 11.a). Integriranje je napravljeno unaprijed u vremenu. Za svaku od tri domene napravljeno je više proračuna (tablice 1., 2. i 3.) koje su uključivale odabir različitih metoda integracije, prostorne rezolucije i vremenskog koraka te ukupnog vremena integracije. Cilj je bio što jasniji prikaz LCS-ova, ali sa što kraćim vremenskim trajanjem proračuna FTLE metode na osobnom računalu.

Za domenu koja pokriva Jadransko more u prvom proračunu je korištena Eulerova metoda, vremenski korak od 1 dan, prostorni korak od 2.5 km koji je jednak rezoluciji polja brzina dobivenih modelskim računom, a vrijeme integracije je bilo 50 dana (tablica 1.). Prostorna rezolucija FTLE mreže je bila jednaka rezoluciji ulaznog polja, unatoč tome što je za početnu udaljenost δ_i preporučeno da mora biti manja od rezolucije ulaznog polja brzina. Razlog takvog odabira je prikaz onog što se dobije odabirom koraka modelske mreže za prostorni korak FTLE metode. LCS-ovi se nisu mogli jasno detektirati (slika 9.b). Povećavanje vremena integracije s 50 dana na vrijeme koje odgovara vremenu zadržavanja prosječne čestice u Jadranu od 70 dana te potom na 90 dana ne rezultira jasnijim prikazom LCS-ova, ali povećava iznos vremena izračuna. Upotreba Runge-Kutta metode četvrtog stupnja i smanjenje prostorne rezolucije na 0.625 km daje oštrije definirane LCS-ove u skalarnom polju, nauštrb povećanju vremena izračuna. Ali i dalje je prisutan šum u polju koji maskira linije LCS-ova (slika 9.c). Smanjenjem vremenskog koraka proračuna na 6 sati eliminiran je spomenuti šum, i dobiven je jasan prikaz LCS-ova (slika 9.d). Zbog toga je za prikaz LCS-ova odabran proračun pod nazivom Runge 6 (tablica 1.), unatoč procesorskoj zahtjevnosti, u kojem se koristi Runge-Kutta metoda 4. stupnja, prostorna rezolucija od 1.25 km, vremenski korak od 6 sati i vrijeme integracije u trajanju od 50 dana.

Procedura istovjetna proceduri za jadransku domenu upotrijebljena je i za ASHELF-2 domenu (tablica 2.). Napravljen je proračun s Eulerovom metodom,

vremenom integracije od 16 dana, vremenskim korakom od 1 dan, te početnom udaljenosti δ_i koja odgovara prostornoj rezoluciji ASHELF-2 modela. S kombinacijom tih paramatera, dobiveno polje ne omogućuje jasnu detekciju LCS-ova (slika 10.b). Smanjivanje vremenskog koraka na 3 sata i povećanje prostorne rezolucije na 500 m je rezultiralo lakšim uočavanjem LCS-ova, ali je i dalje prisutan šum u prikazu (slika 10.c). Povećavanje vremena integracije na 22 dana nije rezultiralo boljim prikazom FTLE polja. Smanjivanje vremena integracije na 12 dana ne donosi lošiji prikaz, ali skraćuje računalno vrijeme potrebno za proračun. Runge 2 (tablica 2.) je naziv proračuna koji je obuhvatio optimalnu kombinacija parametara i u kojem je korištena Runge-Kutta metoda četvrtog stupnja. Vremenski korak je iznosio 1 sat, prostorna rezolucija 250 m, a vrijeme integracije je bilo 12 dana (slika 10.d).

Isti postupak je i po treći put ponovljen za radarsko polje struja (tablica 3). Korištenje rezolucije radarskog polja za FTLE proračune nije omogućilo jasnu detekciju LCS-ova (slika 11.b). Smanjivanje prostorne rezolucije je i dalje ostavilo šum u prikazu (slika 11.c). Optimalna kombinacija parametara je nađena korištenjem Runge-Kutta metode 4. stupnja i vremenskog koraka u iznosu od 30 min s prostornom rezolucijom od 187 m (slika 11.d). Vrijeme integracije je bilo 3 dana za sve proračune. Prostorna domena radarskih mjerenja od 28x31 točaka rezultira veoma brzim proračunima, ali i opetovanim pojavljivanjem artefakata na FTLE poljima.

Tablica 1. Proračuni FTLE metode za domenu Jadranskog mora. Podcrtana je odabrana metoda

Naziv proračuna	**Metoda integracije**	**Vremenski korak (dan)**	**Prostorna rezolucija (km)**	**Vrijeme integracije (dan)**	**Računalno vrijeme potrebno za izračun (s)**
Euler 1	Euler	1	2.5	50	50
Euler 2	Euler	1	2.5	70	74
Euler 3	Euler	1	2.5	90	86
Euler 4	Euler	1	1.25	50	158
Euler 5	Euler	1	1.25	70	211
Euler 6	Euler	1	0.625	50	806
Runge 1	Runge-Kutta 4	1	1.25	70	885
Runge 2	Runge-Kutta 4	1	0.625	50	2201
Runge 3	Runge-Kutta 4	1	0.625	70	3049
Runge 4	Runge-Kutta 4	0.5	1.25	30	711
Runge 5	Runge-Kutta 4	0.5	1.25	50	1186
Runge 6	Runge-Kutta 4	0.25	1.25	50	2341

Tablica 2. Proračuni FTLE metode za ASHELF-2 domenu. Podcrtana je odabrana metoda.

Naziv proračuna	**Metoda**	**Vremenski korak (sat)**	**Prostorna rezolucija (km)**	**Vrijeme integracije (dan)**	**Računalno vrijeme potrebno za izračun (s)**
Euler 1	Euler	24	1	16	5
Euler 2	Euler	12	1	16	9
Euler 3	Euler	6	1	22	27
Euler 4	Euler	3	0.5	16	92
Euler 5	Euler	1	0.25	16	279
Runge 1	Runge-Kutta 4	1	0.25	16	4385
Runge 2	Runge-Kutta 4	1	0.25	12	2615

Tablica 3. Proračuni FTLE metode za radarsko područje. Podcrtana je odabrana metoda.

Naziv proračuna	**Metoda**	**Vremenski korak (sat)**	**Prostorna rezolucija (km)**	**Vrijeme integracije (dan)**	**Računalno vrijeme potrebno za izračun (s)**
Euler 1	Euler	2	1.5	3	1
Euler 2	Euler	1	0.7	3	1
Euler 3	Euler	1	0.375	3	1
Runge 1	Runge-Kutta 4	1	0.375	3	2
Runge 2	Runge-Kutta 4	1	0.187	3	4
Runge 3	Runge-Kutta 4	0.5	0.187	3	9

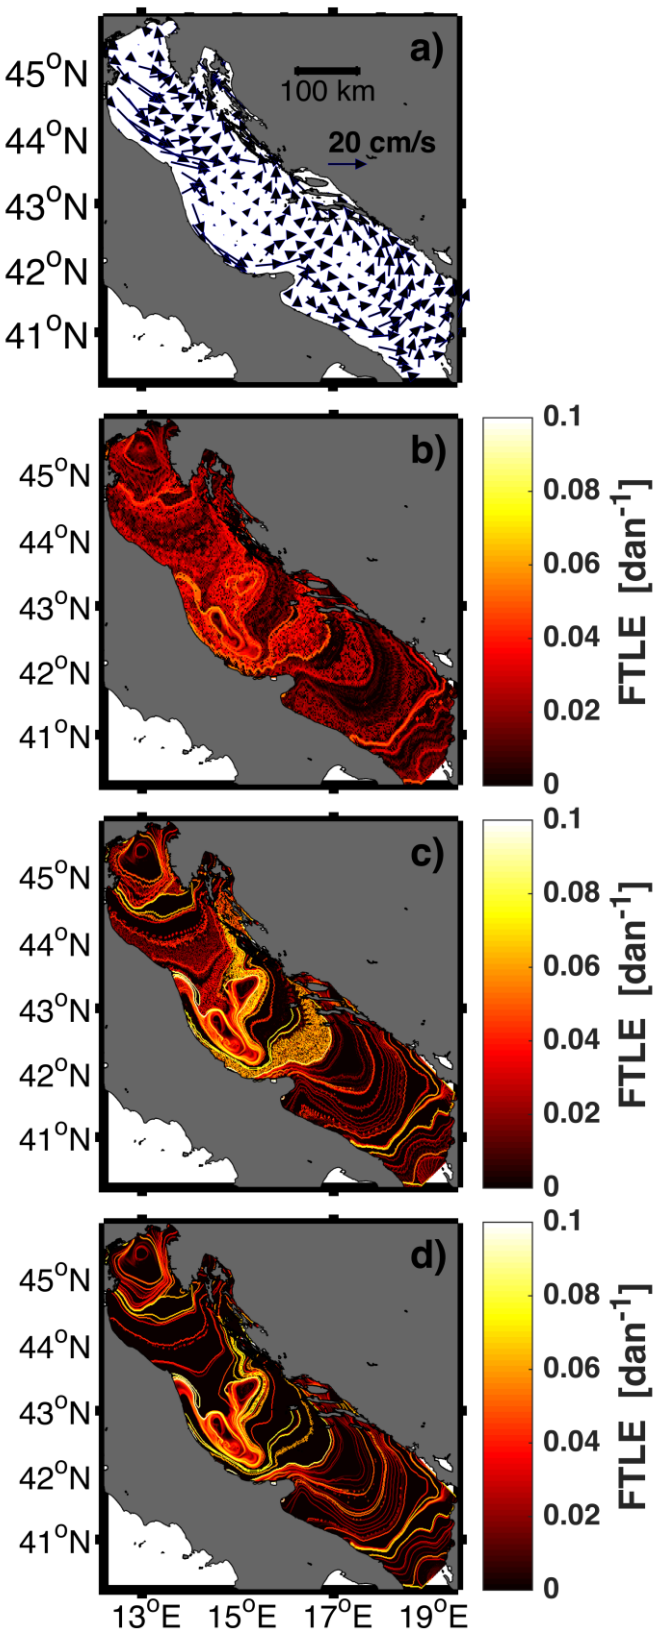

Slika 9. Dnevna srednja vrijednost površinskih struja iz jadranskog modela na dan 23. ožujka 2016. godine. Prikazan je svaki deseti vektor (a). Za navedeno polje struja prikazani su FTLE proračuni: Euler 2 (b), Runge 1 (c) i Runge 6 (d) označeni prema tablici 1.

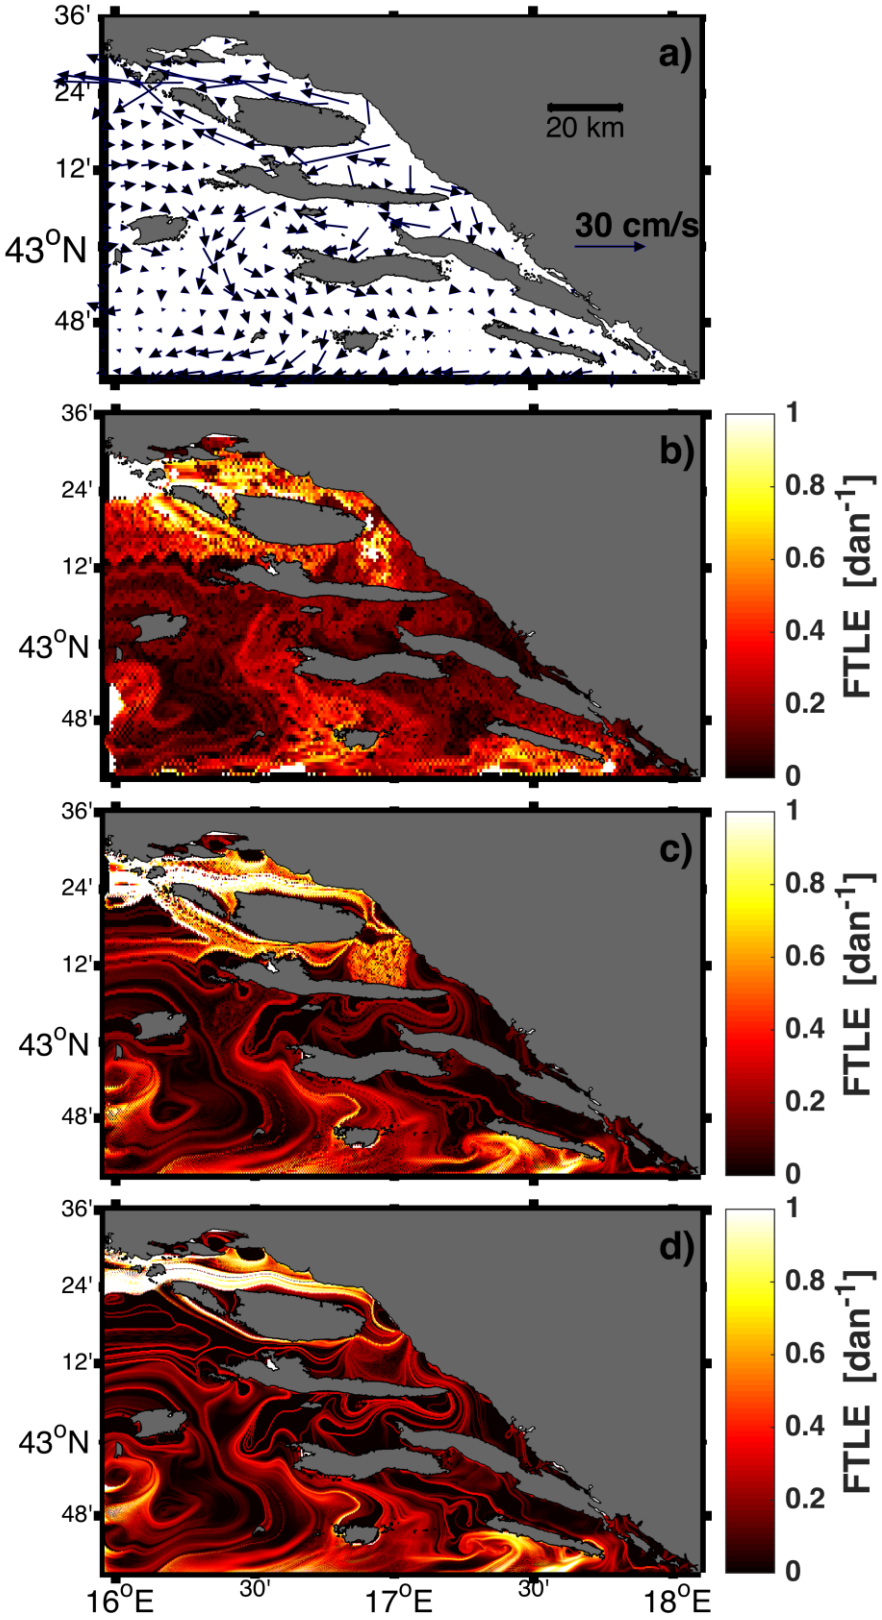

Slika 10. Dnevna srednja vrijednost površinskih struja ASHELF-2 modela na dan 23. ožujka 2016. godine. Prikazan je svaki šesti vektor (a). Za navedeno polje struja prikazani su FTLE proračuni: Euler 1 (b), Euler 4 (c) i Runge 2 (d) označeni prema tablici 2.

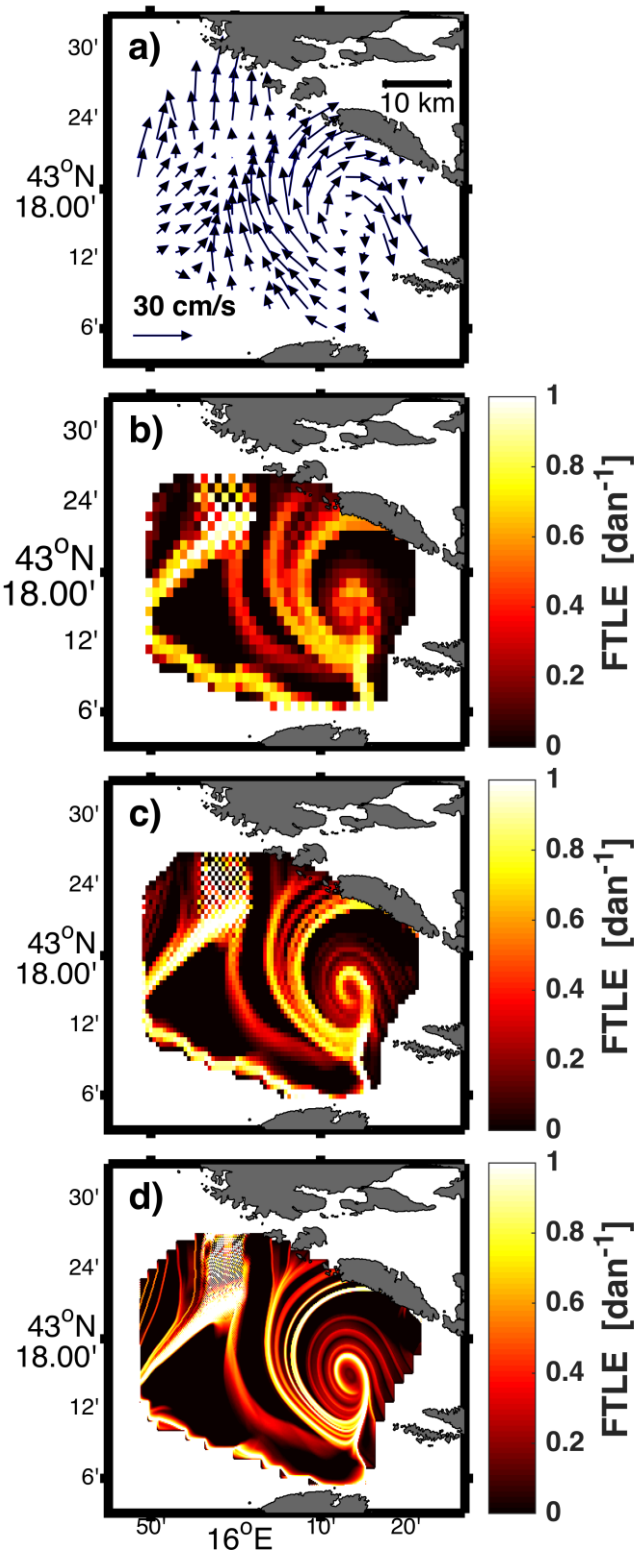

Slika 11. Dnevna srednja vrijednost površinskih struja mjerenih radarom na dan 23. ožujka 2016. godine. Prikazan je svaki drugi vektor (a). Za navedeno polje struja prikazani su FTLE proračuni: Euler 1 (b), Euler 3 (c) i Runge 3 (d) označeni prema tablici 3.

3. DISPERZIJA IHTIOPLANKTONA ATLANTSKE PLAVOPERAJNE TUNE U JADRANSKOM MORU

3.1. Motivacija za istraživanje

Skušovke (palamide, tune i skuše (Collette, 1999)) obitavaju u toplim i tropskim morima diljem svijeta. Migracije su im uvjetovane prehranom i mrijestom. Zbog komercijalne važnosti prostorna raspodjela i biološke osobine ovih vrsta su dobro poznate. Atlantsku plavoperajnu tunu, pelagičkog predatora, odlikuju sezonske migracije i činjenica da se mrijesti uvijek na istim lokacijama. Glavna područja mrijesta su Sredozemno more i Meksički zaljev (Cermeño i sur., 2015). Opaženo globalno smanjenje populacije tune uzrokovano povećanim ribarskim izlovom (Collette i sur., 2011; Juan-Jorda i sur., 2011) potaklo je kavezni uzgoj tuna i učinilo ga isplativom zamjenom za sam ribolov. Uzgoj tuna u Hrvatskoj se zasniva na ulovu manjih jedinki tune (8-10 kg) u otvorenom moru i kasnijem dohranjivanju u kavezima do ciljane tržišne veličine (230 kg). Tijekom 2011. godine aktivno je bilo pet uzgajališta u vlasništvu četiri hrvatske tvrtke na lokacijama središnjeg dijela istočnog Jadranskog mora (slika 12.). Mrijest tune u Sredozemnom moru (Balearski otoci, obala Sicilije, Libija i Cipar) (Corriero et i sur., 2005) se događa tijekom toplijeg dijela godine, točnije u razdoblju između svibnja i srpnja (Karakulak i sur., 2004; Druon i sur., 2016; Alemany i sur., 2010). Jedinke koje se izvale na navedenom području kasnije se vraćaju nazad na isto područje u zreloj dobi radi mrijesta. Jadransko more se razmatra kao potencijalno mrijestilište u nekoliko konfliktnih nerecenziranih radova, dok je u recenziranoj literaturi Jadransko more klasificirano kao područje hranjenja na temelju pokusa s elektroničkim označavanjem tuna (Cermeño i sur., 2015). Rezultat istog pokusa s elektroničkim označavanjem ukazuje na mogućnost da je središnje Jonsko more sekundarno potencijalno mrijestilište, čemu u prilog idu i najnoviji rezultati modeliranja ekoloških nivoa (Druon i sur., 2016). Spontani mrijest tune u kavezima je opažen u Sredozemnom moru (Karakulak i sur., 2004; Gordoa i Carreras 2014; de la Gándara i sur., 2011), uključujući i uzgajališta u Jadranskom moru tijekom ljeta 2011. godine (Grubišić i sur., 2013).

Slučajni ulov mladih jedinki tune u Jadranskom moru južno od otoka Mljeta (slika 12.) zajedno s ostalim dvjema vrstama iz porodice skušovki 1. rujna 2011.

godine otvorio je mnoga pitanja. Odgovori na ta pitanja mogu biti u suprotnosti s dosadašnjim spoznajama vezanim uz ekologiju tune i samim time mogu imati utjecaj na buduće odluke vezane uz zaštitu i uzgoj te vrste. Pogotovo ako se uzme u obzir da dosad nikad nije opažen mrijest tune u Jadranu, vrste čiji je fond pod striktnom regulacijom. Morfološka i molekularna identifikacija, te utvrđena starost od 30 dana su pokazale mogućnost mrijesta tune u Jadranu i potakle ideju da se upotrebom uparenog modelarskog sustava odredi potencijalno područje mrijesta.

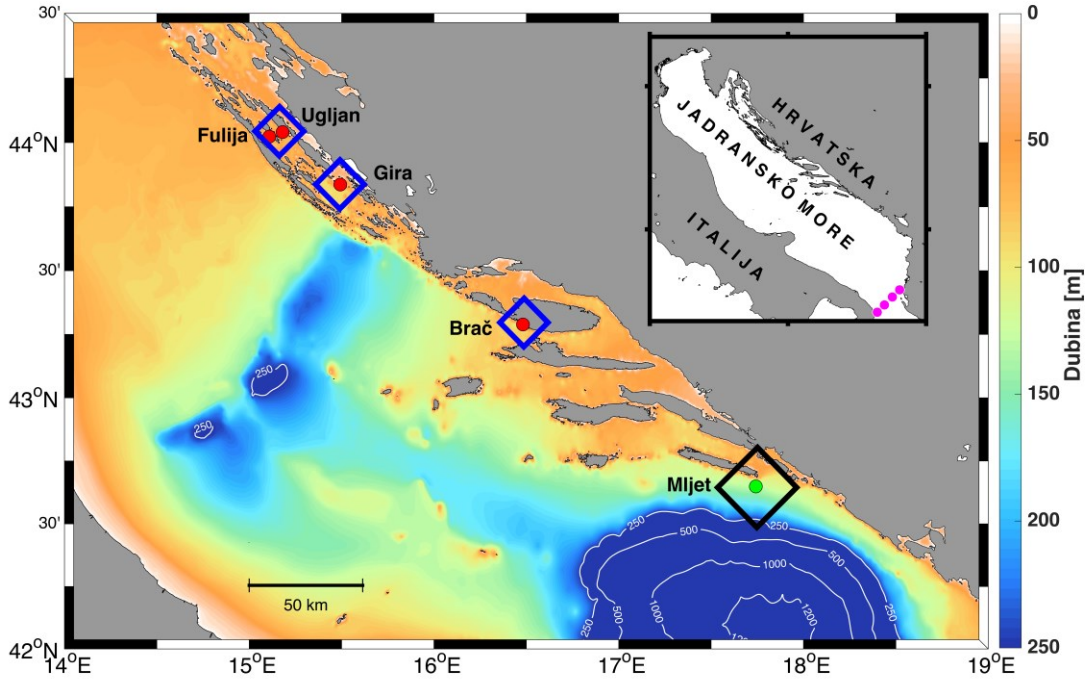

Slika 12. Batimetrija središnjeg dijela Jadranskog mora s lokacijom ulova tune južno od otoka Mljeta (zeleni krug) i lokacijama uzgajališta uz otoke Brač, Giru, Ugljan i Fuliju (crveni krugovi). Plavi kvadrati oko lokacija uzgajališta su područja uspjeha za čestice u pokusu unazad. Crni kvadrat oko lokacije ulova je područje uspjeha za čestice u pokusu unaprijed. Četiri ružičaste točke na karti cijelog Jadranskog mora (gornji desni kut) su točke ispuštanja čestica u Otrantskim vratima u pokusu 10. (tablica 4.).

3.2. Opis modelskog sustava

S ciljem utvrđivanja potencijalne lokacije na kojoj se dogodio mrijest, pokrenut je upareni modelski sustav sastavljen od oceanografskog modela ROMS i disperzijskog individualno temeljenog modela Ichthyop. Satne srednje vrijednosti morskih struja, temperature i saliniteta su izračunate za razdoblje 17. srpnja - 2. rujna

2011. godine. Vremenski korak u Ichthyop simulacijama je iznosio 600 sekundi. Odabir je napravljen tako da zadovolji Courant-Friedrichs-Lewyev uvjet i bude optimalan u korištenju računalnog vremena. U parametrizaciji ponašanja čestica prilikom nailaska na kopno odabrana je opcija odbijanja čestica od obalne linije. Namjera je bila zadržati sve čestice u lagrangeovskom izračunu i na taj način dobiti što više trajektorija koje će dati cjelovitiju sliku disperzije čestica. Runge-Kutta metoda četvrtog reda je korištena kao numerička shema s ciljem što točnijeg izračuna položaja čestica unatoč većoj računalnoj zahtjevnosti. U proračunima disperzije čestica korištene su simulacije unaprijed i unazad u vremenu. Korištenje oba vremenska smjera nije učestala praksa u simulacijama disperzije ihtioplanktona zbog nedostatka informacije o početnoj i krajnjoj točki, to jest području mrijesta i području ulova odnosno staništa u kojem se ihtioplankton duže zadržava, kao što je to bio slučaj u ovom istraživanju. Odabir optimalnog broja čestica korištenog u simulacijama napravljen je u skladu sa statističkim kriterijem stabilnosti (Brickman i Smith, 2002). Metoda određivanja broja čestica je jednostavna: provesti što veći broj istovjetnih simulacija s proizvoljnim brojem čestica i potom dobiti kvantativnu i kvalitativnu mjeru rezultata. Bez testiranja optimalnog broja čestica ne možemo biti sigurni je li rezultat reprezentativan ili je atipične vrijednosti (eng. outlier) koji može dati krivi zaključak. Najčešći problem u određivanju broja čestica je odabir premalog broja čestica u disperzijskoj simulaciji. Testiranje optimalnog broja je napravljeno s 5000, 10000, 20000 i 40000 čestica, gdje je za svaki broj čestica simulacija pokrenuta 8 puta. Mjesto ispuštanja čestica je bila lokacija ulova tuna (slika 12.), a ciljno područje je bilo područje uspjeha oko lokacije uzgajališta na Braču (slika 12.). Broj čestica u području uspjeha je pomnožen s postotkom mokrih točaka unutar kvadrata, koji definira područje uspjeha. Simulacije su rađene unazad u vremenu s najosnovnijom parametrizacijom: čestice su bile pasivni plivači ispušteni u mrlji polumjera 500 m koja je obuhvaćala prvih 30 m vodenog stupca. Potom je za svaki osmočlani ansambl izračunata srednja vrijednost i standardna devijacija. Broj od 20000 čestica se pokazao optimalnim (slika 13.). Upotreba 20000 čestica jasno pokazuje porast broja čestica u području uspjeha s približavanjem 17. srpnja kao zadnjeg dana simulacije unazad. Pritom nije računalno zahtjevna kao upotreba 40000 čestica. Navedeni porast nije lako uočljiv s 5000 ili 10000 čestica. Udio čestica koje pristižu u područje uspjeha kreće se od 1 do 2 posto ukupnog broja ispuštenih čestica za sve četiri vrijednosti broja ispuštenih čestica. Postotni udio čestica je sačuvan cijelo

vrijeme, ali razlika u broju čestica pobrojanih 17. srpnja i 5. kolovoza je vizualno uočljivija.

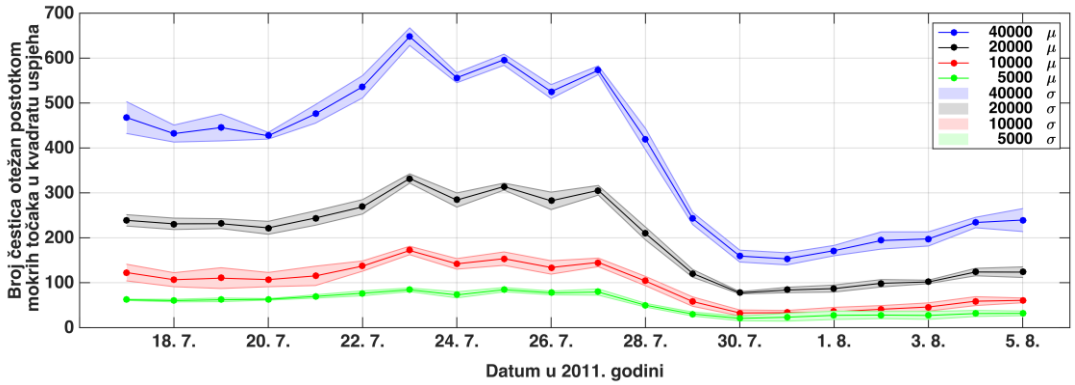

Slika 13. Prikaz srednje vrijednosti $\boldsymbol{\mu}$ i standardne devijacije $\boldsymbol{\sigma}$ broja čestica koje su pristigle u područje uspjeha kod otoka Brača u pokusu unazad iz ishodišta kod otoka Mljeta. Srednje vrijednosti i standardne devijacije su izračunate iz osmočlanog ansambla simulacija s 5000 (zelena boja), 10000 (crvena boja), 20000 (siva boja) i 40000 čestica (plava boja).

Na pasivni pomak čestica u pokusima unazad utjecaj imaju samo modelirane struje i varijabilna difuzijska polja. Točka ispusta čestica za simulacije unazad je bila južno od otoka Mljeta (slika 12.), gdje je 20000 čestica ispušteno u mrlji polumjera 500 m, koja je obuhvaćala prvih 15 m vodenog stupca (pokus 1. iz tablice 4.). Simulacije su trajale 46 dana gledano unazad od datuma puštanja čestica 1. rujna 2011. godine. Dodatni rasponi dubina su također testirani (pokusi 2., 3. i 4. iz tablice 4.). Rasponi su zasnovani na istraživanjima dnevne i noćne dubinske raspodjele larvi tuna u blizini Balearskih otoka (Alemany i sur., 2010) kao i na dubini termokline u Jadranskom moru izmjerenoj tijekom srpnja i kolovoza 2011. godine Argo plovkom. Podaci vezani uz dnevnu i noćnu vertikalnu raspodjelu za larve tune u Jadranskom moru ne postoje. U pokusu 4. zadan je izmjereni nivo termokline kao gornja očekivana dubina. Tuna je u dobi u kojoj je uhvaćena aktivni predator i njezin plijen može biti ispod termokline. U pokusima unaprijed, lokacije izvora čestica su smještene na lokacijama uzgajališta tuna: uzgajališta kod Ugljana, Gire i Brača (slika 12.). Uzgajalište kod Ugljana je predstavljalo i uzgajalište kod Fulije zbog male međusobne udaljenosti koja ih skoro smješta unutar iste numeričke ćelije modela. Polumjer mrlje je iznosio 250 m što odgovara području koje zauzimaju kavezi. Iako kavezi dopiru do 30 m dubine, mrlja je bila raspoređena u prvih 15 m dubine, jer je to dubina na kojoj tuna obitava tijekom mrijesta. Svaki dan između 17. srpnja i 5. kolovoza u 0300 UTC 1000 čestica je pušteno sa svake od tri lokacije uzgajališta

tuna. Unatoč tome što je opaženo vrijeme u kojem se događa mrijest između 0000 i 0300 UTC (Gordoa i Carreras, 2014), pokusi osjetljivosti su pokazali da korištenje bilo kojeg vremena ispuštanja unutar opaženog intervala nema veliki utjecaj na konačne rezultate disperzijske simulacije. Pokusi unaprijed su provedeni na nekoliko načina: samo s pasivnim pomakom (pokus 5.), s pasivnim pomakom kombiniranim s aktivnim plivanjem (pokus 6. i 7.) i sa samo aktivnim plivanjem (pokus 8. i 9.). Brzina plivanja čestica je iznosila jednu, dvije ili četiri tjelesne dužine u sekundi (Mariani i sur., 2010; Reglero i sur., 2015). Temeljem prethodno objavljenih funkcija rasta (Mesa i sur., 2005) definirana je starosna dob prikupljenih jedinki tune sljedećom jednadžbom:

$$FL = 41.20 + 2.37 * t, \qquad (37)$$

gdje je FL (eng. fork length; vilična dužina tijela) udaljenost od usta ribe do sredine zadnjeg ruba repne peraje u mm, a t starosna dob u danima. U svakom vremenskom koraku smjer plivanja je zadan slučajnim odabirom. Korištena su dva načina parametrizacije brzine plivanja. U konstantnom načinu čestica je plivala brzinom, koja je definirana funkcijom dobi. U načinu slučajnog odabira čestica je plivala brzinom, čiji je iznos svaki vremenski korak slučajno odabiran iz intervala od 0 do dvostrukog iznosa brzine zadane funkcijom dobi. Interval od 0 do dvostrukog iznosa brzine je odabran zato da srednja brzina plivanja bude istovjetna za oba načina parametrizacije plivanja. Inkubacijski period, koji traje 30 sati u zatočeništvu (Grubišić i sur., 2013), je zanemaren u numeričkim pokusima koji traju 48 dana. Pretpostavljeno je da čestica ima odmah duljinu izvaljene larve i samim time mogućnost plivanja. Dodatnim pokusom (pokus 10.) su testirane putanje čestica koje kreću s četiri točke koje se nalaze u Otrantskim vratima (40°11'46.32"N, 18°35'7.8"E; 40°41'20.76"N, 19°13'58.44"E; 40°31'48.36"N, 19°1'24.96"E i 40°21'18.72"N, 18°47'37.68"E) (slika 12.).

Tablica 4. Popis numeričkih pokusa

Broj pokusa	**Vremenska orijentacija pokusa**	**Dubina ispuštanja čestica (m)**	**Točka ispuštanja čestica**	**Pasivno gibanje čestica**	**Brzina plivanja (ne, konstantna, slučajno odabrana)**
Pokus 1.	Unazad	0 - 15	Mljet	Da	Ne
Pokus 2.	Unazad	15 – 30	Mljet	Da	Ne
Pokus 3.	Unazad	30 – 50	Mljet	Da	Ne
Pokus 4.	Unazad	20 - 50	Mljet	Da	Ne
Pokus 5.	Unaprijed	0 - 15	Kavezi	Da	Ne
Pokus 6.	Unaprijed	0 - 15	Kavezi	Da	Konstantna
Pokus 7.	Unaprijed	0 - 15	Kavezi	Da	Slučajno odabrana
Pokus 8.	Unaprijed	0 - 15	Kavezi	Ne	Konstantna
Pokus 9.	Unaprijed	0 - 15	Kavezi	Ne	Slučajno odabrana
Pokus 10.	Unaprijed	0 - 50	Otrantska vrata	Da	Ne

3.3. Rezultati

3.3.1. Meteorološki i oceanografski uvjeti

Analiza prevladavajućih meteoroloških i oceanografskih uvjeta je napravljena korištenjem svih podataka koji su bili dostupni za proučavano razdoblje. Tijekom promatranog razdoblja vrijeme je bilo pod utjecajem jako razvijene Azorske anticiklone i Karachi depresije. Na Jadranu je prevladavalo toplo i suho vrijeme s karakterističnom iznimno razvijenom dnevnom obalnom cirkulacijom (Meteorološki bilten 07/2011, Meteorološki bilten 08/2011, Prikazi br. 23). Srednja dnevna

vrijednost temperature zraka na 2 m visine dobivena modelom ALADIN tijekom cijelog razdoblja simulacije nije pala ispod 24 °C na otvorenom moru (slika 14.).

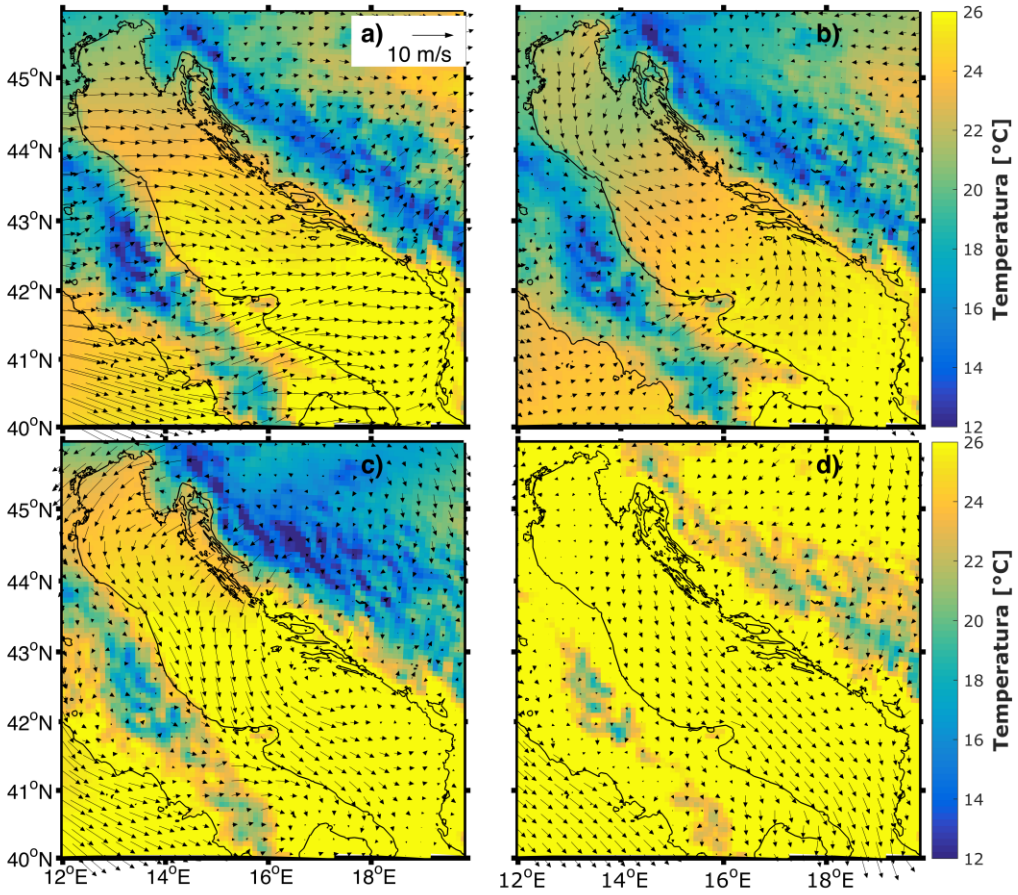

Slika 14. Srednje dnevne vrijednosti temperature zraka na 2 m visine i vjetra na 10 m visine dobivene modelom ALADIN za dane: 20. srpnja (a), 28. srpnja (b), 9. kolovoza (c) i 25. kolovoza 2011. godine (d).

Iako su smjer i jačina vjetra na visini od 10 m varirali tijekom razdoblja obuhvaćenog disperzijskom simulacijom, uglavnom je prevladavalo zapadno i sjeverozapadno strujanje popraćeno kraćim epizodama bure (slika 14.).

Dodatna potvrda o iznimno toplom ljetnom razdoblju došla je i iz mjerenja površinske temperature mora. Površinska temperatura mora za postaje Split i Hvar usrednjena za srpanj i kolovoz 2011. godine je bila jednu standardnu devijaciju iznad klimatološke srednje vrijednosti dobivene za 65-godišnje razdoblje 1950. - 2015. godine (http://www.izor.hr/web/guest/virtual-laboratory, Grbec i sur., 2016.). Površinska temperatura mora za postaju Komiža, najbližu otvorenom moru, je bila čak dvije standardne devijacije iznad klimatološke srednje vrijednosti (slika 15.).

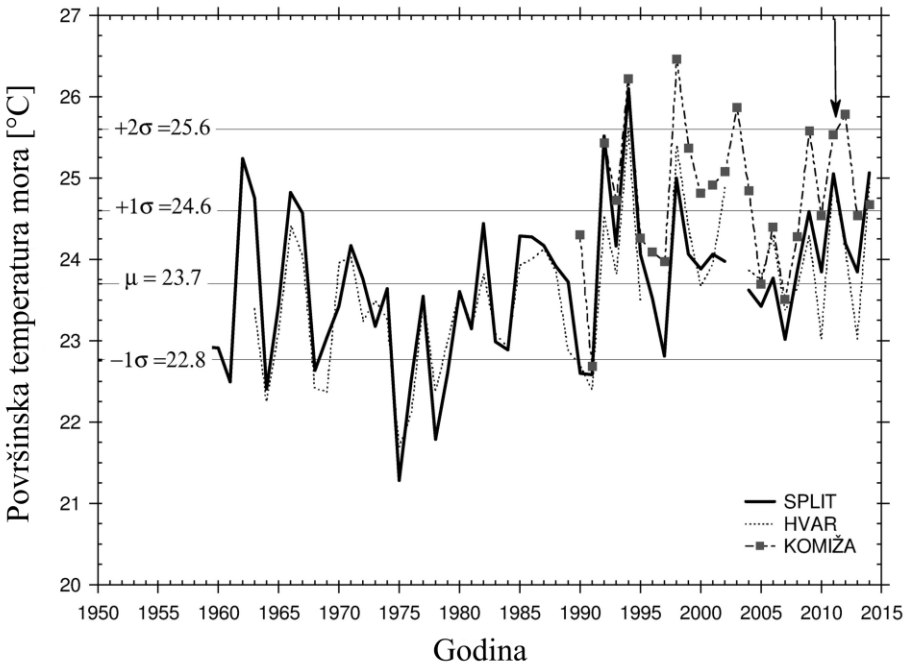

Slika 15. Vremenski niz dostupnih srednjih dvomjesečnih vrijednosti površinske temperature mora za srpanj i kolovoz u razdoblju od 1950. do 2015. Temperatura je mjerena na obalnim postajama Split, Hvar i Komiža. Strelicom je u desnom gornjem kutu naznačena 2011. godina.

S ciljem dobivanja cjelovitog prikaza površinske temperature Jadranskog mora upotrijebljena su satelitska mjerenja (slika 16.). Satelitska mjerenja poslužila su i za verifikaciju modelirane površinske temperature. Površinska temperatura mora dobivena satelitskim mjerenjem tijekom cijelog promatranog razdoblja na otvorenom moru je bila iznad 23 °C (slika 16., stupac a). Područje Kvarnera je bilo jedino područje gdje je temperatura bila znantno niža od ostatka Jadrana, što je posljedica ohlađivanja mora pod utjecajem ljetnih epizoda bure (Bergamasco i Gačić, 1996; Beg Paklar i sur., 2008). Numeričkim modeliranjem su dobiveni slični rezultati za područje Kvarnera (slika 16., stupac b), no područje uz albansku obalu je bilo daleko hladnije u usporedbi sa satelitskim mjerenjima. Oduzimanjem iznosa površinske temperatura dobivene satelitskim mjerenjem od površinske temperature dobivene numeričkim modeliranjem zamijećena su područja u kojima je najizraženija razlika: otvoreno more srednjeg i južnog Jadrana (slika 16., stupac c). Apsolutne razlike u temperaturi nisu prelazile iznos od 2 °C na većini područja, a modelirane temperature su i dalje bile iznad donjeg temperaturnog praga povoljnog za mrijest. Negativna odstupanja modela duž obale Jadranskog mora su ukazala na nužnost poboljšanja

implementacije riječnih protoka u modelu. Protoci su određeni prema klimatološkim vrijednostima (Raicich, 1994) i pri tome je njihov temperaturni efekt zanemaren. Za očekivati je poboljšanje modeliranih temperaturnih polja uvođenjem realnije implementacije rijeka.

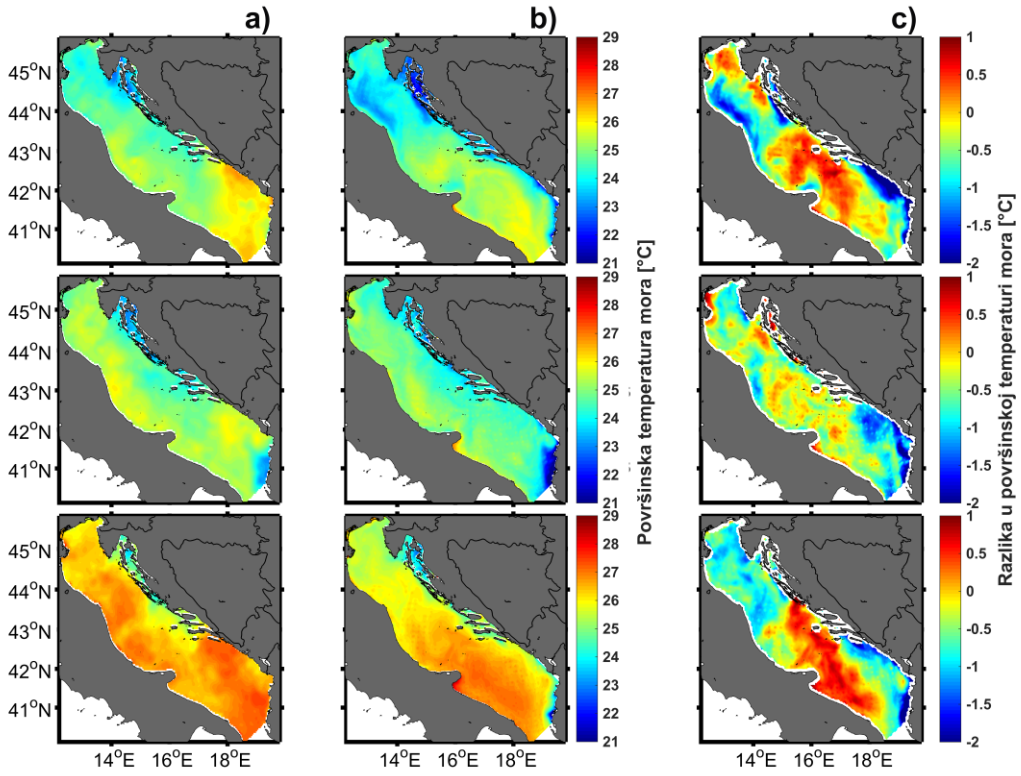

Slika 16. Srednja dnevna vrijednost površinske temperature mora dobivena iz reprocesiranih AVHRR satelitskih podataka (stupac a), dnevna srednja vrijednost površinske temperature mora dobivena pomoću modela ROMS (stupac b), razlika između modeliranih i izmjerenih vrijednosti (stupac c). Prvi redak su podaci za 23. srpnja, drugi redak su podaci za 14. kolovoza i treći redak su podaci za 1. rujna 2011. godine.

Promjena u vremenu iznosa odstupanja površinske temperature mora (slika 16., stupac c) upućuje na mogući utjecaj sinoptičkih situacija (Prikazi br. 23) tijekom kojih se smjenjuju utjecaji različitih procesa. U drugoj polovici srpnja preko Jadranskog mora premještale su se na istok hladna fronta i plitka ciklona, što je bilo popraćeno kišom na Jadranu uz već spomenuti sjeverozapadni vjetar s burom. Kolovoz je protekao uz izmjenu utjecaja Sredozemnog polja visokog tlaka i plitkih i slabo izraženih ciklona popraćenih hladnim frontama. Promjene navedenih sinoptičkih utjecaja zahtijevaju detaljniju analizu, koja je izvan tematike ovog rada. No, ako uzmemo u obzir da su simulacije disperzijskim modelom provedene

uglavnom s pasivnim česticama, dobivene maksimalne temperaturne razlike u iznosu od 2 °C nemaju veliki utjecaj na konačni rezultat. Pogotovo jer su područja s najvećim odstupanjima modelirane površinske temperature mora od izmjerene izvan svih pretpostavljenih putanja tuna.

Dodatna potvrda o temperaturi mora pogodnoj za mrijest došla je sa samog uzgajališta kod otoka Ugljana (slika 17.a). Na dubini od 1 m u razdoblju od ožujka do sredine kolovoza 2011. godine je mjerena temperatura mora. Na slici 17. prikazana je temperatura mora u prethodno spomenutom razdoblju od 17. srpnja do 15. kolovoza. Navedeno razdoblje započinje s datumom koji odgovara datumu mrijesta najstarijih uhvaćenih jedinki tune i završava sa zadnjim danom mjerenja temperature na uzgajalištu. Iz mreže modela ROMS je odabrana točka koja je najbliže uzgajalištu, te je za tu točku prikazana temperatura na dubini od 1 m (slika 17.). Razlike između modelirane i mjerene potpovršinske temperature pokazuju dva obrasca: razdoblje sličnih vrijednosti do 29. srpnja i razdoblje sličnih trendova, ali s izraženim pomakom u vrijednostima poslije 29. srpnja. Opaženi obrasci su posljedica različitih sinoptičkih uvjeta prije i poslije 29. srpnja. Od 14. do 18. srpnja i od 30. srpnja do 15. kolovoza vrijeme je bilo stabilno, toplo i suho, dok su se od 19. do 29. srpnja atmosferske nestabilnosti premiještale preko Jadranskog mora (Prikazi br. 23). Tijekom stabilnih atmosferskih uvjeta model se previše zagrijava što se vidi u dobivenim modeliranim vrijednostima temperature, koje su bile veće ili jednake od izmjerenih vrijednosti u samom uzgajalištu. Iako su razlike od 1.5 °C zadovoljavajuće za simulacije s pasivnim česticama, navedeni problem traži dodatnu analizu. Zbog blizine lokacije uzgajališta kopnu teško je za očekivati da će model rezolucije od 2 km reproducirati temperaturu, pogotovo u kompleksnom području hrvatske obale Jadranskog mora. S povećanjem rezolucije modela očekujemo i povećanje točnosti rezultata, pogotovo u obalnom dijelu. Pri tomu naglasak na popravljanje rezultata temperature mora ima veliku težinu jer se u simulacije individualno temeljenim modelom može uključiti temperaturno zavisan rast jedinki kao i smrtnost zbog nepovoljnih temperaturnih uvjeta za jedinku. Korelacija između modeliranog i mjerenog niza potpovršinske temperature za lokaciju uzgajališta kod otoka Ugljana ($r = 0.73,\ \alpha = 0.01$) omogućila nam je da pretpostavimo i pojavu mrijesta na uzgajalištima kod otoka Brača i Gire. Na navedenim uzgajalištima nije mjerena temperatura i nije dokumentiran mrijest tijekom ljeta 2011. godine. Ali modelirani vremenski nizovi za sva tri uzgajališta pokazuju iznimnu sličnost i u hodu i u iznosima. U prilog

pretpostavci mrijesta ide i donja temperaturna granica mrijesta od 19.5 °C za tune u zapadnom Sredozemnom moru (Gordoa i Carreras, 2014). Mjerene, ali i modelirane temperature na uzgajalištima tijekom pretpostavljenog razdoblja mrijesta su se kretale iznad 22 °C što je daleko iznad donje granice. Još jedan povoljni uvjet za mrijest je i nagli porast temperature na 25 °C (Mylonas i sur., 2007). Navedeni porast je opažen pri mjerenjima u kavezima uzgajališta kod otoka Ugljana (Grubišić i sur., 2013), ali je i uspješno modeliran što se očituje početnom vrijednošću od 25 °C u sva tri prikazana modelirana temperaturna niza (slika 17.).

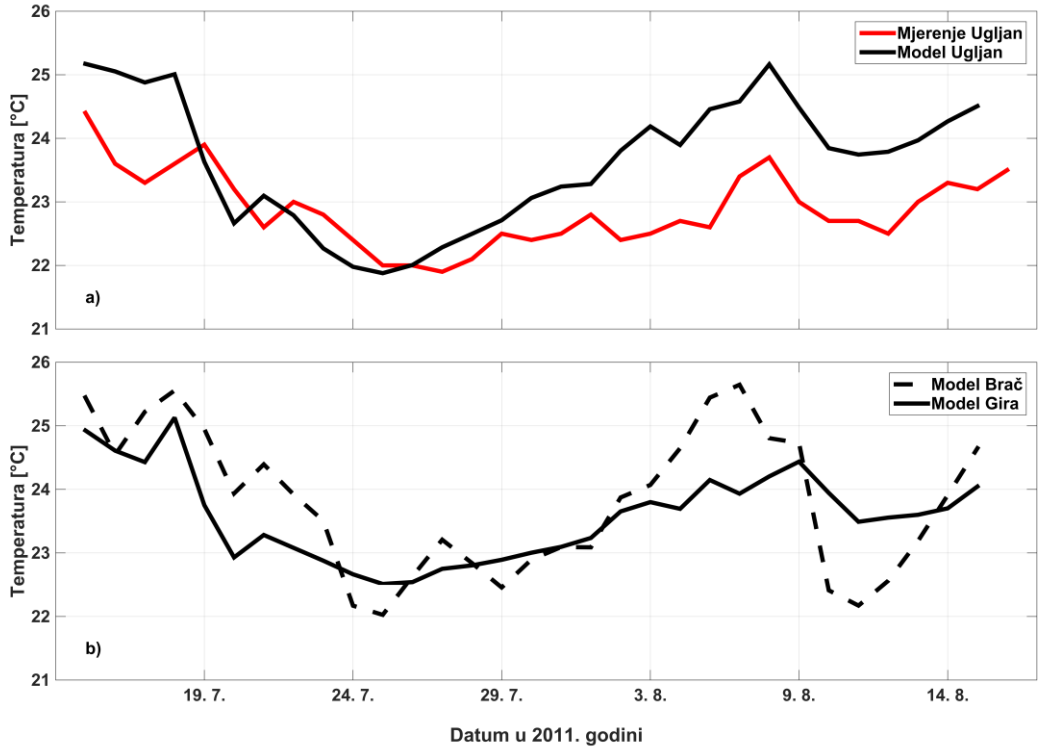

Slika 17. Modelirani i mjereni vremenski niz temperature mora na dubini od 1 m na uzgajalištu pored otoka Ugljana (a), modelirani vremenski nizovi temperature na dubini od 1 m na uzgajalištima pored otoka Brača i Gire (b).

Modelirane površinske struje i struje na 10 i 30 m dubine duž istočne obale srednjeg i južnog Jadranskog mora su bile u smjeru suprotnom istočnojadranskoj obalnoj struji (slika 18.). Istočnojadranska obalna struja ima sjeverozapadni smjer i dio je jadranske ciklonalne cirkulacije (Artegiani i sur., 1997b; Poulain i Cushman-Roisin, 2001). Jugoistočni smjer strujanja uz istočnu jadransku obalu bio je dominantan u cijelom razdoblju od 17. srpnja do 1. rujna. Sličan obrat u ljetnom površinskom strujanju duž istočne jadranske obale je zabilježen i u mjerenjima struja

na transektu Split - Gargano (Zore-Armanda, 1968). Postojanje obrata upućuje na jaki sezonski signal u površinskom strujnom polju. Obrat struja od uobičajenog NW smjera u SE smjer u istočnom dijelu Jadranskog mora također je dobiven i u rezultatima numeričkog modela POM (Princeton Ocean Model) u okviru projekta ADRICOSM (Orlić i sur., 2006a). U klimatološkoj simulaciji obrat je dobiven tijekom ljeta kada su na otvorene granice nametnuti rezultati šireg jadranskog AREG modela (Zavatarelli i Pinardi, 2003), dok se u simulaciji s radijacijskim rubnim uvjetima na otvorenim granicama nije javljao. Navedeno upućuje na važnost utjecaja dinamike cijelog bazena na postojanje obrata. U realističnim međugodišnjim simulacijama obrat struje se može povezati s prevladavajućim sjeverozapadnim vjetrom, ali i s razdiobom termohalinih svojstava, osobito temperature. Slična ovisnost obrata struje o sjeverozapadnom vjetru zabilježena je i u rezultatima oceanografskih prognoza koje su izdavane za ASHELF-2 domenu od travnja do rujna 2003. godine. Na temelju rezultata POM modela se može zaključiti da su uzroci obrata ili lokalni ili su rezultat djelovanja procesa na širim prostornim skalama. Kako tijekom projekta ADRICOSM nisu direktno mjerene struje, teško je odgovoriti na pitanje koji je proces bio dominantan u pojedinim situacijama. Vremenske karakteristike ljetnog razdoblja koje su dovele do obrata u numeričkim rezultatima u kolovozu 2003. godine za vrijeme projekta ADRICOSM su bile slične onima u ljeto 2011. godine.

Temperatura zraka je bila iznimno visoka s dominatnim sjeverozapadnim vjetrom. Struje tijekom ljeta 2011. godine na potezu od otoka Visa do područja južno od otoka Mljeta su cijelo vrijeme simulacije bile snažnije i pokazivale su manju varijabilnost u usporedbi sa strujama na potezu od Dugog otoka do otoka Brača. Na tom potezu varijabilnost iznosa kao i smjera struja je bila značajnija, pri čemu su iznosi brzina struja bili daleko manji. Duž zapadne talijanske obale strujanje odgovara uobičajenom smjeru zapadnojadranske obalne struje (Zore-Armanda, 1968; Artegiani i sur., 1997b; Poulain i Cushman-Roisin, 2001). Modelirana temperatura mora (slika 18.) je bila u prvih 10 m iznad donje granice mrijesta od 19.5 °C tijekom cijelog proučavanog razdoblja, dok je na dubini od 30 m bila iznad 16 °C. Adultne jedinke tune imaju tedenciju zadržavanja u prvih 30 m sve dok je temperatura mora iznad 13 °C (Galuardi i Lutcavage, 2012; Druon i sur., 2016). Oba temperaturna uvjeta su bila zadovoljena duž cijele pretpostavljene putanje mladih tuna uzduž hrvatskog dijela južnog otvorenog Jadranskog mora.

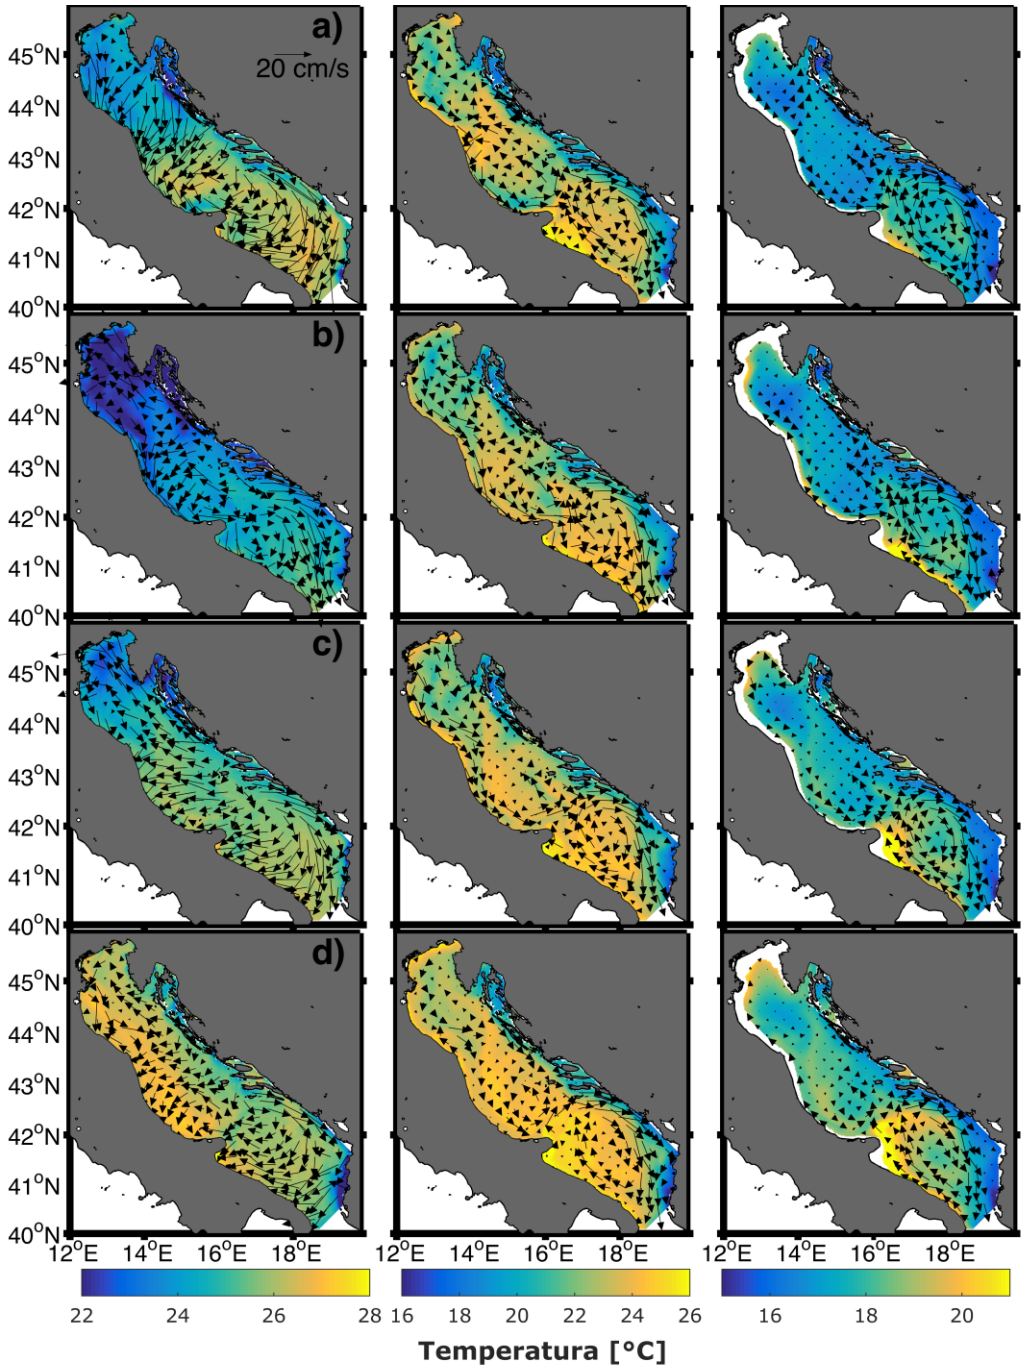

Slika 18. Srednja dnevna temperatura i srednje dnevne vrijednosti strujanja u moru izračunati pomoću modela ROMS na dubini od 1 m (prvi stupac), na dubini od 10 m (drugi stupac) i na dubini od 30 m (treći stupac) za 20. srpnja (redak a), za 28. srpnja (redak b), za 9. kolovoza (redak c) i za 20. kolovoza 2011. godine (redak d). Vektori su crtani za svaku desetu točku mreže.

Za vrijeme trajanja simulacije u srednjem Jadranu se nalazio i Argo plovak (slika 19.). Putanja plovka zajedno s vertikalnim profilima temperature i saliniteta, koje je Argo mjerio svakih pet dana, su iskorišteni za verifikaciju rezultata ROMS modela. Od ukupno 10 dostupnih vertikalnih profila izmjerenih u razdoblju od 17. srpnja do 2. rujna odabrana su i prikazana 2 profila.

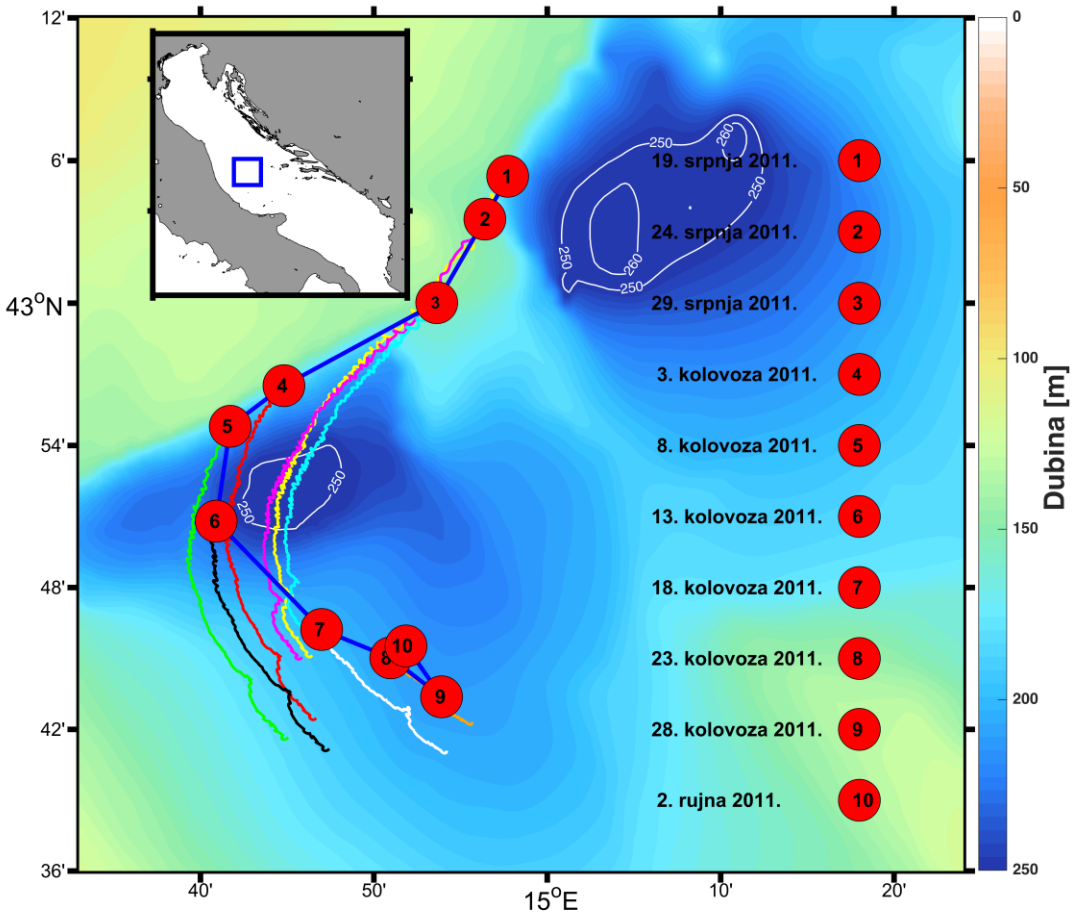

Slika 19. Batimetrija Jabučke kotline s prikazom modeliranih (ROMS) putanja plovaka (nepravilne linije), mjerene putanje Argo plovka (pravilne plave linije) s lokacijama (crveni kružić) i datumima profiliranja. Plavi kvadrat na mapi Jadranskog mora pokazuje područje kretanja Argo plovka u razdoblju od 19. srpnja do 2. rujna 2011. godine.

Ostali profili su vrlo slični prikazanima zbog blizine točaka profiliranja u Jabučkoj kotlini. Dugotrajno toplo i suho vrijeme tijekom ljeta 2011. godine je rezultiralo izraženom stratifikacijom vodenog stupca (slika 20.). Termoklina se nalazila na oko 40 m, jasno dijeleći površinski topliji sloj od hladnijeg dubljeg sloja. Modelirani profili upućuju da je model ROMS ne samo dobro reproducirao zagrijani

površinski sloj, već i da se modelirani i mjereni vertikalni profili temperature i saliniteta iznimno dobro slažu. Razlike u izmjerenim i modeliranim profilima saliniteta mogu biti zanemarene zbog malih iznosa.

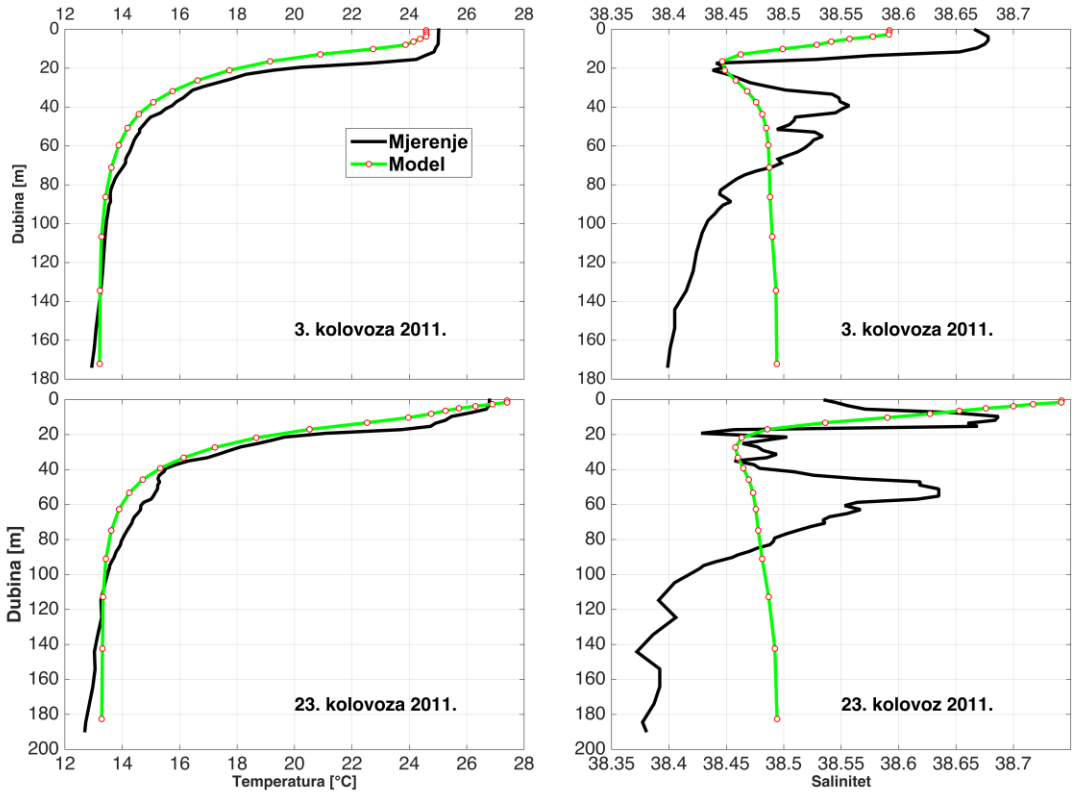

Slika 20. Modelirani (ROMS) i izmjereni (Argo) profili temperature i saliniteta 3. i 23. kolovoza 2011. godine.

Statistička usporedba rezultata modela i mjerenja je napravljena izračunom pristranosti modela (BIAS) i srednje kvadratne pogreške (RMSE). BIAS i RMSE za temperaturu i salinitet su izračunati za sve vertikalne CTD profile u razdoblju od 19. srpnja do 2. rujna 2011. godine (slika 21.). Sažimanje je napravljeno pod pretpostavkom sličnosti profila koje je mjerio Argo plovak u ljetnom razdoblju. Najveća razlika između modelirane i mjerene temperature je na dubini termokline (slika 21.a). S porastom dubine razlika između modeliranih i mjerenih rezultata se smanjuje. U slučaju saliniteta najveća razlika je u površinskom sloju (slika 21.b). Također, BIAS i RMSE su izračunati i zasebno za svaki od 10 CTD vertikalnih profila (tablica 5.). I za temperaturu i za salinitet rezultati modela podcjenjuju rezultate mjerenja, pri čemu su iznosi u promatranom razdoblju istog reda veličine.

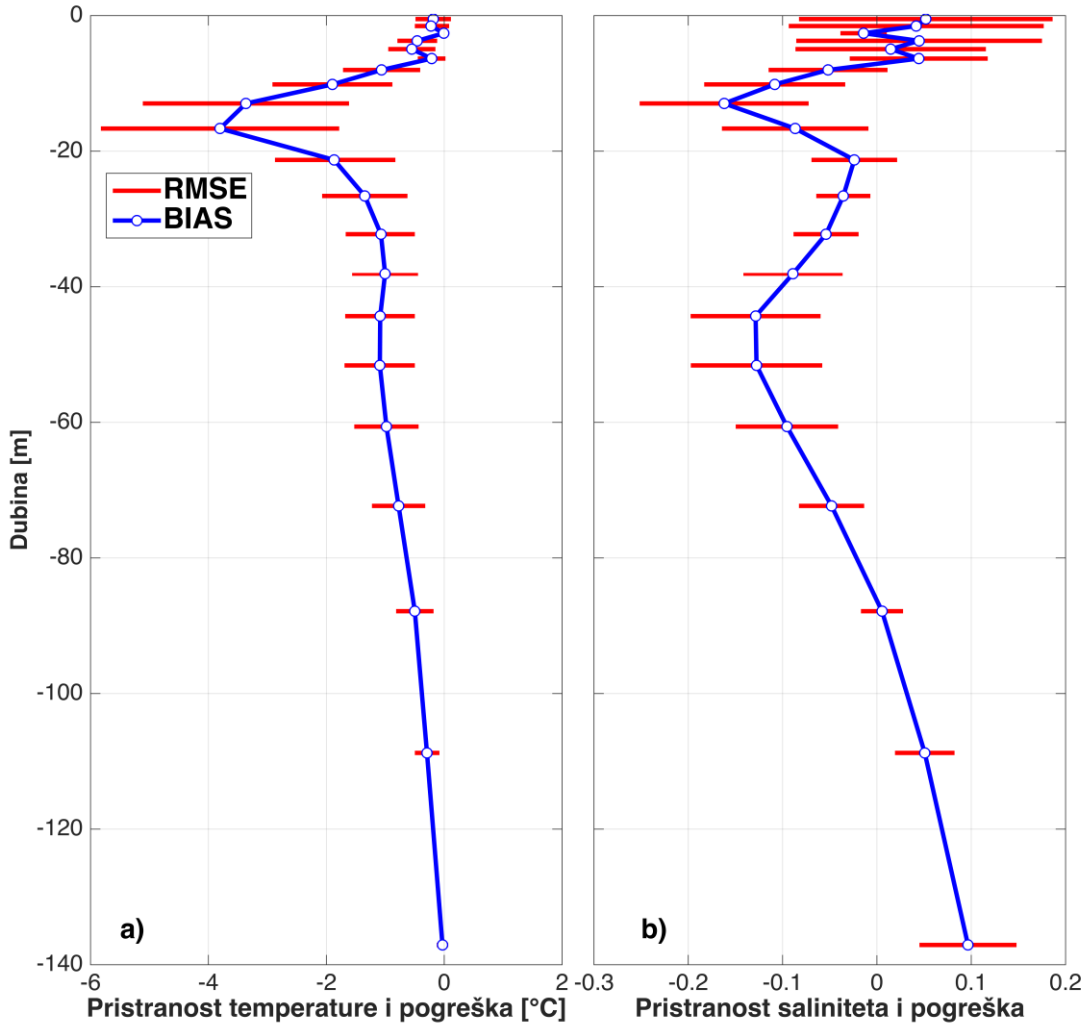

Slika 21. Vertikalni profili pristranosti (BIAS – plave vertikalne linije) i srednje kvadratne pogreške (RMSE – horizontalne crvene linije) modela za temperaturu (a) i salinitet (b). RMSE i BIAS vrijednosti su izračunate za sve vertikalne CTD profile Argo plovka u razdoblju od 19. srpnja do 2. rujna 2011. godine. Izračun je napravljen na s-nivoima ROMS modela. Donja granica profila je određena na temelju pridnene dubine mjerenja najplićeg Argo plovka u navedenom razdoblju.

Tablica 5. Iznosi pristranosti (BIAS) i srednje kvadratne pogreške (RMSE) modela za temperaturu i salinitet za svaki od 10 vertikalnih CTD profila Argo plovka u razdoblju od 19. srpnja do 2. rujna 2011. godine.

Redni broj	**Lokacija postaje**	**Datum postaje**	**RMSE (Temperatura)**	**BIAS (Temperatura [°C])**	**RMSE (Salinitet)**	**BIAS (Salinitet)**
1.	43°5’20.40” N 14°57’43.20 ”S	19. srpnja	1.459	-1.252	0.108	-0.085
2.	43°3’32.40” N 14°56’24.00 ”S	24. srpnja	1.6	-1.205	0.11	0.03
3.	43°0’01.08” N 14°53’37.68 ”S	29. srpnja	1.801	-1.067	0.082	-0.032
4.	43°56’20.40 ”N 14°44’48.48 ”S	3. kolovoza	1.502	-0.985	0.081	-0.04
5.	43°54’31.20 ”N 14°41’43.08 ”S	8. kolovoza	1.704	-1.13	0.085	-0.032
6.	43°50’48.60 ”N 14°40’54.48 ”S	13. kolovoza	1.453	-0.914	0.124	-0.085
7.	43°46’48.12 ”N 14°46’59.16 ”S	18. kolovoza	1.497	-0.882	0.334	0.14
8.	43°45’13.44 ”N 14°50’58.20 ”S	23. kolovoza	1.28	-0.819	0.113	-0.06
9.	43°43’22.80 ”N 14°53’54.24 ”S	28. kolovoza	1.203	-0.854	0.108	-0.066
10.	43°45’32.04 ”N 14°51’51.48 ”S	2. rujna	1.013	-0.749	0.111	-0.029

Verifikacija modelirane cirkulacije jadranskog bazena izvan pretpostavljenog područja putanje malih tuna napravljena je usporedbom putanje virtualnih čestica i same putanje Argo plovka (slika 19.). Virtualne čestice su ispuštane u trenutku i položaju koji je odgovarao izranjanju Argo plovka na površinu mora. Simulacije s virtualnim česticama napravljene su s ROMS i Ichthyop modelom, dok su rezultati zbog sličnosti prikazani samo za ROMS model. Ispušteno je 50 čestica za svaku lokaciju izranjanja Argo plovka, dok je radi preglednosti crtana samo jedna putanja. Najbolje slaganje modeliranih putanja i stvarne putanje je dobiveno za dubinu ispuštanja od 120 m, iako je plovak plutao na dubinama između 150 i 200 m. Virtualne čestice su praćene do 2. rujna i njihove putanje su grubo pratile putanju Argo plovka. Zbog relativno malog broja podataka o položaju Argo plovka (položaji su poznati svakih pet dana) u ocjeni realističnosti putanja nisu korištene statističke metode već vizualna procjena.

3.3.2. Rezultati lagrangeovskih izračuna

U simulacijama unazad provedeni su samo lagrangeovski pokusi s pasivnim česticama (pokusi 1., 2., 3. i 4., tablica 4.). Pokusi od 1. do 4. međusobno su se razlikovali po dubini ispuštanja čestica. Cilj pokusa je bio procijeniti mogu li čestice s lokacije ulova južno od otoka Mljeta (slika 12.) biti transportirane do područja u blizini tri promatrana uzgajališta tuna (slika 12.). Prostorne razdiobe čestica izračunate u pokusu 1. za dane 17. srpnja (slika 22.a, c, e) i 5. kolovoza 2011. godine (slika 22.b, d, f) pokazuju da su čestice nakon 28 dana, odnosno 46 dana, pristigle samo do područja u blizini uzgajališta kod otoka Brača za sva četiri raspona dubina. Do uzgajališta uz Ugljan i Giru nije došla niti jedna čestica. Navedeni datumi su odabrani jer su najmlađe uhvaćene jedinke bile stare 28 dana, a najstarije 46 dana (slika 2.). Prostorna razdioba je prikazana za 0300 UTC što je vrijeme koje odgovara završetku dnevnog perioda mrijesta. Izračun razdiobe je napravljen brojanjem čestica koje su zatečene u blizini pojedinog čvora mreže ROMS modela rezolucije 2.5x2.5 km. Područje uspjeha za simulacije unazad je definirano kao kvadrat površine 225 km^2 (6x6 ćelija domene) u sredini kojeg se nalazila lokacija uzgajališta. Zbog nejednake raspodjele kopna i mora u kvadratima uspjeha bilo je potrebno izračunati težinski faktor za svaki od tri kvadrata zasebno. Sam težinski faktor je definiran kao postotak mokrih točaka u kvadratu uspjeha za svako uzgajalište, s kojim je potom

pomnožen broj čestica koje su se našle u kvadratu uspjeha. Ukoliko se detaljnije pogleda raspodjela čestica po dubinama može se vidjeti da je 17. srpnja i 5. kolovoza u prvih 5 m vodenog stupca bilo tek 10% čestica (slika 23.a, b), koje su se zatekle u području između srednjedalmatinskih otoka (slika 23.a, b). U rasponu dubine od 5 do 15 m 17. srpnja je bilo oko 30% čestica (slika 23.a), dok je 5. kolovoza bilo 50% (slika 23.b). Glavnina čestica je bila raspoređena u području između srednjedalmatinskih otoka (slika 22.d), no pred kraj simulacije unazad došlo je do advekcije čestica prema otvorenom otvorenom moru pri čemu su čestice formirale izduženu strukturu u smjeru juga pa u smjeru jugoistoka (slika 22.c). U sloju od 25 do 35 m bilo je oko 15% čestica za oba promatrana datuma (slika 23.a, b), a prostorna raspodjela je bila slična obrascu u sloju od 5 do 15 m: 5. kolovoza su se čestice zadržale u području srednjedalmatinskih otoka (slika 22.f), da bi se 17. srpnja ponovo formirala izdužena uska struktura (slika 22.e).

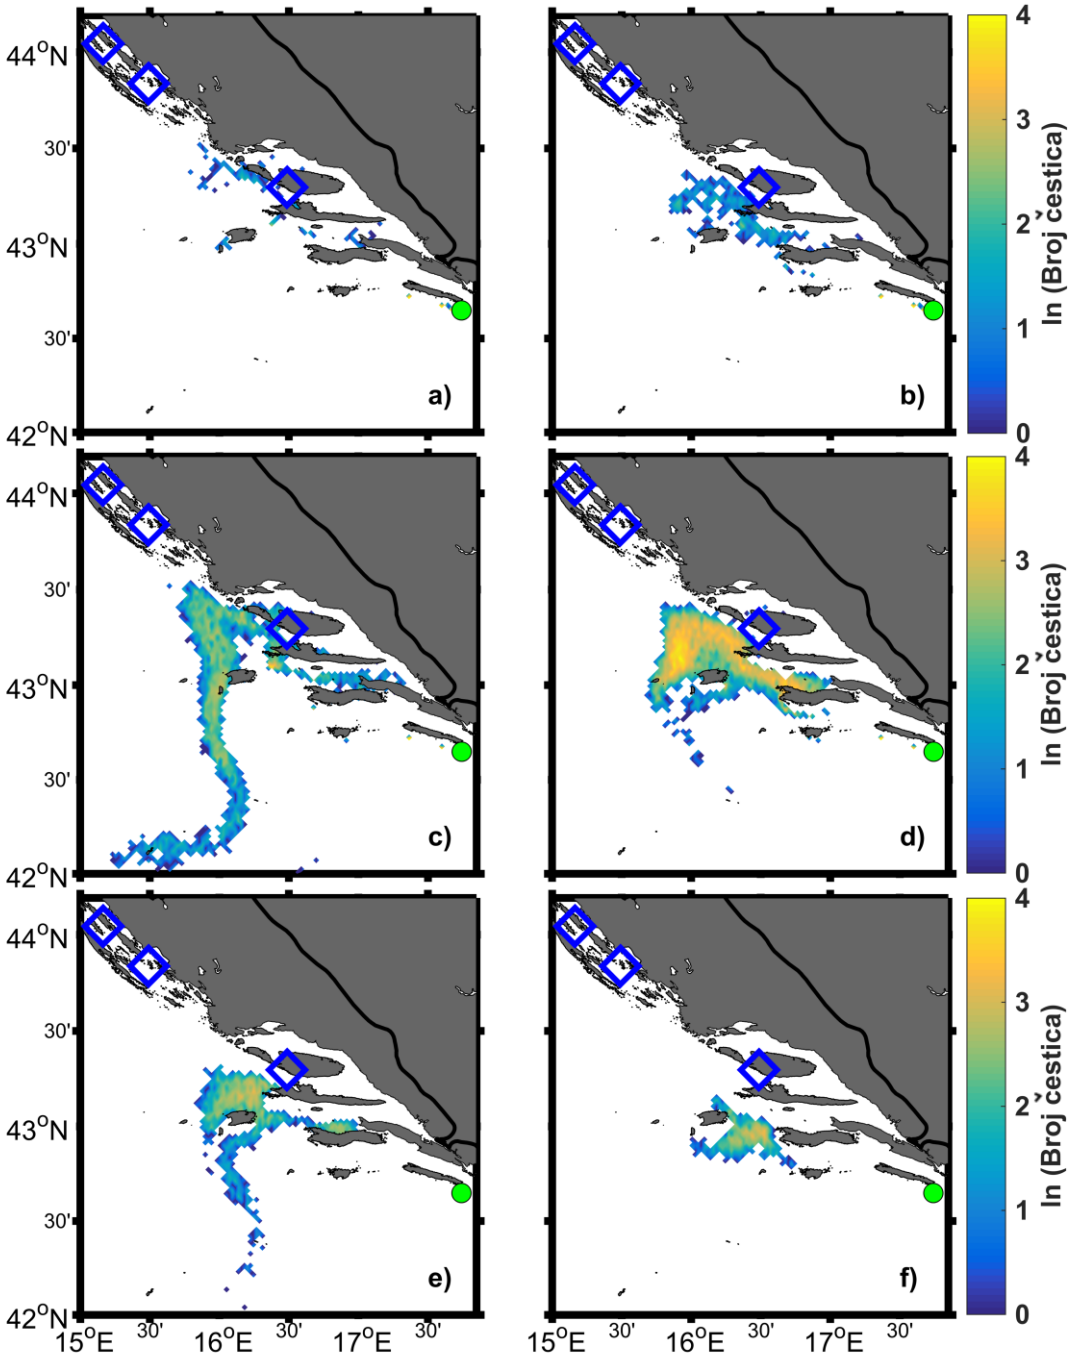

Slika 22. Prostorna razdioba čestica za pokus unazad izračunata pomoću Ichthyop modela korištenjem 20000 čestica na dane 17. srpnja (a, c, e) i 5. kolovoza 2011. godine (b, d, f). Razdioba je obuhvatila čestice na rasponima dubine od 0 do 5 m (a, b), od 5 do 15 m (c, d) i od 25 do 35 m(e, f). Izvorište čestica južno od otoka Mljeta je označeno zelenom točkom. Područja uspjeha su prikazana trima plavim kvadratima smještenim oko lokacija uzgajališta tuna (Brač, Gira, Ugljan). Prostorna razdioba je rezultat pokusa 1. (tablica 4.).

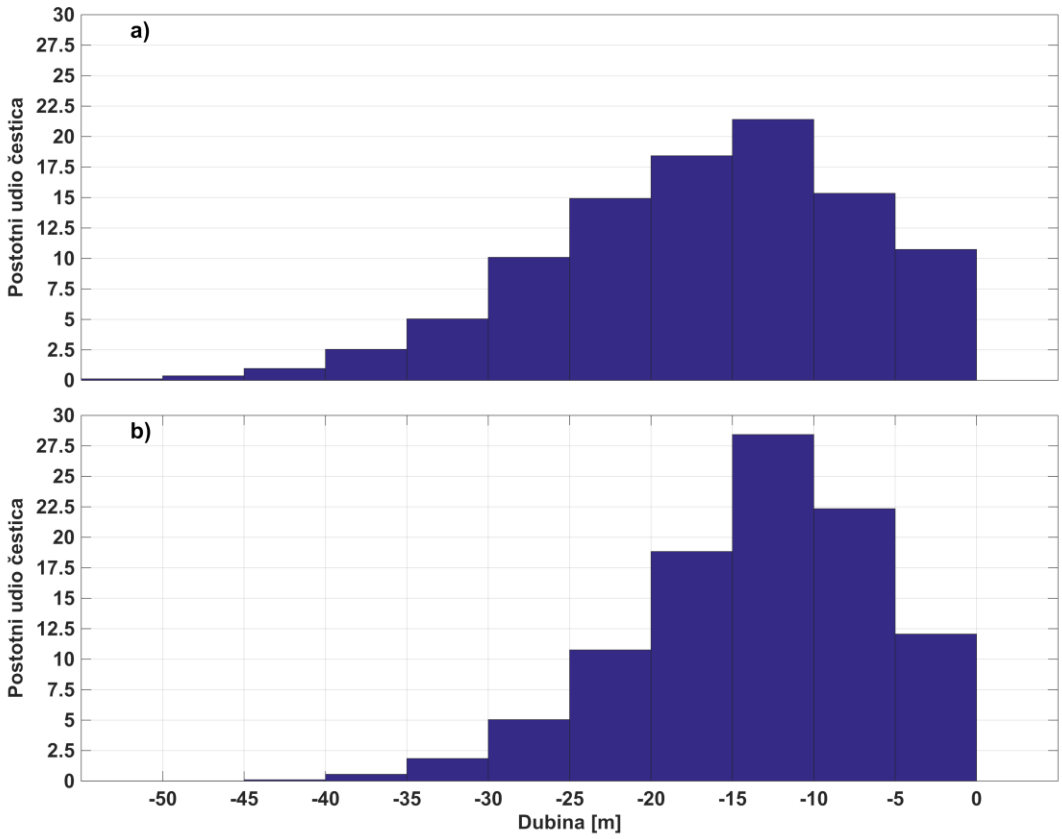

Slika 23. Raspodjela čestica po dubinama u simulaciji unazad na dane 17. srpnja (a) i 5. kolovoza 2011. godine (b) nakon što je 20000 čestica ispušteno južno od otoka Mljeta 1. rujna u pokusu 1. (tablica 4).

Kako su sve čestice na početku simulacije bile u prvih 15 m vodenog stupca, može se primijetiti tedencija tonjenja čestica prema kraju simulacije unazad: 17. srpnja je u prvih 15 m bilo 45% čestica, dok ih je 5. kolovoza bilo 60%. Ukupni broj čestica u kvadratu uspjeha oko otoka Brača je rastao prema kraju simulacije 17. srpnja (slika 24.). Porast se može objasniti povećanim transportom čestica kroz Splitska vrata, koja su obuhvaćena kvadratom uspjeha. Navedeni trend nije toliko značajan ako uzmemo u obzir ukupni broj čestica jer nikad ne prelazi iznos veći od 1% ispuštenih čestica. Pokusi u kojima su čestice ispuštane s većih dubina (pokusi 2., 3. i 4.) su rezultirali prostornom razdiobom čestica sličnoj onoj u pokusu 1., pa zbog toga nisu prikazani. Razlog za navedeno je dominantna jugoistočna struja u prvih 30 m dubine što je rezultiralo sjeverozapadnim transportom u simulacijama unazad (slika 18.).

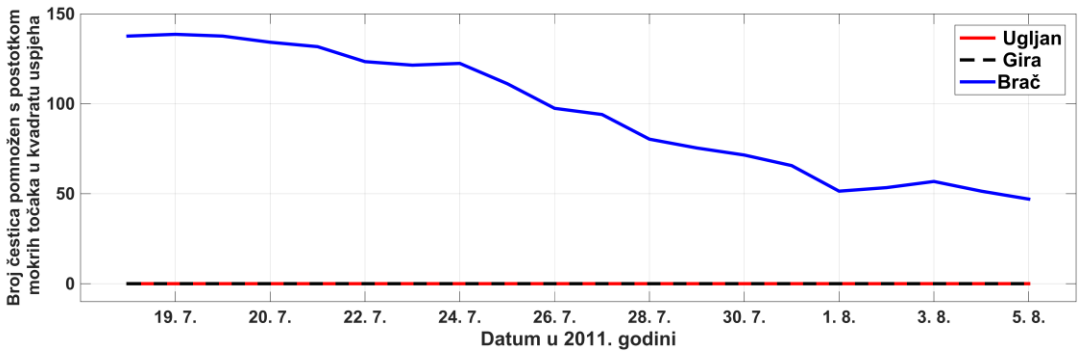

Slika 24. Vremenski niz broja čestica u simulaciji unazad unutar kvadrata uspjeha koji obuhvaća područje oko uzgajališta kod otoka Ugljana (crvena linija), otoka Gire (crna linija) i Brača (plava linija). Broj čestica je pomnožen s težinskim faktorom koji je jednak postotku mokrih točaka za svaki od tri kvadrata uspjeha. U pokusu 1 ispušteno je 1. rujna 2011. godine 20000 čestica iz točke ulova južno od otoka Mljeta.

Potvrda uloge prevladavajućeg strujanja u transportu čestica u simulacijama unazad je kvantificirana izračunom metrike kojom se lako vizualizira transport. Na srednjim dnevnim vrijednostima strujanja u Jadranskom moru dobivenim pomoću modela ROMS za dane 17. srpnja i 5. kolovoza izračunata su FTLE polja (tablica 1.) metodom unazad u vremenu za dubine od 1, 10 i 30 m (slika 25.). Metoda unazad je upotrijebljena s ciljem provjere podudaranja konvergentih područja s područjima na kojima je dobivena najveća koncentracija čestica u pokusu unazad (slika 22.). Dubine od 1, 10 i 30 m su odabrane jer se u prvih 30 m vodenog stupca tijekom cijele simulacije nalazilo preko 60% ukupnog broja čestica. Pretpostavljeno je da FTLE polje može poslužiti kao aproksimacija za cijeli raspon dubina unutar kojeg je računata koncentracija čestica. Najbolje podudaranje između privlačnih područja u FTLE polju i prostorne raspodjele čestica je dobiveno za FTLE polja izračunata na dubinama od 10 m (slika 25.c, d) i koncentracijama koje su obuhvatile čestice na dubini od 5 do 15 m (slika 22.c, d). Jedan dio čestica je 17. srpnja pratio privlačnu liniju koja se prostirala s vanjske strane srednjedalmatinskih otoka u pravcu pružanja obale, dok je drugi dio čestica na konvergentnoj liniji u smjeru juga formirao već spomenutu usku izduženu strukturu. Prevladavajući transport 5. kolovoza pratio je privlačnu liniju, koja je paralelna smjeru pružanja obale.

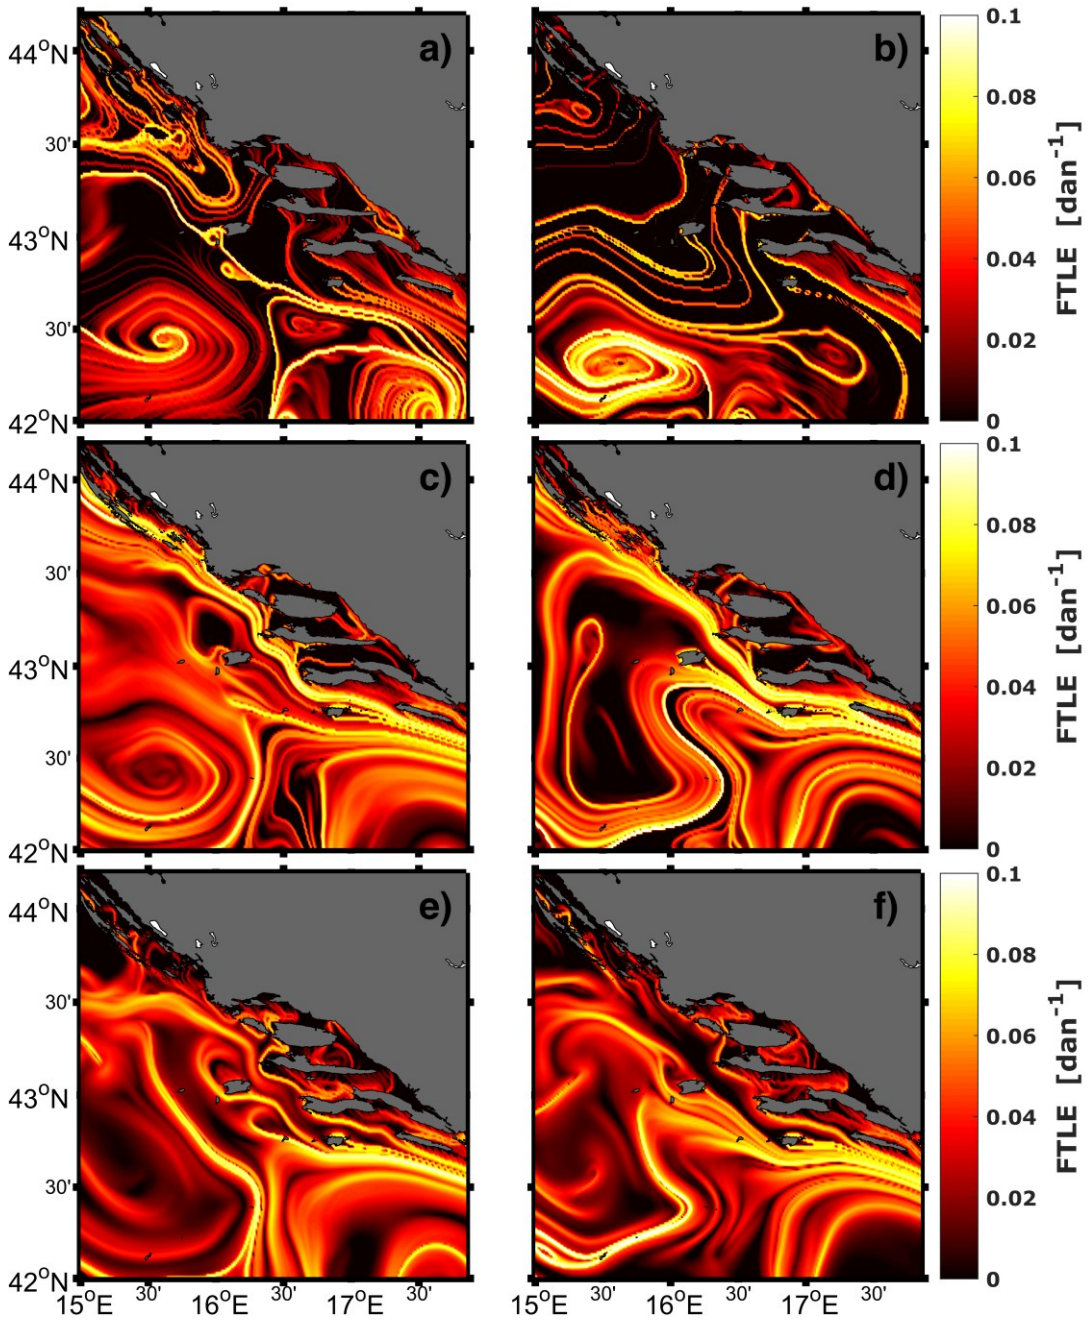

Slika 25. FTLE polje dobiveno proračunom unazad u vremenu na polju srednjeg dnevnog strujanja u moru izračunatog pomoću modela ROMS za datume 17. srpnja (a, c, e) i 5. kolovoza 2011. godine (b, d, f). Dubine na kojima je FTLE izračunat su 1 m (a, b), 10 m (c, d) i 30 m (e, f).

U pokusima unaprijed područje uspjeha je definirano kao kvadrat površine 625 km^2 s lokacijom ulova smještenom u sredini kvadrata. Veća površina kvadrata uspjeha u simulacijama unaprijed u usporedbi sa simulacijama unazad je odabrana da bi se zahvatio što veći broj čestica. Procijenjena dob uhvaćenih tuna govori da tune imaju već tad razvijenu sposobnost plivanja što im omogućava veću raspršenost u

prostoru. Na slici 26. je prikazana prostorna raspodjela čestica za datum 1. rujna 2011. godine dobivena u pokusu unaprijed u vremenu (pokus 5., tablica 4.), gdje je u razdoblju od 17. srpnja do 5. kolovoza svaki dan u 0300 UTC ispuštano po 1000 pasivnih čestica iz svakog od uzgajališta. Raspodjela pokazuje da su neke od ispuštenih čestica prispjele u kvadrat uspjeha južno od otoka Mljeta, ali samo u sloju koji obuhvaća prvih 5 m dubine (slika 26.a). U sloju koji obuhvaća raspon dubina od 5 do 15 m čestice su prispjele do sjevernih obala otoka Mljeta (slika 26.b). U prvih 5 m dubine na kraju simulacije bilo je 22% čestica, dok je u prvih 15 m bilo 42% čestica (slika 27.), što nam govori da i u simulacijama unaprijed, kao i u simulacijama unazad, imamo tedenciju tonjenja čestica. Prostorna raspodjela čestica dobivena 1. rujna je kvantificirana izračunom broja čestica u kvadratu uspjeha pri čemu se u obzir uzimala i lokacija izvorišta (slika 28.). Sve čestice koje su u pokusu unaprijed pristigle do lokacije ulova bile su podrijetlom s uzgajališta kod otoka Brača (slika 28.a), što se slaže s rezultatima pokusa unazad. Raspodjela po datumima ispuštanja (slika 28.b) pokazuje da su čestice u kvadratu uspjeha svojom dobi pokrile cijelo pretpostavljeno razdoblje mrijesta. Kao i u pokusu unazad, čestice su i u pokusu unaprijed bile nošene jugoistočnom strujom u prvih 30 m dubine. Razlog zašto čestice s uzgajališta kod Ugljana i Gire nisu dospjele do mjesta ulova je potražen upotrebom FTLE metode unaprijed u vremenu kojom su izračunate divergentne linije, zapravo barijere u transportu. FTLE polja su izračunata (tablica 1.) za polja struja na dubinama od 1, 10 i 30 m za datume 20. i 28. srpnja, 9. i 20. kolovoza 2011. godine (slika 29.). Navedene dubine su odabrane jer mogu najbolje opisati transport u kojem je više od 50% čestica bilo u prvih 30 m vodenog stupca (slika 27.). Struje za iste dubine i datume su prikazane na slici 18. U potpovršinskom sloju na dubini od 1 m tijekom cijelog razdoblja simulacije javljala se odbojna barijera koja je spriječavala transport čestica južno od otoka Šolte (slika 29., prvi stupac). Efektu blokiranja čestica sjevereno od otoka Šolte je doprinosila i barijera koja je povezivala početnu točku lociranu u području oko rta Planka sa zapadnom obalom u točki koja je oscilirala duž zapadne obale na transvezali sjevoroistok–jugozapad pritom dijeleći Jadransko more u dva dijela.

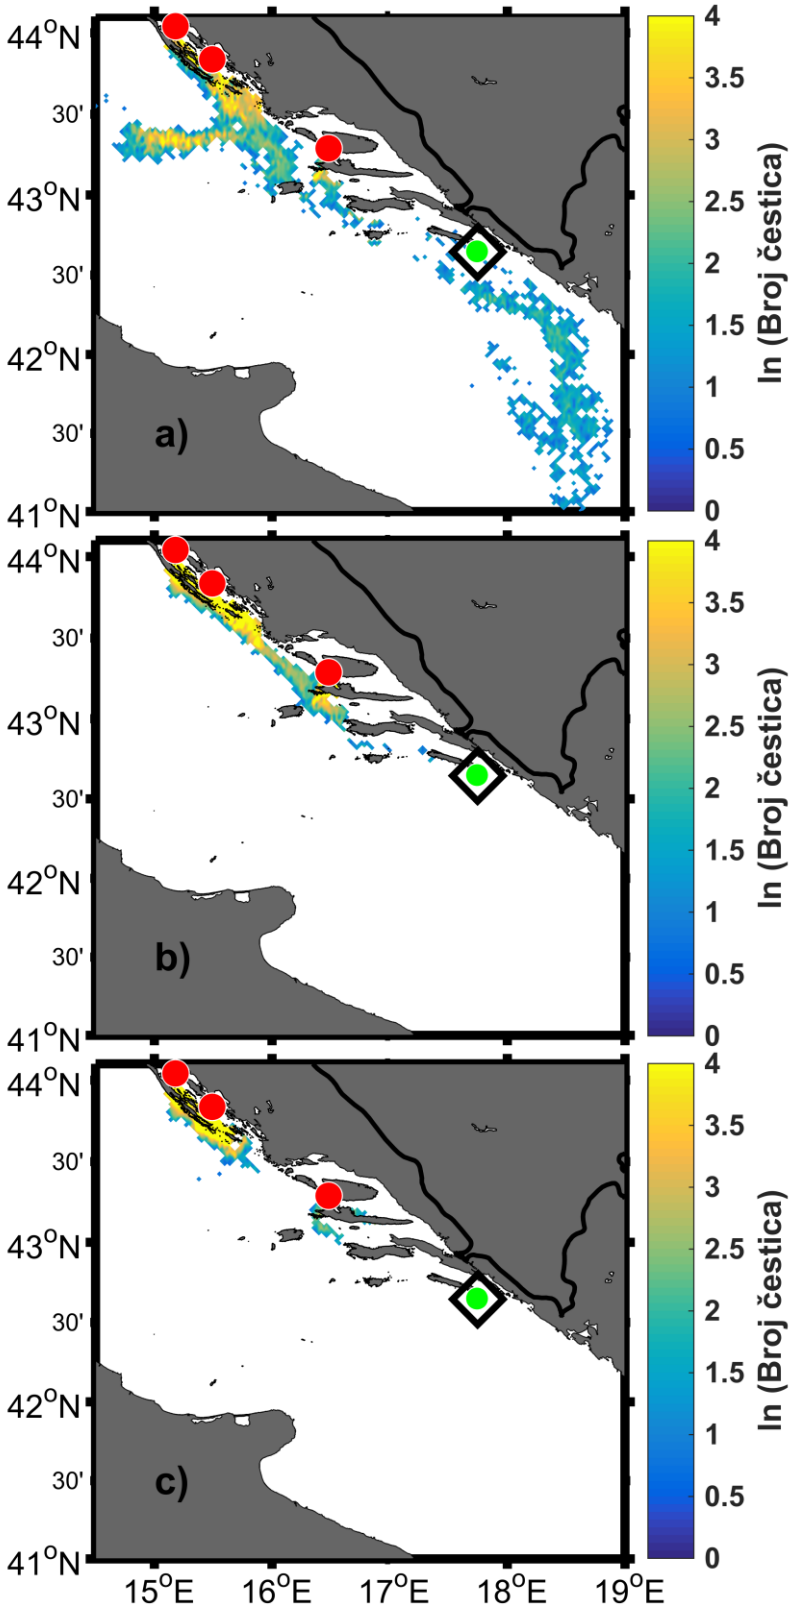

Slika 26. Prostorna razdioba čestica na dan 1. rujna 2011. godine dobivena Ichthyop modelom u pokusu unaprijed (pokus 5., tablica 4.) u kojem je 20000 pasivnih čestica ispušteno sa sve tri lokacije uzgajališta (crvene točke). Crni kvadrat predstavlja područje uspjeha oko lokacije ulova tune (zelena točka). Razdioba je izračunata za tri raspona dubina: od 0 do 5 m (a), od 5 do 15 m (b) i od 25 do 35 m (c).

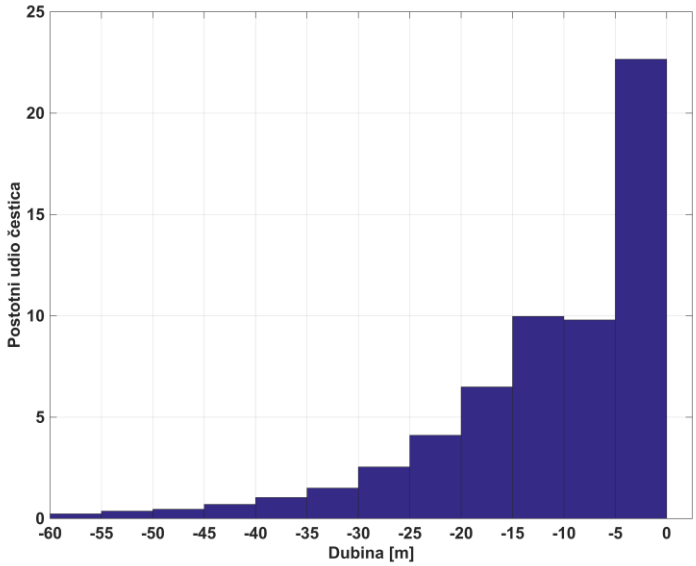

Slika 27. Raspodjela čestica po dubini u Ichthyop simulaciji naprijed 1. rujna 2011. godine za pokus 5. (tablica 2.) u kojem je u razdoblju od 17. srpnja do 5. kolovoza svaki dan u 0300 UTC ispuštano po 1000 pasivnih čestica iz svakog od uzgajališta.

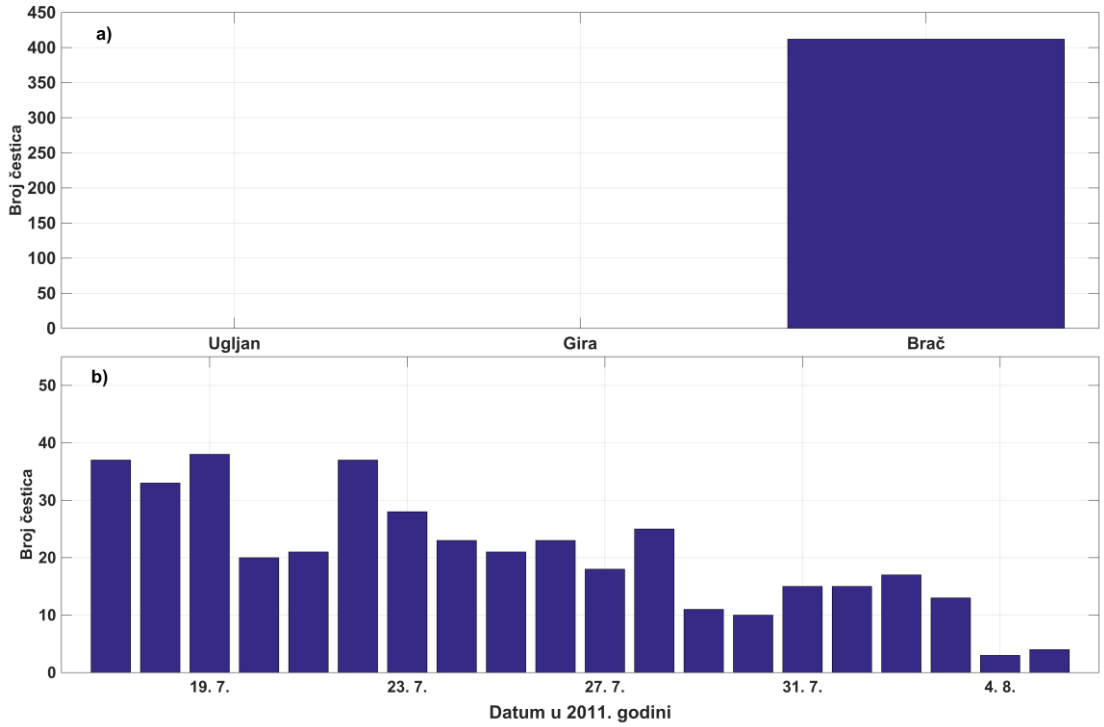

Slika 28. Ukupan broj čestica unutar kvadrata uspjeha 1. rujna 2011. godine grupiran zavisno o izvorištu i dobiven u Ichthyop simulaciji unaprijed u vremenu (pokus 5., tablica 4.) s 20000 čestica ispuštenih iz svakog od tri izvora na lokacijama uzgajališta (a). Raspodjela zavisna o dobi čestica dobivena u istom pokusu za čestice ispuštene samo s uzgajališta kod Brača (b).

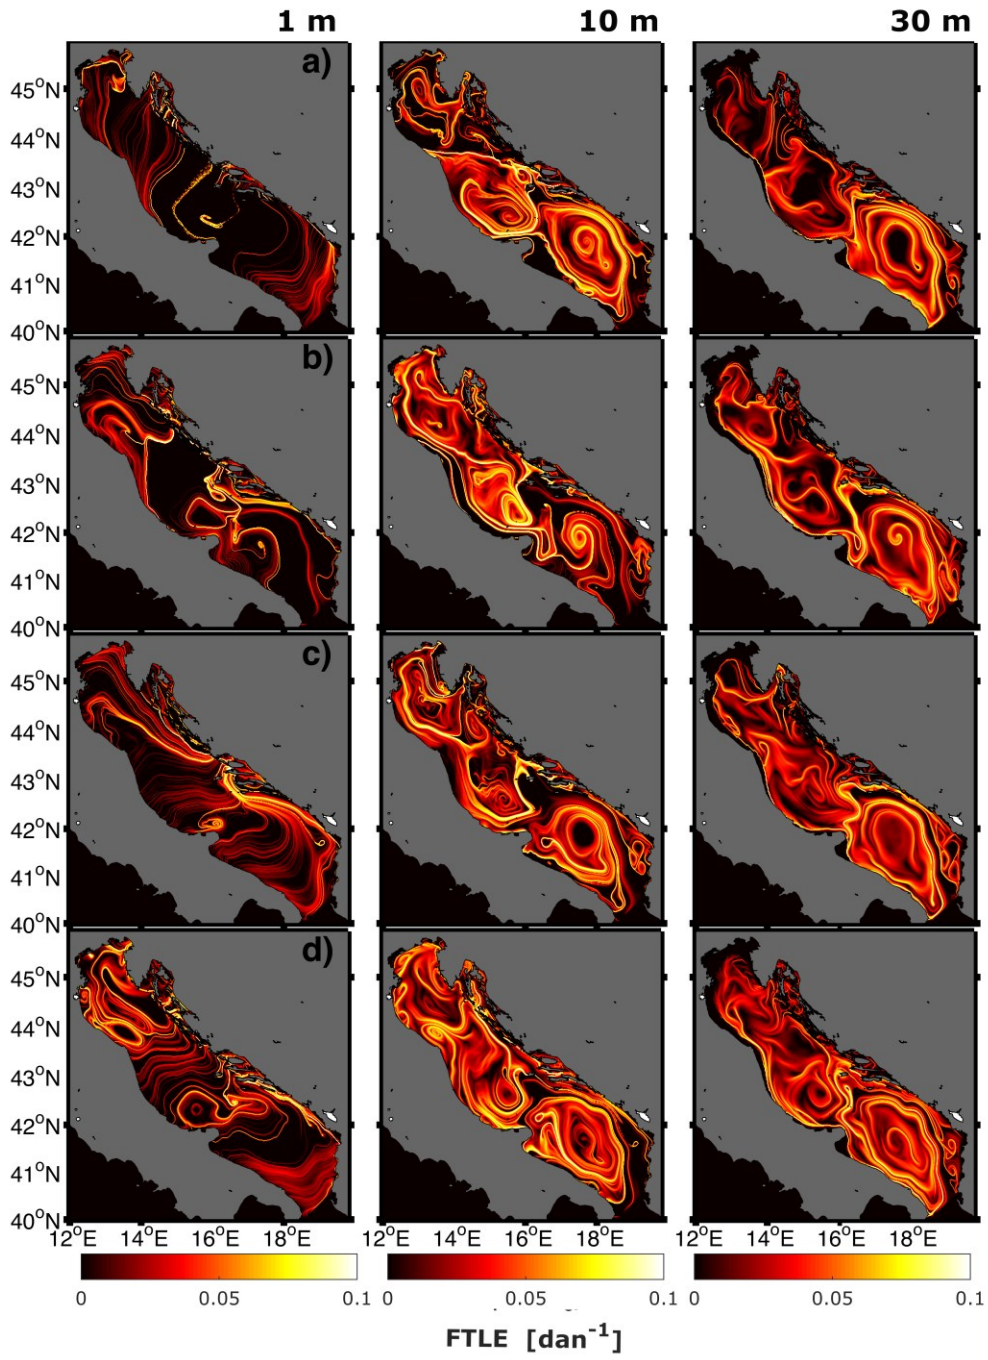

Slika 29. Polje FTLE-a dobiveno proračunom unprijed u vremenu na polju srednjeg dnevnog strujanja u moru izračunatog pomoću modela ROMS na dubini od 1 m (prvi stupac), na dubini od 10 m (drugi stupac) i na dubini od 30 m (treći stupac) za 20. srpnja (redak a), za 28. srpnja (redak b), za 9. kolovoza (redak c) i za 20. kolovoza 2011. godine (redak d).

Na području srednjedalmatinskih otoka postojala je barijera paralena s obalom, koja je kanalizirala transport čestica prema južnoj obali otoka Mljeta. Nakon prolaska te barijere čestice su se raspršile po južnom dijelu Jadranskog mora (slika 26.a). Na dubini od 10 m (slika 29., drugi stupac) pojavio se veći broja barijera.

Barijera koja je spriječavala transport južno od Šolte se pojačala, dok se barijera koja je kanalizirala transport južno od otoka Mljeta pomakla u vanjski rub južnojadranskog vrtloga. Na dubini od 30 m (slika 29., treći stupac) FTLE polje jasno pokazuje područje u kojem dominira južnojadranski vrtlog kao i područje jugozapadne struje duž talijanske obale.

Prije uvođenja opcije aktivnog plivanja čestica napravljena je procjena maksimalne udaljenosti koju u 20 dana prevale pasivne čestice (slika 29.). Pretpostavljeno je da je 20 dana period u kojem čestice ili nemaju mogućnost plivanja ili je njihova brzina plivanja nedovoljno velika u usporedbi s prevladavajućim strujanjem u okolini. Zbog toga su čestice potpuno ovisne o hidrodinamičkim uvjetima. Procjena maksimalnog dosega pasivnih čestica iskorištena je i za dodatnu analizu utjecaja odbojnih barijera u organizaciji transporta čestica. Odbojne barijere su izračunate FTLE proračunom unaprijed u vremenu na polju srednjeg dnevnog strujanja u moru izračunatog pomoću ROMS modela. Čestice su se 20 dana nakon ispuštanja u prvih 5 m dubine približile lokaciji ulova (slika 30.a), ili su došle do same lokacije ulova (slika 30.b), ili su transportirane dalje od lokacije ulova (slika 30.c). Promatranjem FTLE polja zamijećuje se organizacijska uloga odbojne barijere na dubini od 1 m, koja je djelomično skrivena česticama koje nisu raspoređene na dubini barijere već su raspoređene u prvih 5 m dubine. S povećavanjem dubine na kojoj je izračunato FTLE polje i povećanjem debljine sloja u kojem je prikazan manji broj čestica uloga odbojnih barijera u transportu postaje jasnija (slika 30.d, e, f). Čestice su kanalizirane u usko područje između odbojne barijere i vanjske obale otoka Mljeta. Na dubini od 30 m čestice ne uspijevaju izaći iz područja srednjedalmatinskih otoka (slika 30.g, h, i).

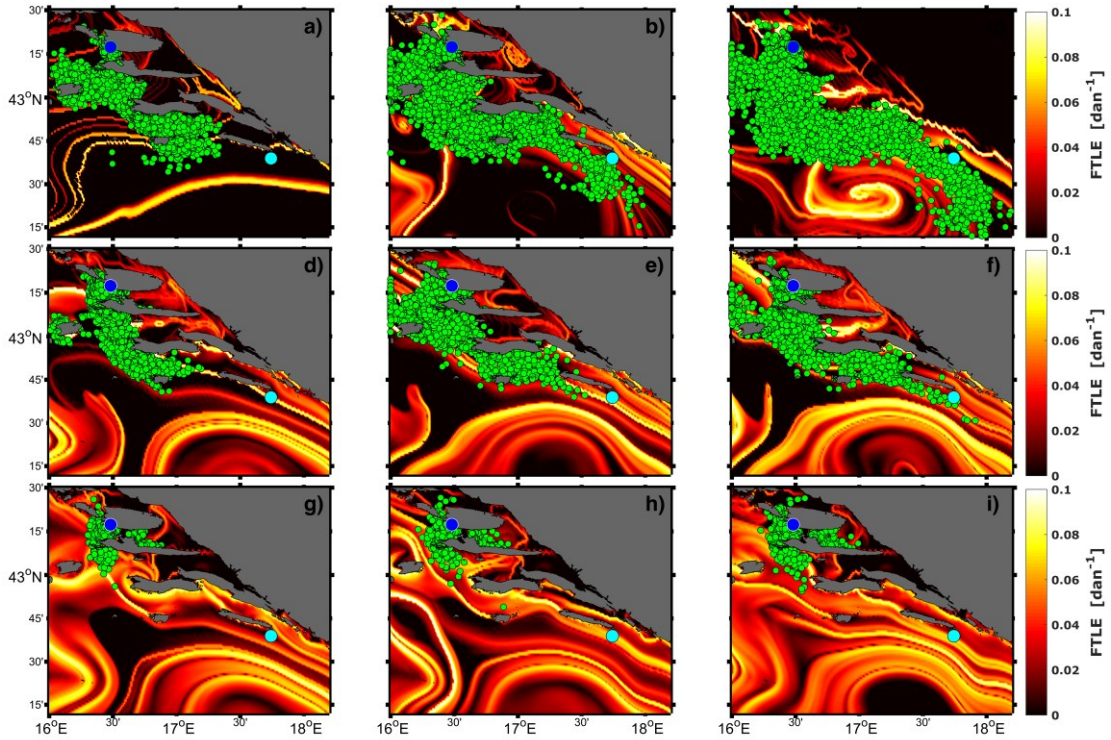

Slika 30. Položaji čestica (zeleni kružići) 20-og dana nakon ispuštanja u pokusu unaprijed (pokus 5.), ali samo za izvorište na lokaciji kod otoka Brača. Razdiobe čestica i FTLE polja prikazani su za datume: 8. kolovoza (a, d, g), 14. kolovoza (b, e, h) i 16. kolovoza (c, f, l). Dubine na kojima su prikazana FTLE polja su: 1 m (a, b, c), 10 m (d, e, f) i 30 m (g, h, i). Čestice su prikazane za raspone dubina od 0 do 5 m (a, b, c), od 5 do 15 m (d, e, f) i od 25 do 35 m (g, h, i). Plava točka označava uzgajalište kod otoka Brača, a svijetloplava točka označava lokaciju ulova kod Mljeta. FTLE polja su dobivena proračunom unprijed u vremenu na polju srednjeg dnevnog strujanja u moru izračunatog pomoću modela ROMS.

Procjena utjecaja aktivnog plivanja na transport čestica napravljena je u četiri pokusa unaprijed (tablica 4.; pokusi 6., 7., 8. i 9.). Aktivno plivanje je prvo testirano kao jedini način širenja čestica. Rezultat je pokazao da su čestice raspoređene na prostoru polumjera 50 km za brzinu plivanja od 1 duljine tijela/s (slika 31.a) i polumjera od 70 km za brzinu plivanja od 4 duljine tijela/s (slika 31.c). Kombinacija obje brzine plivanja i pasivnog transporta (pokusi 6. i 7.) je rezultirala 1. rujna prostornom distribucijom prikazanom na slikama 31.b i 31.d koja je bila slična onoj dobivenoj samo s pasivnim gibanjem (pokus 5.). Glavni razlog za tako malu razliku između razdiobe koja je rezultat pasivnog gibanja i one u kojoj je pridodana opcija plivanja je u činjenici da je smjer u kojem čestice plivaju slučajno odabran u svakom vremenskom koraku simulacije.

Hipoteza transporta čestica iz Ionskog mora prema lokaciji ulova testirana je u pokusu 10. (tablica 4.). Čestice su ispuštene s četiri lokacije smještene tako da ravnomjereno pokriju južni rub domene u Otrantu (slika 12.). Na kraju simulacije sve su čestice bile transportirane izvan domene modela prema Jonskom moru prevladavajućom jugoistočnom strujom (navedeni rezultat nije prikazan grafički).

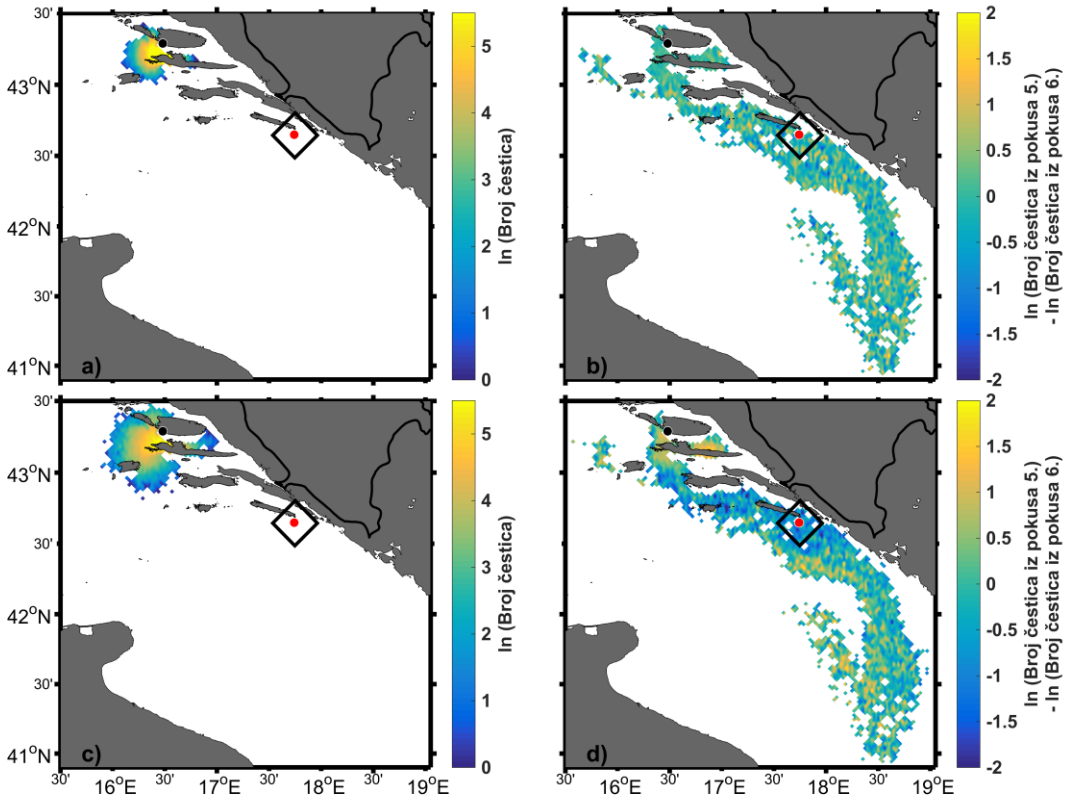

Slika 31. Prostorna razdioba čestica 1. rujna 2011. godine dobivena u Ichthyop pokusima unaprijed s 20000 čestica koje su ispuštene s lokacije uzgajališta kod otoka Brača (crna točka) i imale su samo mogućnost plivanja gdje je brzina iznosila 1 duljinu tijela/s (a) odnosno 4 duljine tijela/s (c). Razlika između prostorne razdiobe dobivene u Ichthyop pokusu unaprijed s 20000 čestica koje su ispuštene s lokacije uzgajališta kod otoka Brača (crna točka) na čiji su transport utjecale samo difuzija i advekcija (pokus 5.) i onih na čiji su transport utjecali advekcija, difuzija i aktivno plivanje (pokus 6.), pri čemu je brzina plivanja iznosila 1 duljinu tijela/s (b) odnosno 4 duljine tijela/s (d).

3.4. Diskusija

U fluktuirajućem ekosustavu kao što je more, održivost ribljih populacija usko je povezana s njihovom uspješnom reprodukcijom te novačenjem. Za unapređenje zakonske regulative i nadzora pojedinih ribljih populacija potrebno je poznavanje ekološki važnih područja za rane razvojne stadije (područja mrijesta i područja odrastanja).

Slučajni ulov malih tuna u rujnu 2011. godine u južnom dijelu Jadranskog mora je otvorio pitanje mogućeg mrijesta tune u Jadranu. Uz znanstvenu važnost, striktna zakonodavna regulacija uzgajanja i lova tune je bila dodatna motivacija u istraživanju.

Glavni cilj ovog istraživanja je bio otkriti podrijetlo malih tuna uhvaćenih u južnom Jadranu, procijeniti utjecaj dinamike morskog strujanja na transport i utvrditi ulogu koherentih struktura u organizaciji transporta čestica. Detaljniji opis biološke komponente multidisciplinarnog istraživanja koje je obuhvaćalo obradu ribarskih podataka, genetičku i fenotipsku analizu može se pronaći u radu Džoić i sur. (2017), dok je u doktoratu stavljen naglasak na analizu meteoroloških i oceanografskih uvjeta, istraživanje numeričkim i lagrangeovskim metodama dinamike ranih stadija tune korištenjem uparenog modelskog sustava ROMS-Ichthyop. Sličan pristup u kojem se kombinira genetska analiza s modeliranjem cirkulacije je korišten u istraživanju panatlantske povezanosti ugroženih zelenih kornjača (Naro-Maciel i sur., 2017).

Fenotipske analize napravljene na uhvaćenim tunama (odnos između ukupne duljine tijela i duljine od usta do sredine repne peraje ribe, pozitivan alometrijski rast) su bile u skladu s prije publiciranim podacima (Mesa i sur., 2005), dok je procijenjena starosna dob od oko 30 dana upućivala na mogući mrijest u Jadranu. Postoji nekoliko područja na kojima je bio moguć mrijest tune. Najbliže poznato područje mrijesta tune u divljini je istočna obala Sicilije (Corriero i sur., 2005; Druon i sur., 2016). Prosječna površinska brzina za kolovoz 2011. godine u iznosu od 20 cm/s između istočne obale Sicilije i mjesta ulova izračunata je pomoću mediteranskog modela (slika 32.). Pretpostavljajući da je ta brzina pratila cijelo vrijeme putanju tune i uvažavajući činjenicu da tuna 20 dana nakon mrijesta može plivati brzinom koja iznosi 8 cm/s, odnosno nakon 48 dana brzinom od 15 cm/s, tuna u 35 dana može, uz povoljne uvjete i pretpostavku da se giba približno pravocrtno, prevaliti 700 km

udaljenosti od istočne obale Sicilije do lokacije ulova. No, argument koji eliminira obalu Sicilije kao moguće područje mrijesta je ka jugu usmjerno površinsko strujanje dobiveno mediteranskim modelom i jadranskim ROMS-om čija su polja korištena u proračunima disperzije modelom Ichthyop. To je potvrđeno i transportom svih čestica ispuštenih u Otrantskim vratima u Ichthyop simulaciji u smjeru Ionskog mora umjesto prema lokaciji ulova. Kako je prirodni mrijest divlje tune u Jadranskom moru veoma diskutabilan, pretpostavljeno je da su se tune izmrijestile u jednom od uzgajališta smještenih duž istočne obale Jadrana sjeverno od lokacije ulova. Nakon mrijesta, tune su bile nošene jugoistočnom strujom 20 dana. Nakon 20 dana razvile su sposobnost samostalnog kretanja/plivanja i bile su nezavisne o hidrodinamici okoline (Mather i sur., 1995) što im je omogućilo da dođu na lokaciju ulova unutar svoje procijenjene dobi.

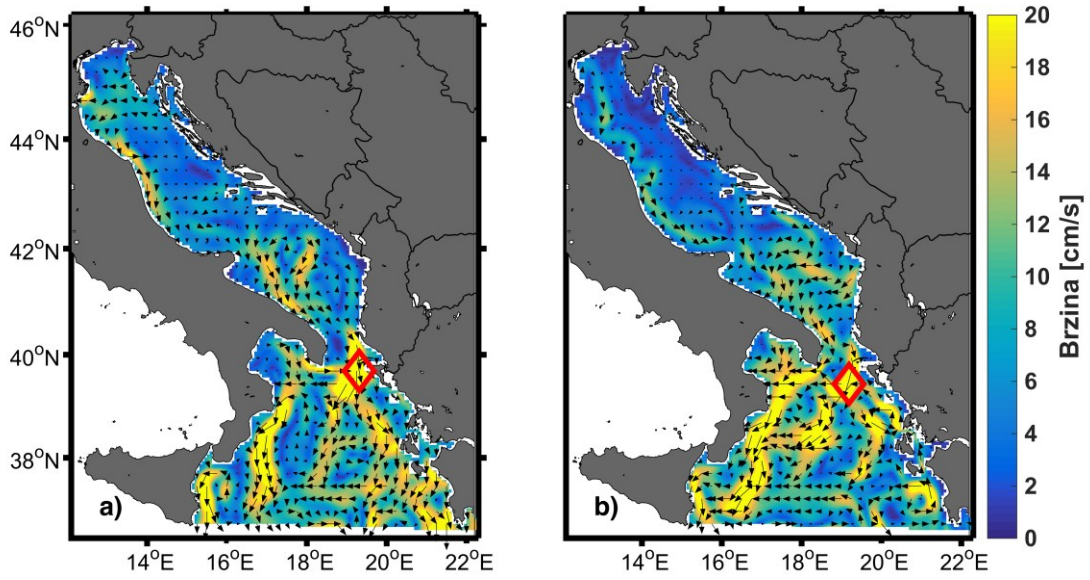

Slika 32. Srednje dnevno strujanje mora na dubini od 1 m izračunato mediteranskim modelom (http://marine.copernicus.eu) za 23. srpnja (a) i 19. kolovoza 2011. godine (b). Vektori su crtani za svaku četvrtu točku. Crveni kvadrat označava područje s najvećim iznosom brzine za navedeni datum.

Numerički modelski sustav, koji se sastojao od hidrodinamičkog modela ROMS i IBM modela Ichthyop, omogućio je testiranje hipoteze mrijesta u uzgajalištima. Slični modelski sustavi s hidrodinamičkim i IBM modelima su često korišteni za simulaciju dinamike ranih razvojnih stadija mnogih vrsta (srdela, inćun), dok su za tunu objavljeni radovi u kojima je korišteno modeliranje dinamike IBM

modelom iznimno rijetki. Prema dostupnoj literaturi ovo istraživanje je prvi pokušaj numeričkog modeliranje dinamike ranih stadija tuna u Jadranskom moru.

Korištenjem satnih izlaznih polja ROMS modela s horizontalnom rezolucijom od 2.5 km očuvani su svi bitni fizikalni procesi u Jadranu (Putman i He, 2013). Uzimajući u obzir kompleksnu topografiju, dodatna poboljšanja mogu biti napravljena za simulacije duž istočne obale Jadranskog mora korištenjem finije prostorne rezolucije i procedura gniježđenja (Orlić i sur., 2006a). Zbog nedostatka informacija i znanja o procesima vezanim uz rane stadije tuna, u numeričkim simulacijama je uvedena pretpostavka da su čestice pasivni plivači cijelo vrijeme. Uvođenje dodatnih procesa zavisnih o dobi i stadiju u razvoju tune (jaja, larve) poput uzgona, dnevno-noćne vertikalne migracije, zavisnosti rasta jedinki i smrtnosti o temperaturi mora bi najvjerojatnije povećalo točnost rezultata modela i pouzdanost rezultata. Neki od tih procesa su već uključeni u Ichthyop simulacije, iako su potrebne parametrizacije napravljene na temelju istraživanja provedenih u područjima izvan Jadranskog mora. Uvođenje dnevno-noćne migracije u Ichthyop simulacije rezultiralo je gomilanjem čestica duž zapadne obale Jadranskog mora u pokusima unaprijed. U budućim simulacijama nužna je bolja parametrizacija procesa dobivena u laboratirijskim i terenskim istraživanima u Jadranu. Podaci putanje Argo plovka su korišteni u istraživanju s ciljem verifikacije modelirane cirkulacije. Argo plovak je cijelo vrijeme bio u Jabučkoj kotlini, i njegova putanja poslužila je za verifikaciju strujanja na otvorenom moru, ali nije mogla poslužiti za procjenu povezanosti između lokacije ulova i pretpostavljenih lokacija mrijesta jer se nalazila daleko od pretpostavljene putanje tuna (Fossette i sur., 2012).

Ovo istraživanje pokazuje važnost točno simuliranih fizikalnih polja, posebice polja struja koje su odgovorne za transport tuna u ranim stadijima. Realistične numeričke simulacije objelodanile su obrat struja duž istočne jadranske obale, od uobičajenog sjeverozapadnog smjera strujanja na jugoistočni. Obrat je već ranije uočen u mjerenjima morskih struja (Zore Armanda, 1968; Andročec i sur., 2009; Vilibić i sur., 2009) i rezultatima modela (Orlić i sur., 2006a) u ovom području za vrijeme ljetnog razdoblja. U radu Vilibića i sur. (2009) u srpnju 2006. godine na strujomjerima postavljenim duž istočne obale Jadranskog mora u blizini Lastova zabilježen je obrat struja. Obrat struja je trajao nekoliko dana i zabilježen je u cijelom vodenom stupcu. Geostrofičke struje izračunate iz podataka temperature i saliniteta mjerenih na palagruškom transektu u razdoblju od 1957. do 2010. godine također su

pokazale obrate struja (Vilibić i sur., 2015). Obrati duž cijelog vodenog stupca su trajali nekoliko tjedana, a bivali su sve slabiji idući prema zapadnoj obali. Utjecaj obrata nikad nije proučavan u disperzijskim simulacijama s ciljem analize povezanosti područja i njegovog utjecaja na morsku ekologiju. Studije povezanosti su se dosad u Jadranu provele na dekadalnim vremenskim nizovima za područje cijelog bazena (Bray i sur., 2017; Melià i sur., 2016). Bez jugozapadnog strujanja, jaja i larve tuna ne bi bile transportirane južno prema lokaciji ulova. S uobičajenim sjeverozapadnim strujanjem, male tune bi bile transportirane sjeverno od uzgajališta tuna u srednjem Jadranu i pitanje je da li bi mogle preživjeti u sjevernom obalnom području Jadrana. Kvalitetna reprodukcija temperaturnog polja je također bitna ako uzmemo u obzir da je početak mrijesta vezan uz temperaturne uvjete (Gordoa i Carreras, 2014).

Lagrangeovske koherentne strukture pokazale su se ne samo kao iznimno korisna dijagnostička metrika, koja otkriva pozadinsku strukturu cirkulacije, već i kao praktičan alat koji otkriva zavisnost dinamike transporta larvi o kinematičkom okviru u kojem se nalazi (Harrison i sur., 2013). Proučavanje utjecaja privlačnih odnosno odbojnih struktura u strujanju fluida na transport larvi je novo znanstveno područje koje dosad nije korišteno u istraživanju u Jadranskom moru. Primjena LCS-ova u proučavanju disperzije se dosada uglavnom koncentrirala na transport vezan uz polutante i biologiju (d'Ovidio i sur., 2010; Huhn i sur., 2012). Primjena FTLE metode za detekciju LCS-ova u Jadranu otkrila je obrasce koji utječu na transport čestica. Odbojne barijere su spriječavanjem transporta podijelile Jadran na južni i sjeverni dio, dok su uz istočnu obalu bile rubovi kanaliziranog transporta čestica prema jugu. Privlačne barijere su se pokazale kao mjesta konvergencije i ukazale su na obrazac advekcije čestica prema otvorenom moru.

Rezultati numeričkih simulacija Ichthyop modelom, orijentiranih i unaprijed i unazad u vremenu, su pokazali da su uzgajališta u srednjem Jadranu moguće lokacije mrijesta. Uzgajalište tuna kod otoka Brača je bilo najvjerojatnije mjesto podrijetla uhvaćenih jedinki. Zbog prisutnosti vrtloga u srednjem Jadranu, pasivne čestice u pokusima unazad nisu mogle prići uzgajalištima kod Gire i Ugljana. Time su navedena uzgajališta eliminirana kao moguće lokacije mrijesta uhvaćenih jedinki unatoč tome što je na Ugljanu zabilježen mrijest u kavezima (Grubišić i sur., 2013). Pokusi unaprijed su pokazali da čestice ispuštene s lokacije kod Brača mogu prići na udaljenost od 20 do 50 km do mjesta ulova 20 dana nakon ispuštanja bez obzira na

datum samog ispusta. Ovi rezultati potvrđuju da je dominantni smjer strujanja najvažniji čimbenik koji je igrao ulogu u transportu malih tuna do mjesta ulova. Zavisnost o datumu i vremenu ispusta u ovom slučaju nije imala značajnu ulogu u transportu (Putman i sur., 2016). Pasivni transport uzrokovan samo strujama kojem je pridodano plivanje sa slučajno odabranim smjerom nije bio najbolji izbor. No, u nedostatku boljih parametrizacija plivanja i boljeg poznavanja plivanja tuna, isti je korišten u proučavanje dinamike ranih stadija tune. Potrebno je uzeti u obzir da je pomak izračunat na taj način bio najsporiji i u većini slučajeva zanemariv naspram maksimalnog pomaka do kojeg bi došlo u slučaju podudaranja smjera strujanja i plivanja. Uvažavanjem hipoteze da je uzgajalište kod Brača lokacija mrijesta, imamo vrijedan materijal za buduće testiranje poboljšanja u numeričkim modelima. Rijetka je prilika imati točne lokacije mrijesta. U većini slučajeva nemamo točnu lokaciju gdje se mrijest mogao dogoditi, već je područje mrijesta definirano kao veće područje s visokom vjerojatnošću mrijesta na temelju višegodišnjih istraživanja. Dobro definirana lokacija mrijesta daje veću pouzdanost u ocjeni rezultata i hidrodinamičkog i IBM modela.

4. DISPERZIJA IHTIOPLANKTONA KOMARČE U JADRANSKOM MORU

4.1. Motivacija za istraživanje

Komarča (*Sparus aurata*) je danas najvažnija riba u uzgoju na području Sredozemnog mora (Trujillo i sur., 2012). U prirodi obitava najviše u obalnim vodama i estuarijima. Mlađ odrasta u lagunama i estuarijima, a potom se širi duž obale i između otoka (Glamuzina i sur., 2014). U Hrvatskoj je u proteklih deset godina proizvodnja komarče porasla za 65%, pri čemu godišnja proizvodnja iznosi 3640 tona (FEAP, 2015). Zbog nedovoljne domaće proizvodnje mlađi komarče, više od 70% potražnje se uvozi iz uzgajališta u Sredozemnom moru u kojima dominiraju jedinke podrijetlom iz Atlantskog oceana (Šegvić-Bubić i sur., 2014).

U zadnjih nekoliko godina uočen je značajan porast u populaciji divlje komarče u obalnim područjima Jadrana (Glamuzina i sur., 2014; Šegvić-Bubić i sur., 2014). Dosadašnja istraživanja taj porast pripisuju razvoju marikulture, osobito povećanju broja uzgajališta komarče, ali i trendu globalnog zatopljenja koji pogoduje suptropskim vrstama u koje spada i komarča.

Pretpostavka je da nagli porast broja uzgajališta doprinosi povećanju populacije komarče ne samo bijegom ribe iz kaveza već i transportom njenih jaja u okolna područja koja su oplođena unutar kaveza nakon mrijesta koji se dogodio unutar njih (Šegvić-Bubić i sur., 2014; Somarakis i sur., 2013). Izbjegle komarče iz uzgajališta mogu utjecati na divlje populacije predacijom, natjecanjem za hranu, stanište i mogućnost mrijesta, širenjem parazita i bolesti te križanjem s divljim primjercima (Grigorakis i Rigos, 2011; Jonsson i Jonsson, 2006).

I druge komponente marikulture utječu na populaciju komarči pa su obilne i sezonski stabilne agregacije komarče uočene u blizini uzgajališta tuna kod otoka Brača i Ugljana (Stagličić i sur., 2017). Uzgajališta školjaka su također značajan izvor hrane za komarče pa su duž cijele jadranske obale prijavljene velike štete na uzgajalištima školjaka upravo zbog povećanja populacije komarči (Šegvić-Bubić i sur., 2011; Glamuzina i sur., 2014).

Trend zatopljenja u iznosu od 0.035 ± 0.007 °C/god Sredozemnog mora (Shaltout i Omstedt, 2014) uzrokovan globalnim zatopljenjem pogoduje komarči, koja

ima afinitet spram toplijih mora (Sabates i sur., 2006; Bianchi i Morri, 2000). Može se reći da komarča iskorištava klimatske promjene koje povećavaju šansu preživljavanja temperaturno osjetljivih larvi, što pogoduje novačenju i samim time povećanju populacija koje se mogu širiti na nova sjevernija staništa (Avignon i sur., 2017).

Opsežna uzorkovanja različitih stadija komarči provedena su od srpnja 2015. godine do rujna 2016. godine duž istočne jadranske obale s ciljem rasvjetlavanja uzroka povećanja populacije divlje komarče. Jedan od ciljeva istraživanja bio je odrediti porijeklo mlađi komarče ulovljene 15. svibnja 2016. godine na ušćima Neretve, Raše i Rike (močvara Pantan). Uočena genetska sličnost između mlađi ulovljene na ušćima triju rijeka s roditeljima uhvaćenim oko uzgajališta tuna kod otoka Brača i Ugljana (rad u pripremi za objavu) omogućava postavljanje hipoteze o povezanosti lokacija na kojima dolazi do mrijesta komarče i lokacija prirodnih rastilišta ranih stadija za tu vrstu, to jest lokacija na kojima jedinke odrastaju. Hipoteza o hidrodinamičkoj povezanosti ima posebnu težinu jer se promatra u iznimno dinamički kompleksnom području obalnog dijela istočnog Jadranskog mora. Dinamička kompleksnost proizlazi iz veoma raznolike topografije tog dijela Jadrana koja uključuje veliki broj otoka, kanala, zaljeva i uvala, prisustnost rijeka te veoma jak utjecaj meteoroloških čimbenika osobito vjetra. Razdoblje u kojem se promatrao transport ranih razvojnih stadija komarči (1. siječnja - 15. svibnja 2016. godine) je meteorološki karakteriziran snažnim vjetrovima (Meteorološki bilten 01/2016; 02/2016; 03/2016) koji direktno utječu na strujanje u moru, a samim time i na transport.

Korištenje uparenog modelskog sustava, istog kao i u prethodnom poglavlju doktorata, otvara mogućnost da se napravi kvantintativna i kvalitativna analiza transporta između početne (uzgajališta na Braču i Ugljanu) i kranje točke (ušća rijeka Raše, Neretve i Pantana) u disperzijskoj simulaciji. Istraživanje bi također moglo dati odgovor na pitanje postoji li korelacija između genetske i transportne povezanosti. Spoznaje dobivene ovom analizom mogle bi pomoći u kvalitetnijem proučavanju utjecaja ribljih uzgajališta na domaće vrste u Jadranskom moru.

4.2. Opis modelskog sustava

Provjera hipoteze hidrodinamičke povezanosti lokacija na kojima je uhvaćena mlađ komarče (Pantan, Neretva, Raša) (slika 33.) i lokacija na kojima su uhvaćeni roditelji komarči (Brač, Ugljan) napravljena je korištenjem uparenog modelskog sustava koji se sastojao od oceanografskog modela ROMS i disperzijskog individualno temeljenog modela Ichthyop. Modelski sustav sličan onom opisanom u potpoglavlju 3.2. korišten je i u simulacijama disperzije ihtioplanktona komarče. Pored iste jadranske domene s rezolucijom od 2.5 km, ovdje je zbog analize povezanosti u dinamički kompleksnom području istočnog obalnog dijela Jadranskog mora upotrijebljena i ASHELF-2 domena s rezolucijom od 1 km (slika 33.) .

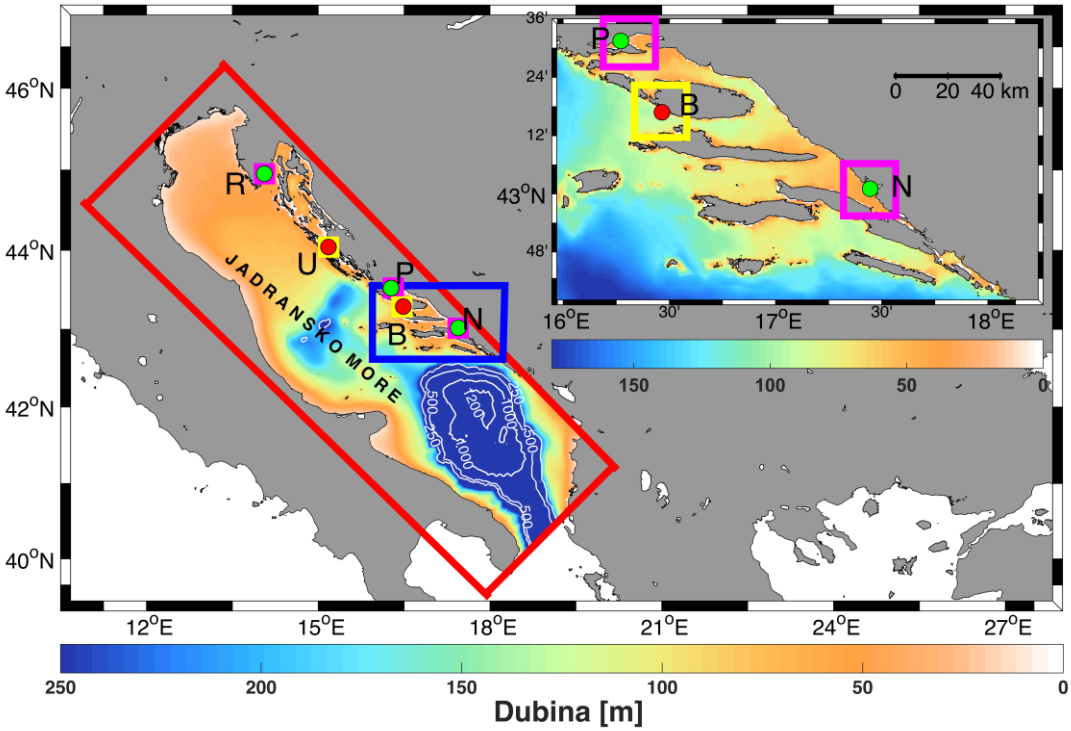

Slika 33. Batimetrija Jadranskog mora s lokacijama prirodnih područja rastilišta ranih stadija za komarču (zelene točke) (R – Raša, P – Pantan (ušće Rike), N – Neretva) i lokacijama uzgajališta tuna (crvene točke) (U – Ugljan, B – Brač). Crveni kvadrat označava jadransku modelsku domenu, dok plavi kvadrat označava ASHELF-2 domenu. Batimetrija ASHELF-2 domene je detaljnije prikazana u gornjem desnom kutu na slici. Ružičasti kvadrati oko lokacija rastilišta ranih stadija su područja uspjeha u simulacijama unaprijed, dok su žuti kvadrati oko lokacija uzgajališta područja uspjeha u simulacijama unazad.

Za razdoblje od 1. siječnja do 15. svibnja 2016. godine u obje domene modela ROMS su izračunate srednje satne vrijednosti morskih struja, temperature i saliniteta. Vremenski korak u jadranskim simulacijama je iznosio 900 sekundi, dok je u ASHELF-2 simulacijama iznosio 1200 sekundi. Odabir vremenskog koraka je napravljen u skladu s CFL kriterijem kao i u potpoglavlju 3.2. U parametrizaciji ponašanja čestica pri nailasku na obalu su upotrijebljene dvije opcije. Opcija odbijanja čestice od obalne linije je iskorištena u početnim izračunima za dobivanje cjelovitije slike lagrangeovske disperzije zadržavanjem svih čestica u proračunu. Opcija naplavljivanja čestica povećala je realističnost simulacija i to za čestice koje su dospjele u područje uspjeha, kao i za one izvan tog područja. Uvažavanje naplavljivanja čestica na obale izvan područja uspjeha eliminira čestice u daljnjem disperzijskom izračunu, te time simulira zadržavanje ribljeg ihtioplanktona u području koje je nepogodno za daljnji razvoj. Kod naplavljivanja unutar područja uspjeha uklonjena je mogućnost transporta čestica izvan područja uspjeha u sljedećem vremenskom koraku i na taj način je simulirano zadržavanje ribljeg ihtioplanktona u biološki povoljnom području rastilišta u boćatim područjima koja se protežu duboko u kopno i nisu prepoznata u domenama modela. Razlozi za odabir Runge-Kutta metode četvrtog reda, način odabira optimalnog broja čestica u simulacijama, te prednosti korištenja simulacija unaprijed i unazad u vremenu su istovjetni onima opisanim u potpoglavlju 3.2. U disperzijskim proračunima ukupni broj čestica je bio konstantan, ali je način ispuštanja čestica zavisio o vremenskoj orijentaciji simulacije. U simulacijama unaprijed (pokus 1., 2., 3.; tablica 6.) čestice su ispuštane s lokacija uzgajališta (slika 33.), i to tako da je na pojedinom uzgajalištu svaki dan ispušteno po 1000 čestica u razdoblju od 1. siječnja do 28. veljače 2016. godine. Ukupno je ispušteno 59000 čestica sa svakog uzgajališta. Čestice su ispuštane u 17 h što je vrijeme u sredini dnevnog perioda mrijesta komarče u Jadranskom moru (Ibarra-Zatarain i Duncan, 2015). Dodatne simulacije u kojima se testirala osjetljivost konačnog rezultata na odabir vremena ispuštanja čestica su pokazale da odabir termina nema veliki utjecaj. U simulaciji unazad (pokus 4.; tablica 6.) 59000 čestica je ispušteno odjednom u 17 h 15. svibnja 2016. godine sa svake od lokacija rastilišta (slika 33.).

U simulacijama unaprijed čestice su na početku bile raspoređene u mrlji polumjera 2000 m odnosno površine 12.47 km^2 na dubini od 30 do 60 m (Stagličić i sur., 2017). U simulaciji unazad mrlja je imala isti polumjer, ali je bila smještana u

prvih 15 m vodenog stupca jer se nalazila u području plitkog obalnog mora. U svim simulacijama čestice su smatrane pasivnim plivačima na čiji pomak jedini utjecaj imaju modelirane struje i varijabilna difuzijska polja. Mogućnost aktivnog plivanja čestica nije uvažena u disperzijskom računu zbog veoma dugog planktonskog stadija komarče koji može trajati od 50 do 70 dana (Moretti i sur., 1999) u uvjetima optimalne temperature od 17 do 18 °C (Polo i sur., 1991), zatim raspona između razdoblja mrijesta (1. siječnja - 28. veljače) i datuma uzorkovanja (15. svibnja), pri čemu čestice mogu biti stare od 76 do 136 dana i konačno zbog relativno velike brzine strujanja u Jadranu u odnosu na brzinu plivanja, koju komarče mogu postići do dobi od 5 i po mjeseci. Za čestice stare 76 dana može se pretpostaviti da su pasivni plivači zbog neznatne razlike između njihove starosti i maksimalne dobi planktonskog stadija. Jedinke komarče stare 100 dana mogu postići ukupnu duljinu tijela od 3.5 cm (Russo i sur., 2007) i pritom im prosječna brzina ne prelazi 0.5 duljina tijela/s (Basaran i sur., 2007). Prosječna brzina površinskih struja izračunata ROMS modelom za cijeli Jadran je iznosila oko 10 cm/s. Ako usporedimo brzinu plivanja komarče i brzinu strujanja u Jadranu možemo zaključiti da je brzina plivanja komarče 5 do 8 puta manja od brzine strujanja. Dakle, velika većina čestica koje simuliraju rane stadije komarče tijekom eksperimenta od 5 i po mjeseci su ili u planktonskom stadiju ili su im brzine plivanja tako male da su ovisne o hidrodinamici okoline, pa je pretpostavka o pasivnim pomacima opravdana. Mogućnost pothlađivanja, odnosno pregrijavanja čestica je upotrijebljena u simulacijama unaprijed. Ukoliko bi se čestice našle u području izvan temperaturnog raspona definiranog donjom granicom od 12 °C i gornjom od 32 °C (Polo i sur., 1991) bile bi eliminirane iz daljnjeg disperzijskog proračuna. Na taj način su se simulirali nepovoljni uvjeti u okolišu u kojem se nalazio ihtioplankton i mlađ komarče.

Tablica 6. Popis pokusa

Broj pokusa	**Vremenska orijentacija pokusa**	**Ponašanje čestice prilikom nailaska na obalu**	**Lokacija ispuštanja čestica**	**Smrtnost zbog temperature**
Pokus 1.	Unaprijed	Odbijanje	Uzgajališta	Ne
Pokus 2.	Unaprijed	Naplavljivanje	Uzgajališta	Ne
Pokus 3.	Unaprijed	Naplavljivanje	Uzgajališta	Da
Pokus 4.	Unazad	Naplavljivanje	Rastilišta	Ne

4.3. Rezultati

4.3.1. Meteorološki i oceanografski uvjeti

Razdoblje od 1. siječnja do 15. svibnja 2016. godine u kojem je simulirana dinamika ihtioplanktona komarče bilo je iznadprosječno toplo s izmjenama različitih sinoptičkih situacija koje su utjecale na režime vjetra, a time i na morske struje nastale pod utjecajem vjetra. Srednje mjesečne temperature zraka u siječnju i veljači 2016. godine su bile iznad višegodišnjeg prosjeka (1961. - 1990.) u cijeloj Hrvatskoj (Meteorološki bilten 02/2016). Na vrijeme u siječnju utjecale su dvije ciklone koje su nad Jadran donijele hladni i vlažni zrak, te uzrokovale umjerene do jake bure (2. i 3., 16. - 22. siječnja) (Meteorološki bilten 01/2016). Veljaču je odlikovalo veoma promijenjivo vrijeme pri čemu su se po izraženoj visinskoj struji svaka 2 do 3 dana premještale hladne fronte i ciklone. Bilo je vjetrovito s jakim i vrlo jakim jugom i jugozapadnim vjetrom (4., 8. - 10., 12. - 17. i 26. - 29. veljače), te kratkotrajnom i vrlo jakom burom s olujnim udarima (3. - 4., 15. i 20. veljače) (Meteorološki bilten 02/2016). Srednja sezonska temperatura (ožujak, travanj, svibanj) je također bila posvuda viša od tridesetogodišnjeg srednjaka (1961. – 1990.) (Meteorološki bilten 05/2016). U ožujku je vrijeme bilo pod utjecajem atmosferskih fronti s kojima je prodirao vlažan i nestabilan zrak. Između 3. i 5. ožujka dominirala je jaka, a između 21. i 24. ožujka izrazito jaka Genovska ciklona. Na Jadranu su se izmjenjivali umjereno do jako jugo (1., 3. - 10. i 31. ožujka) s vrlo jakom, ponegdje i olujnom burom (1., 3., 4., 13., 14. i 23. ožujka) (Meteorološki bilten 03/2016). U travanju je dominirala jugozapadna visinska struja. Na Jadranu je puhalo jugo (8. - 13., 15. - 18., 22. - 24. travnja) ili umjerena i vrlo jaka bura s orkanskim udarima (19., 25. - 27. travnja) (Meteorološki bilten 04/2016). U prvim danima svibnja nad našim krajevima premještala se izražena Genovska ciklona što je kao posljedicu imalo umjerenu, mjestimice jaku i vrlo jaku buru (1. - 4., 9. svibnja). Zabilježeno je i vrlo jako jugo s olujnim udarima (10 - 12. svibnja) (Meteorološki bilten 05/2016).

Srednje mjesečne vrijednosti modeliranih struja su pokazale da je ROMS primijenjen na jadranskoj domeni reproducirao ciklonalnu cirkulaciju na cijelom bazenu (Cushman-Roisin i sur., 2001) u prvih pet i pol mjeseci 2016. godine (slika 34.). Duž istočne obale Jadrana od veljače do svibnja na površini je dominantna

istočnojadranska struja SZ smjera, dok je duž zapadne obale dominatna zapadnojadranska struja JI smjera (Poulain i Cushman-Roisin, 2001; Artegiani i sur., 1997a; Artegiani i sur., 1997b). Tijekom veljače i ožujka došlo je do jačanja istočnojadranske struje zbog puhanja jakog juga (Zore-Armanda, 1969). S porastom dubine istočnojadranska struja slabi. Za razliku od istočnojadranske, zapadnojadranska struja tijekom promatranog razdoblja ne pokazuje veliku prostornu i vremensku varijabilnost i teče prema JI unutar uskog obalnog pojasa duž talijanske obale (Zavatarelli i Pinardi, 2003). Uz opću ciklonalnu cirkulaciju, iz modeliranih mjesečnih srednjaka uočavaju se i vrtlozi karakteristični za Jadransko more: južnojadranski, srednjejadranski i sjevernojadranski ciklonalni vrtlozi (Artegiani i sur., 1997b) (slika 34.).

Srednje mjesečne vrijednosti strujanja dobivene ROMS modelom na ASHELF-2 domeni pokazale su dominantni sjeverozapadni (SZ) smjer strujanja (slika 35.). Navedeni smjer se podudara sa smjerom istočnojadranske obalne struje, pri čemu je strujanje kanalizirano u mlazove između otoka, dok se iza otoka stvaraju brazde (Orlić i sur., 2006a). U veljači i ožujku strujanje u SZ smjeru se intenziviralo zbog prevladavajućeg juga (Zore-Armanda, 1969; Poulain i Cushman-Roisin, 2001). Jačanje istočnojadranske struje također se može dogoditi i zbog termohalinog djelovanja. Naime, istočnojadranska struja ima karakterističan zimski maksimum koji je povezan s dotocima slatke vode u obalnom području i pojačanim isparavanjem na otvorenom dijelu Jadranskog mora. U godinama sa značajnim stvaranjem guste vode u Jadranskom moru zbog površinskog hlađenja može doći do pojačavanja istočnojadranske struje u proljetnim mjesecima (Orlić i sur., 2006b). Ocjena utjecaja termohalinih faktora na jačanje struje u zimu i proljeće 2016. godine zahtijevala bi dodatne analize. U površinskom sloju najveće brzine strujanja su bile u uskom obalnom području između kopna i otoka Brača. To je posljedica zajedničkog djelovanja vjetra i dotoka slatke vode iz rijeka Jadra, Žrnovnice, Cetine i Neretve koje se izlijevaju u ASHELF-2 domeni. Na dubini od 30 m u kanalnom području javila se protustruja u jugoistočnom (JI) smjeru.

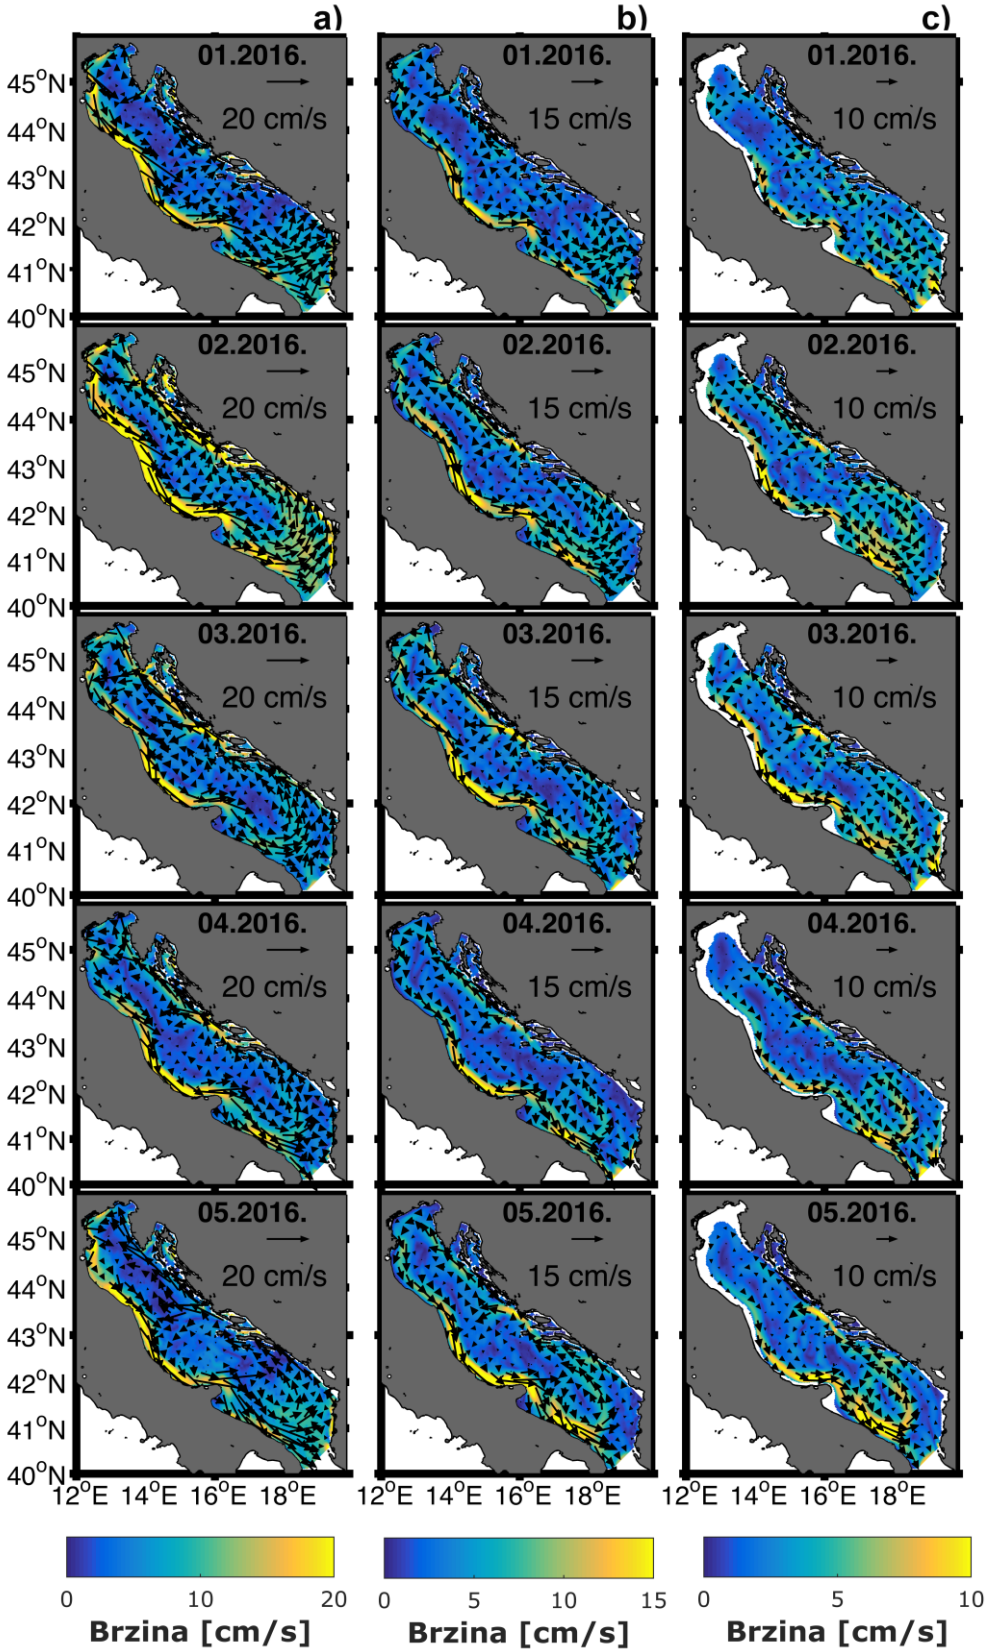

Slika 34. Srednje mjesečne (siječanj, veljača, ožujak i travanj) i polumjesečne (svibanj) vrijednosti strujanja u 2016. godini izračunate pomoću modela ROMS za jadransku domenu na dubini od 1 m (prvi stupac), na dubini od 10 m (drugi stupac) i na dubini od 30 m (treći stupac). Vektori su crtani za svaku desetu točku mreže.

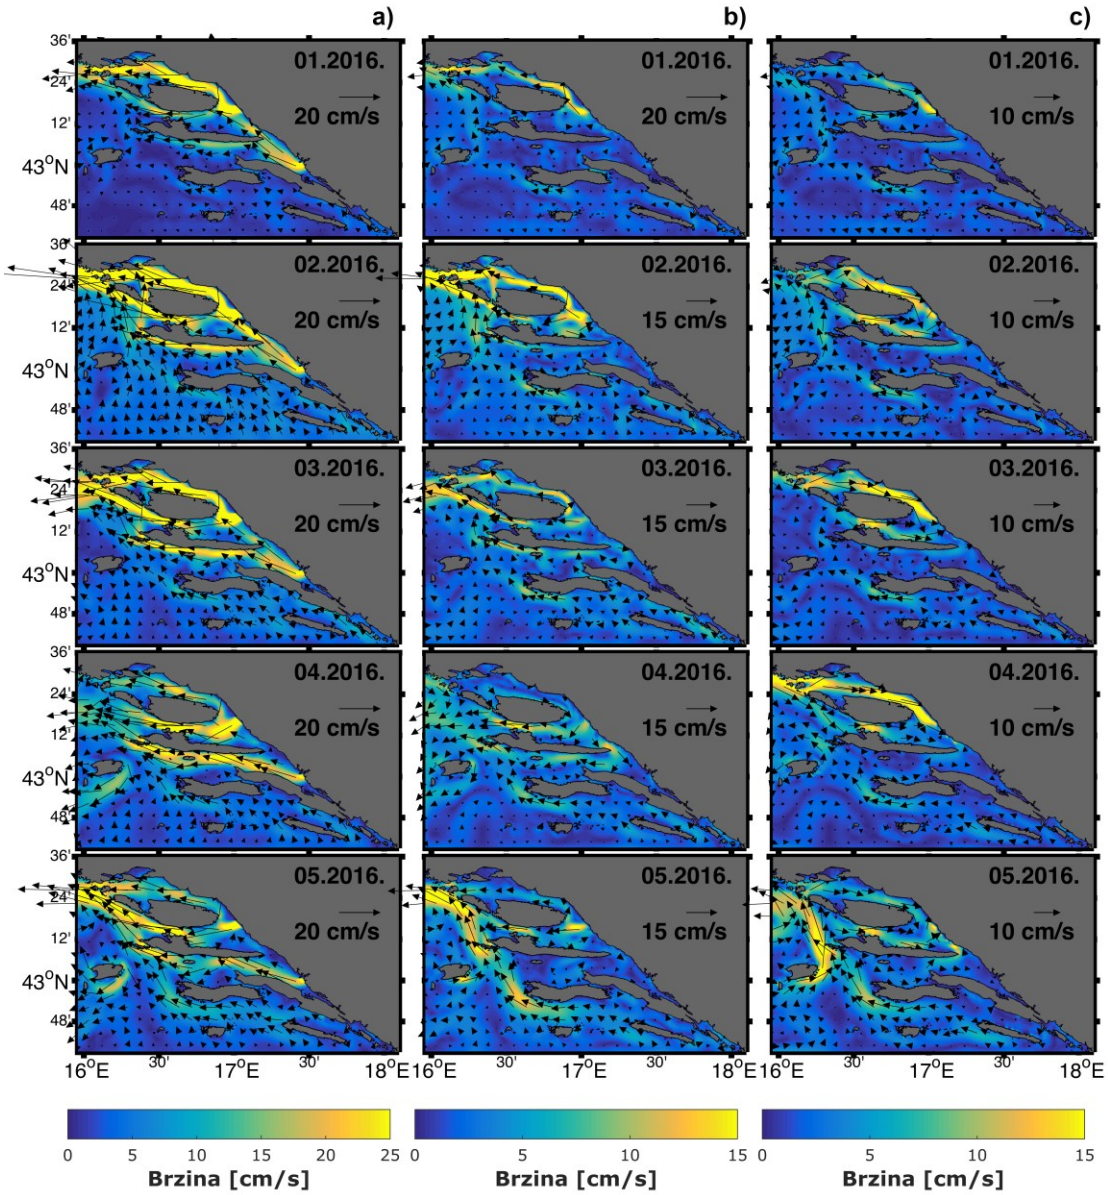

Slika 35. Srednje mjesečne (siječanj, veljača, ožujak i travanj) i polumjesečne (svibanj) vrijednosti strujanja u 2016. godini izračunate pomoću modela ROMS za ASHELF-2 domenu na dubini od 1 m (prvi stupac), na dubini od 10 m (drugi stupac) i na dubini od 30 m (treći stupac). Vektori su crtani za svaku sedmu točku mreže.

Modelirano strujanje je verificirano u obalnom području srednjeg Jadrana i u području otvorenog mora južnog Jadrana. Verifikacija u obalnom području je napravljena usporedbom modeliranih struja s radarskim mjerenjima struja (slika 36.). Radarska mjerenja su pokrila područje između otoka Šolte i Visa, što je područje u neposrednoj blizini uzgajališta na Braču (slika 33.). Time je pokriveno područje koje se nalazi na izravnoj putanji čestica puštenih s otoka Brača, a ujedno je to i područje kroz koje protječe istočnojadranska struja.

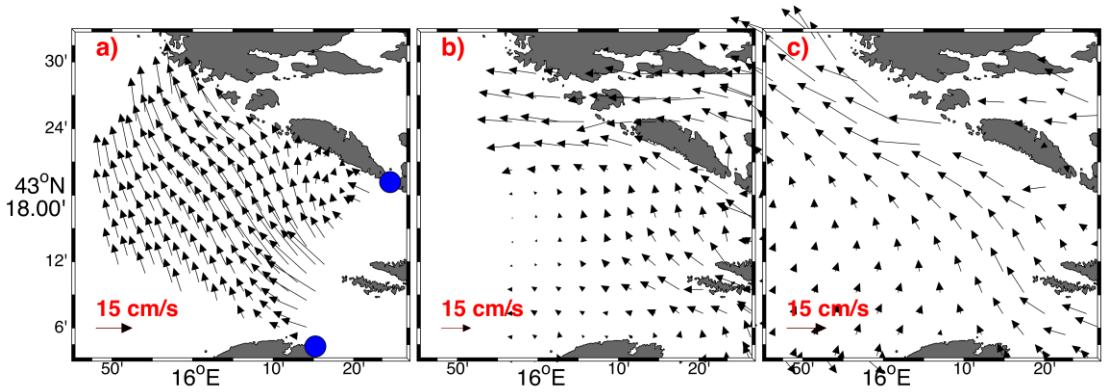

Slika 36. Površinske struje usrednjene u periodu od 1. siječnja do 15. svibnja 2016. godine: izmjerene VHF radarima (a), izračunate modelom ROMS za ASHELF-2 domenu (b) i izračunate modelom ROMS za jadransku domenu (c). Vektori su crtani za svaku treću točke mreže u radarskim mjerenjima, za svaku četvrtu točku u ASHELF-2 domeni i za svaku drugu točku u jadranskoj domeni.

Na slici 36. su prikazane površinske struje usrednjene za cijeli period od 1. siječnja do 15. svibnja 2016. godine. Usporedba radarskih (slika 36.a) i modeliranih struja (slika 36.b i 36.c) pokazuje da su obje primjene ROMS modela simulirale generalni SZ smjer istočnojadranske struje koja prevladava u tom području. Razlika u intezitetu struja u ASHELF-2 i jadranskoj domeni je posljedica otvorene granice u ASHELF-2 domeni koja utječe na konačan rezultat. Oba modela reproduciraju kanaliziranje struje između otoka Hvara i Visa, kao i brazdu na sjevernoj strani otoka Visa koja je tek djelomično vidljiva na južnom rubu polja radarskih mjerenja. Koeficijenti kompleksne korelacije između modeliranih i mjerenih površinskih struja izračunati su prema Kunduu (1976) za razdoblje prvih pet i pol mjeseci 2016. godine. Prethodno su modelirana polja interpolirana na domenu radarskog mjerenja. Iznosi korelacije nisu statistički značajni, a razlog tome je iznimna varijabilnost u površinskom polju strujanja u dugom vremenskom razdoblju. U budućim analizama potrebno je razdvojiti različite komponente strujnog polja (plimno, vjetrovno i rezidualno strujanje) i u rezultatima modela i mjerenja, te provesti korelacijske analize za svaku dinamičku komponentu zasebno.

Verifikacija u području otvorenog dijela južnog Jadranskog mora je napravljena usporedbom putanje Argo plovka s modeliranim putanjama virtualnih čestica (slika 37.). Argo plovak se u razdoblju između 3. siječnja i 12. svibnja 2016. godine nalazio u području južnojadranske kotline. Svakih 4 do 5 dana Argo je izmjerio vertikalni profil temperature i saliniteta. Od ukupno 28 lokacija na kojima je Argo nakon vertikalnog profiliranja izronio, za ispuštanje čestica odabrano je 9

(tablica 7.). Odabir je napravljen tako da ravnomjerno pokrije prvih pet i pol mjeseci 2016. godine. U modelu Ichthyop ispušteno je po 100 čestica na svakoj odabranoj lokaciji izranjanja Argo plovka, dok su radi preglednosti crtane samo 4 virtualne putanje. Najbolje slaganje modeliranih putanja i stvarne putanje je dobiveno za dubinu ispuštanja od 350 m koja odgovara dubini na kojoj je Argo plutao između dva izranjanja. Putanja Argo plovka se mogla podijeliti u tri dijela s obzirom na korelaciju s virtualnim putanjama. U prvom dijelu od 3. siječnja do 3. ožujka plovak je bio nošen strujama ciklonalnog vrtloga po rubu južnojadranske kotline (slika 37. a, b, c, d i e). Virtualne čestice ispuštene u prvom intervalu su grubo pratile putanju plovka do 3. ožujka kad dolazi do razdvajanja virtualnih i mjerene putanje.

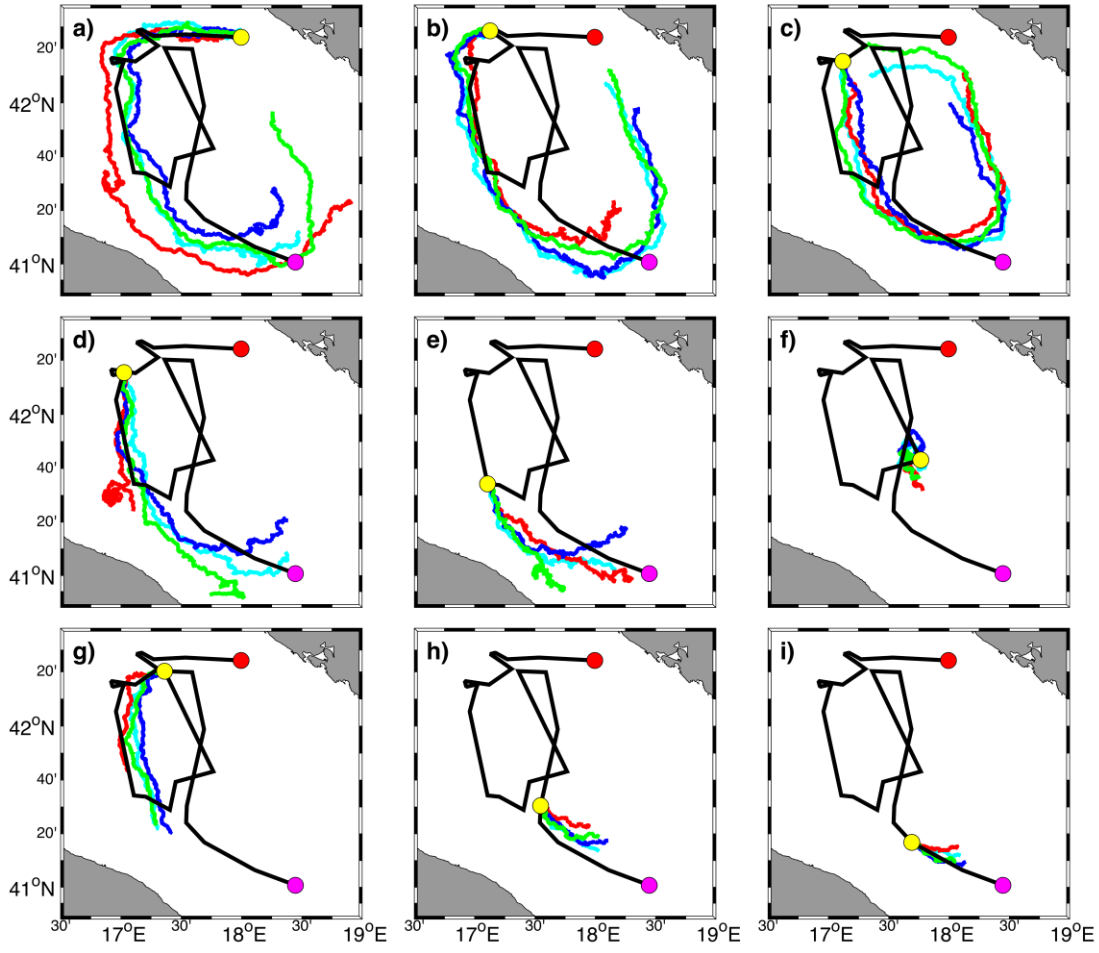

Slika 37. Modelirane (ROMS za jadransku domenu) putanje virtualnih plovaka (zelene, plave, crvene i svjetloplave linije) i izmjerena putanja Argo plovka (crna linija). Žuta točka označava lokaciju ispuštanja virtualnih čestica za odabrane datume (tablica 7.). Crvena točka je početna lokacija Argo plovka na dan 3. siječnja 2016. godine, dok je ružičasta točka krajnja lokacija Argo plovka na dan 12. svibnja 2016. godine.

U sljedećem razdoblju od 3. ožujka do 21. travnja virtualne čestice nastavljaju kružiti oko južnojadranske kotline nošene ciklonalnim vrtlogom, dok se Argo plovak gibao prema središnjem dijelu vrtloga. Mogući razlog neslaganja simuliranih putanja sa stvarnom u drugom dijelu je mezoskalna dinamika koju ROMS nije uspio reproducirati. Argo plovak prolazi kroz središte vrtloga (slika 37.f) i približava se početnoj točki na sjevernoj strani vrtloga (slika 37.g). Zatim se opet kroz središte vrtloga vraća na južni vanjski rub vrtloga (slika 37.h). Virtualne čestice ispuštene u drugom dijelu putanje Argo plovka ne uspijevaju slijediti stvarnu putanju: ili su zarobljene u sredini vrtloga (slika 37.f) ili slijede ciklonalnu cirkulaciju (slika 37.g). U trećem dijelu putanje, nakon 21. travnja, putanje virtualnih čestica i plovka se donekle podudaraju, pri čemu su pomaci Argo plovka veći od pomaka virtualnih čestica, što pokazuje da model u trećem intervalu putanje podcjenjuje brzinu struja (slika 37.h, i). ROMS nije uspio vjerno reproducirati kompleksnu dinamiku koja je utjecala na gibanje Argo plovka, ali je zato reproducirao dio opće cirkulacije Jadranskog mora u južnojadranskom vrtlogu. Zbog relativno malog broja podataka o položaju Argo plovka (položaji su poznati svakih pet dana) u ocjeni realističnosti putanja nisu korištene statističke metode već vizualna procjena.

Tablica 7. Datumi i lokacije Argo plovka s kojih su ispuštene čestice u numeričkim simulacijama, te datumi i lokacije na kojima je napravljeno vertikalno profiliranje.

Ispuštanje virtualnih plovaka		Vertikalni profili temperature i saliniteta	
Datum	Lokacija	Datum	Lokacija
3. siječnja	41°16’49.06”N 17°41’29.96”E	3. siječnja	41°16’49.06”N 17°41’29.96”E
22. siječnja	41°30’27.8”N 17°32’46.88”E	22. siječnja	41°30’27.8”N 17°32’46.88”E
6. veljače	42°20’14.88”N 17°21’44.47”E	6. veljače	42°20’14.88”N 17°21’44.47”E
21. veljače	41°43’11.33”N 17°45’58.49”E	17. veljače	42°14’29.56”N 16°55’51.31”E
7. ožujka	41°34’16.97”N 17°6’26.21”E	3. ožujka	42°5’21.96”N 16°57’33.11”E
27. ožujka	42°15’29.16”N 17°1’33.35”E	17. ožujka	41°28’55.15”N 17°24’20.79”E
6. travnja	42°15’17.39”N 17°7’9.76”E	16. travnja	41°58’49.84”N 17°41’20.51”E
21. travnja	42°26’32.39”N	6. svibnja	41°6’25.41”N

	17°7’43.21”E		18°6’38.84”E
1. svibnja	42°24’10.81”N 17°59’44.76”E		

Vertikalni profili temperature i saliniteta koje je izmjerio Argo plovak su upotrebljeni za verifikaciju rezultata ROMS modela za jadransku domenu (slika 38.). Od 28 lokacija vertikalnog profiliranja odabrano je 8 (tablica 7.). Odabir je napravljen tako da pokrije cijeli promatrani period i pritom prikaže promjenu od homogene strukture vodenog stupca karakteristične za zimsku sezonu u stratificiranu karakterističnu za proljeće (Artegiani i sur., 1997a).

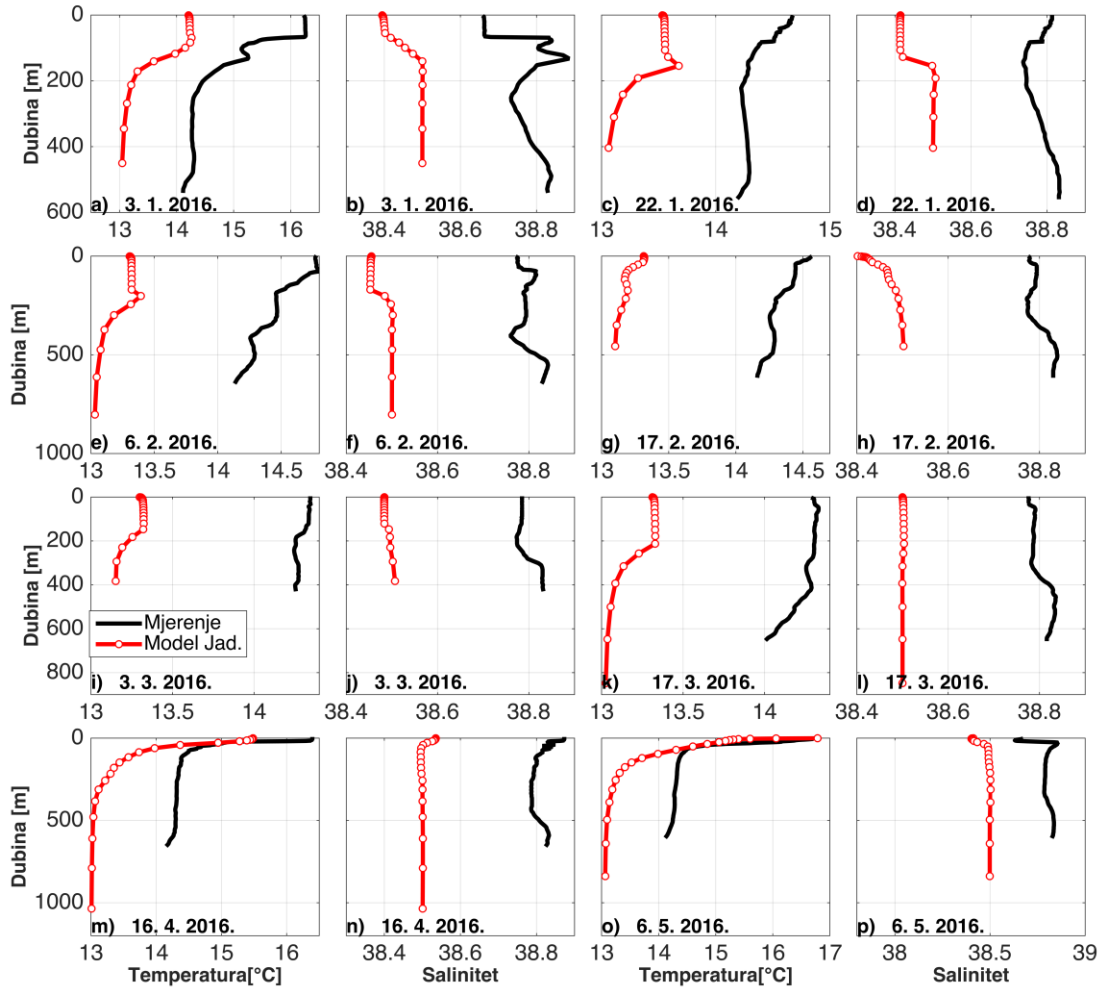

Slika 38. Modelirani (ROMS za jadransku domenu) i izmjereni (Argo) profili temperature i saliniteta tijekom prvih pet i pol mjeseci 2016. godine. Lokacije izmjerenih profila se nalaze u tablici 1. Prvi i treći stupac su vertikalni profili temperature, dok su drugi i četvrti vertikalni profili saliniteta.

Tijekom prva tri mjeseca vodeni stupac je homogen (slika 38., prvi redak). Pri tome model podcjenjuje izmjerenu vrijednost temperature maksimalno do 2 °C. S dolaskom proljeća dolazi do zagrijavanja površinskog sloja, pri čemu se javlja termoklina na 30 m. Model reproducira pojavu stratifikacije, iako su modelirane temperature i dalje niže od izmjerenih (slika 38.m, o). Razlike u modeliranim i mjerenim profilima saliniteta od prosječno 0.4 su posljedica utjecaja rubnih uvjeta na otvorenoj granici za salinitet, preuzetih iz šireg jadranskog modela AREG, loše parametriziranih albanskih rijeka (Janeković i sur., 2014), te korištenja klimatoloških protoka za sve jadranske rijeke. Iako je područje južnog Jadrana po kojem je Argo plovak plutao daleko od pretpostavljene putanje ihtioplanktona komarče, vertikalni profili su pokazali da ROMS model može dobro reproducirati sezonske promjene temperature u vodenom stupcu. Izmjerena i modelirana temperatura na otvorenom moru nikad nije pala ispod letalne temperature za ihtioplantkon komarče od 12 °C, dapače cijelo vrijeme je bila iznad 13 °C u cijelom vodenom stupcu što je u skladu s klimatološkim vrijednostima (Lipizer i sur., 2014). Razlike u dubini modeliranih i izmjerenih profila temperature i saliniteta posljedica su nepodudaranja modelske batimetrije s realnom i činjenice da Argo plovak nikad ne zaroni do maksimalne dubine.

Statistička usporedba rezultata mjerenja i modela je napravljena izračunom vertikalnih profila pristranosti i srednjih kvadratnih pogrešaka na mjesečnoj osnovi (slika 39.). Model podcjenjuje mjerenja i za temperaturu i za salinitet. U svibnju (slika 39.i) s razvojem termokline dolazi do smanjivanja pristranosti za temperaturu. Iz vrijednosti srednjih kvadratnih pogrešaka i pristranosti izračunatih za svaki profil zasebno uočava se da model podcjenjuje mjerenja temperature i saliniteta (tablica 8.). Vrijednost BIAS-ova za temperaturu se smanjuje s dolaskom toplijeg dijela godine i pojavom stratifikacije, dok za salinitet BIAS ostaje u istim okvirima.

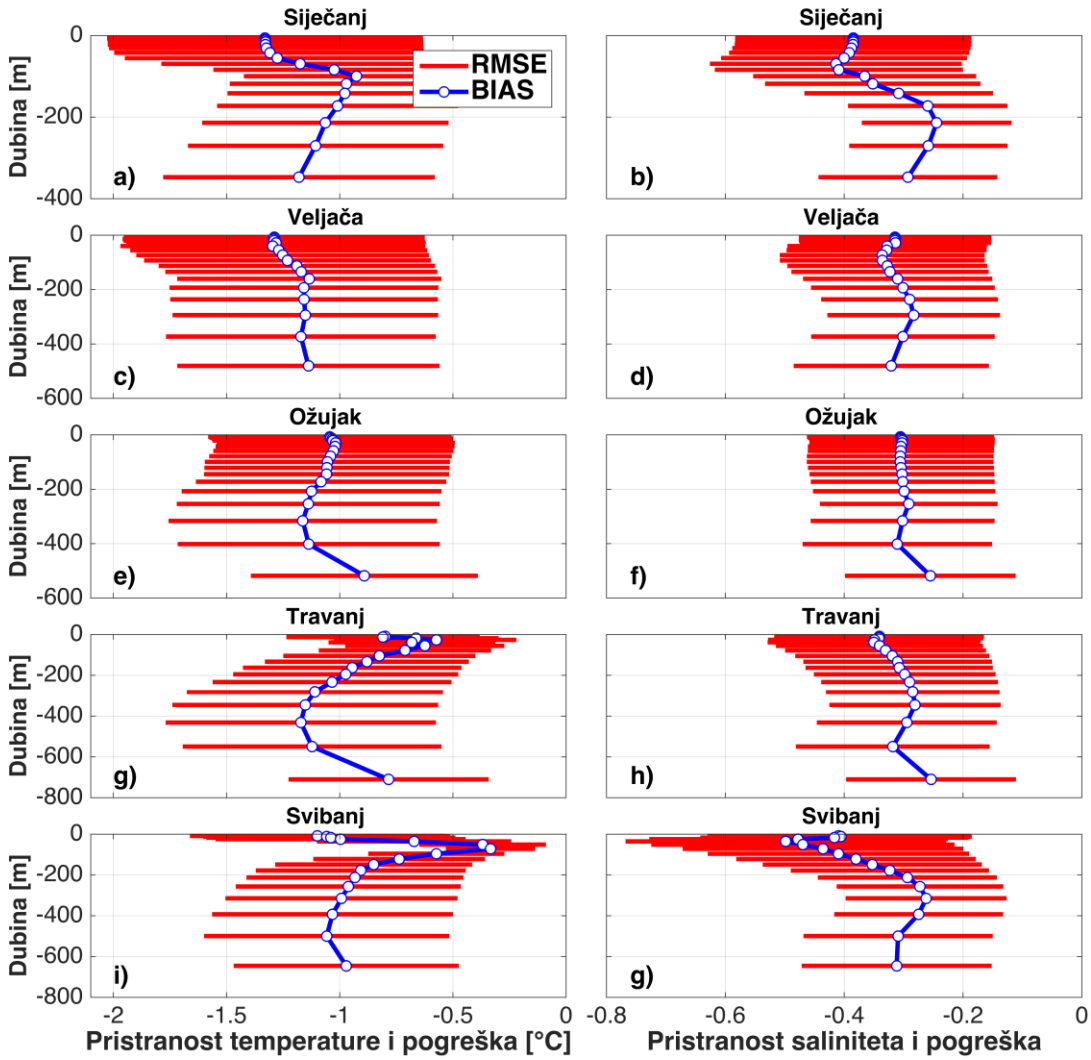

Slika 39. Vertikalni profili pristranosti (BIAS – plave vertikalne linije) i srednje kvadratne pogreške (RMSE – horizontalne crvene linije) modela za temperaturu (a) i salinitet (b). RMSE i BIAS vrijednosti su izračunate za sve vertikalne CTD profile Argo plovka u razdoblju od 1. siječnja do 12. svibnja 2016. godine. Izračuni su napravljeni na s-nivoima ROMS modela i grupirani su po mjesecima. Donja granica profila je određena na temelju pridnene dubine mjerenja najplićeg Argo plovka u navedenom razdoblju.

Tablica 8. Iznosi pristranosti (BIAS) i srednje kvadratne pogreške (RMSE) modela za temperaturu i salinitet za svaki od 27 vertikalnih CTD profila Argo plovka u razdoblju od 3. siječnja do 12. svibnja 2016. godine.

Redni broj postaje	**Datum postaje**	**Lokacija postaje**	**RMSE (Temperatura [°C])**	**BIAS (Temperatura [°C])**	**RMSE (Salinitet)**	**BIAS (Salinitet)**
1.	3. siječnja	42°24’10.81”N 17°59’44.76”S	-1.491	-1.308	0.268	-0.239
2.	7. siječnja	42°25’14.57”N 17°3’22.41”S	0.95	-0.836	0.312	-0.278
3.	13. siječnja	42°24’37.15”N 17°16’13.92”S	0.878	-0.788	0.368	-0.323
4.	17. siječnja	42°27’1.22”N 17°10’17.89”S	1.033	-0.926	0.347	-0.308
5.	22. siječnja	42°26’32.40”N 17°7’43.21”S	0.91	-0.813	0.316	-0.282
6.	27. siječnja	42°23’33.37”N 17°13’41.93”S	1.23	-1.108	0.329	-0.295
7.	1. veljače	42°21’3.80”N 17°18’24.56”S	1.409	-1.292	0.295	-0.271
8.	6. veljače	42°15’17.39”N 17°7’9.76”S	1.21	-1.089	0.293	-0.264
9.	12. veljače	42°16’37.57”N 16°55’4.67”S	1.14	-1.059	0.295	-0.274
10.	17. veljače	42°14’29.56”N 16°55’51.31”S	1.09	-0.986	0.297	-0.268
11.	21. veljače	42°15’29.16”N 17°1’33.35”S	0.973	-0.879	0.279	-0.252
12.	26. veljače	42°12’37.15”N 17°0’9.40”S	0.913	-0.846	0.278	-0.258
13.	3. ožujka	42°5’21.96”N 17°57’33.11”S	0.933	-0.844	0.272	-0.246
14.	7. ožujka	41°34’16.97”N 17°6’26.21”S	1.156	-1.045	0.307	-0.277
15.	13. ožujka	41°33’50.02”N 17°12’17.44”S	1.005	-0.909	0.285	-0.258
16.	17. ožujka	41°28’55.15”N 17°24’20.80”S	0.923	-0.833	0.262	-0.236
17.	23. ožujka	41°39’20.26”N 17°27’13.79”S	0.872	-0.798	0.261	-0.242
18.	27. ožujka	41°43’11.33”N 17°45’58.49”S	0.889	-0.772	0.257	-0.225
19.	1. travnja	42°0’42.24”N 17°34’28.32”S	0.929	-0.848	0.285	-0.264
20.	6. travnja	42°20’14.88”N 17°21’44.47”S	0.807	-0.723	0.287	-0.259

21.	12. travnja	42°19’52.39”N 17°35’26.37”S	0.845	-0.77	0.325	-0.298
22.	16. travnja	41°58’49.84”N 17°41’20.51”S	0.825	-0.682	0.277	-0.243
23.	21. travnja	41°30’27.28”N 17°32’46.88”S	0.763	-0.66	0.279	-0.259
24.	26. travnja	41°24’8.53”N 17°32’27.02”S	0.79	-0.677	0.295	-0.266
25.	1. svibnja	41°16’49.06”N 17°41’29.96”S	0.773	-0.668	0.309	-0.284
26.	6. svibnja	41°6’25.41”N 18°6’38.84”S	0.852	-0.712	0.276	-0.247
27.	12. svibnja	41°0’44.78”N 18°26’50.51”S	0.882	-0.768	0.456	-0.384

Za verifikaciju modeliranih vertikalnih profila temperature i saliniteta u obalnom području istočnog Jadrana upotrebljena su CTD mjerenja s postaja ST101, CJ007, CJ008, CJ009, FP-07 i FP-P4A (slika 33.). Postaja CJ008 se nalazi u blizini uzgajališta uz otok Brač (slika 33.), dok se postaje CJ007 i ST101 nalaze na najkraćem izravnom putu koji mora prijeći ihtioplankton komarče na putu ka rastilištu ranih razvojnih stadija u boćatim vodama rijeke Rike (močvara Pantan) u Kaštelanskom zaljevu (slika 33.). Postaje FP07 i FP-P4A se nalaze u Neretvanskom kanalu u neposrednoj blizini rastilišta lociranom na ušću rijeke Neretve u Jadransko more.

Usporedba izmjerenih i modeliranih profila pokazuje veće vrijednosti saliniteta dobivene mjerenjima (slika 40.). To vrijedi za oba modela. Nadalje, usporedba pokazuje da model finije prostorne rezolucije, ROMS na ASHELF-2 domeni, daje bolje rezultate nego ROMS za jadransku domenu. Iznimke se mogu uočiti na postaji CJ008 u ožujku i na postaji CJ009 u travnju (slika 40.). Na postajama ST101 i CJ007 dolazi do značajnije razlike između mjerenih i modeliranih površinskih vrijednosti saliniteta. Postaja ST101 je u blizini rijeke Jadro, dok je postaja CJ007 pod utjecajem izljeva rijeke Cetine. Na obje postaje su modelirani površinski saliniteti niži od izmjerenih. Simulacije modelom na ASHELF-2 domeni daju manje odstupanje površinskog saliniteta u odnosu na jadranski model. Izmjerene površinske i pridnene vrijednosti saliniteta na postajama CJ008 i CJ009 ne odstupaju od klimatoloških vrijednosti za te postaje (Grbec i sur., 2007), a odstupanja rezultata za jadranski ROMS su slična onima na otvorenom moru.

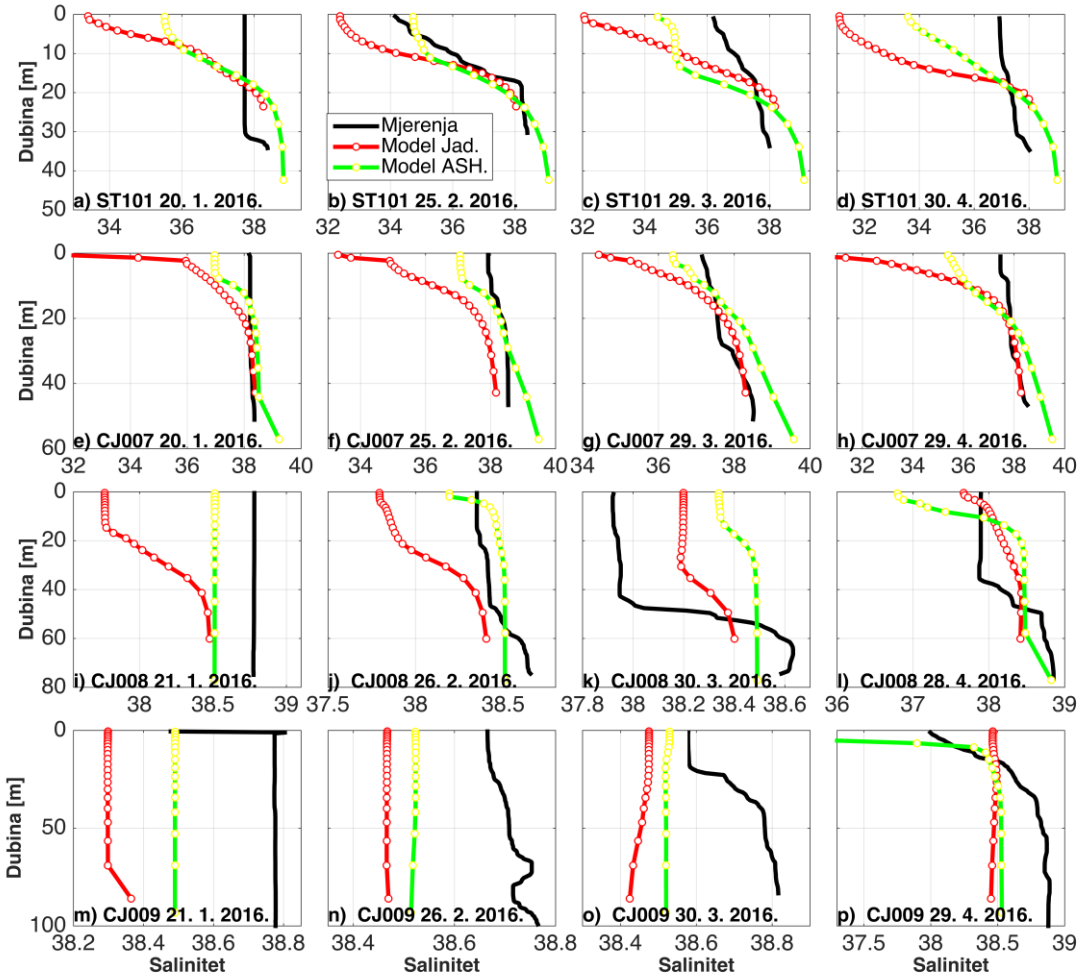

Slika 40. Izmjereni (CTD – crne linije) i modelirani (ROMS model za jadransku domenu – crvene linije; ROMS model za ASHELF-2 domenu – zelene linije) vertikalni profili saliniteta tijekom prva četiri mjeseca 2016. godine. Profili su mjereni na postajama ST101, CJ007, CJ008 i CJ009.

Usporedba modeliranih i mjerenih vrijednosti temperature pokazuje da obje primjene ROMS modela dobro simuliraju sezonske promjene temperature u vodenom stupcu na postajama CJ008 i CJ009 (slika 41.). U siječnju, veljači i ožujku stupac je vertikalno homogen, dok se u travnju javlja termoklina u prvih 30 m. Jadranski ROMS više podcjenjuje mjerenu temperaturu na postajama CJ008 i CJ009 od ASHELF-2 modela u zimskoj sezoni, a u travnju je razlika u temperaturnom profilu između jadranskog i ASHELF-2 ROMS-a zanemariva, posebice u površinskom sloju. Na postajama bližim kopnu, CJ007 i ST101, razlike između modeliranih i mjerenih temperaturnih profila su manje u odnosu na postaje CJ008 i CJ009. Također razlika u temperaturnim profilima između jadranskog i ASHELF-2 modela je manja u usporedbi s postajama bližim otvorenom moru. Izmjerena, ali i modelirana temperatura na svim postajama u prva četiri mjeseca 2016. godine nije pala ispod 12

°C, letalne temperature za rane razvojne stadije komarče, uz iznimku vrijednosti na postajama uz obalu ST101 i CJ007 u siječnju. Izmjerene površinske i pridnene vrijednosti temperature na postajama CJ008 i CJ009 ne odstupaju od klimatoloških vrijednosti za te postaje (Grbec i sur., 2007).

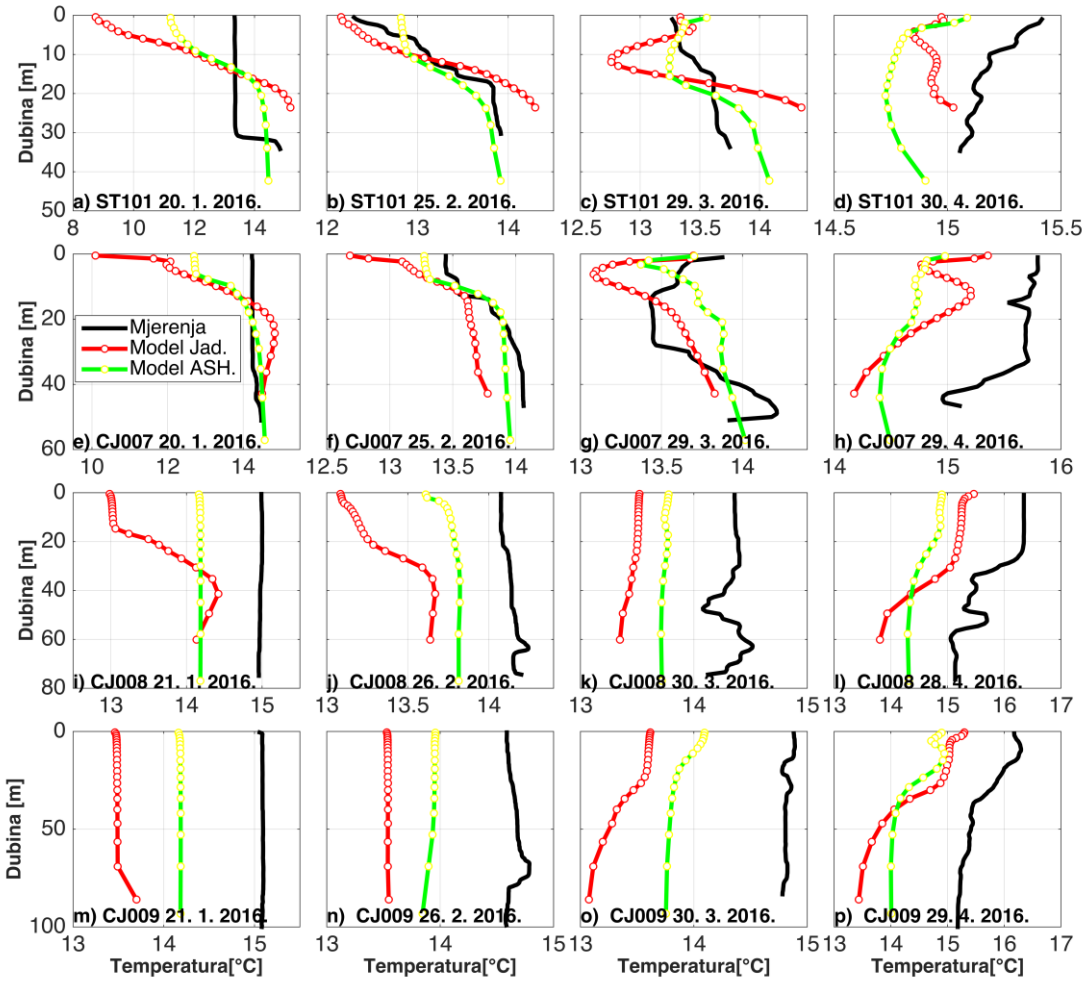

Slika 41. Izmjereni (CTD – crne linije) i modelirani (ROMS model za jadransku domenu–crvene linije; ROMS model za ASHELF-2 domenu – zelene linije) vertikalni profili temperature tijekom prva četiri mjeseca 2016. godine. Profili su mjereni na postajama ST101, CJ007, CJ008 i CJ009.

Postaje FP-07 i FP-P4A se nalaze u neposrednoj blizini rastilišta ranih razvojnih stadija komarče u području ušća Neretve u Jadransko more. CTD mjerenja na tim postajama su napravljena dva tjedna prije ulova mlađi komarči. Razlika između modeliranog i mjerenog saliniteta je minimalna i modeli dobro reproduciraju smanjeni salinitet u površinskom sloju koji je nastao pod utjecajem rijeke Neretve (slika 42.). Modelirani i mjereni vertikalni profili temperature pokazuju da je temperatura iznad 12 °C. Jadranski ROMS dobro reproducira vertikalnu

promjenjivost temperature, ali uz vrijednosti niže za oko 1 °C od izmjerenih. Dubine jadranskog ROMS modela u točkama koje odgovaraju postajama FP-07 i FP-P4A su daleko manje od stvarnih, što je posljedica grube rezolucije tog modela u obalnom području.

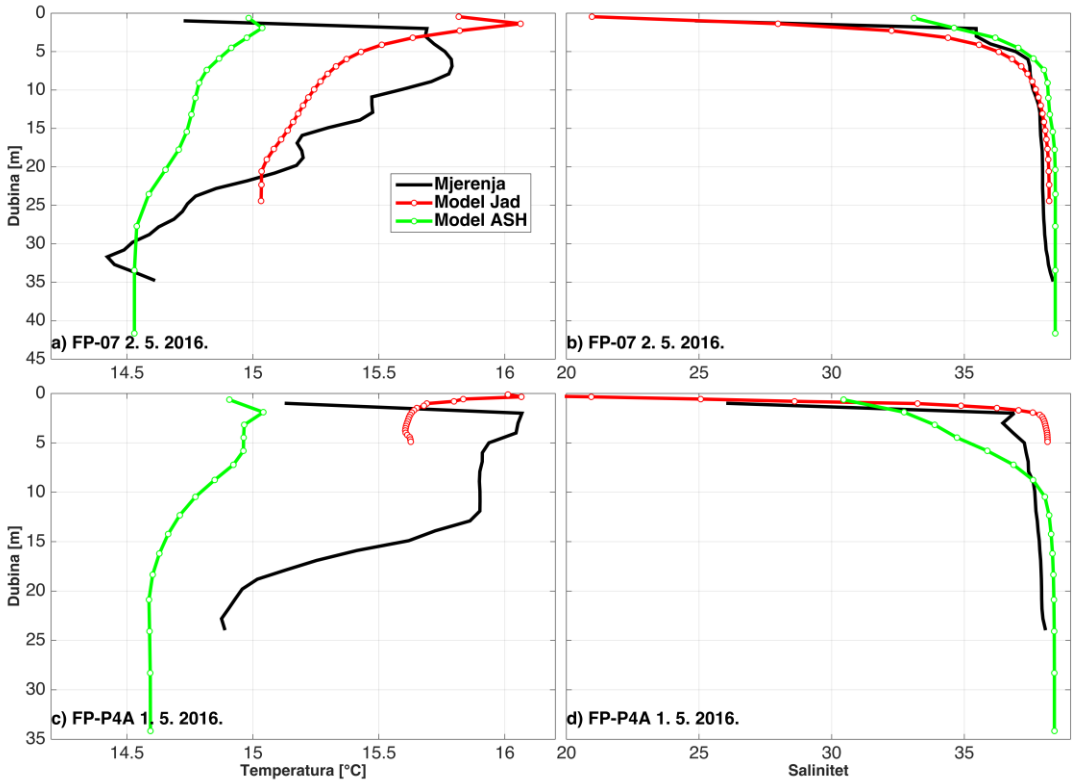

Slika 42. Izmjereni (CTD – crne linije) i modelirani (ROMS model za jadransku domenu – crvene linije; ROMS model za ASHELF-2 domenu – zelene linije) vertikalni profili temperature (a, c) i saliniteta (b, d) u svibnju 2016. godine. Profili su mjereni na postajama FP07 (a, b) i FP-P4A (c, d).

Statistička usporedba modeliranih i mjerenih rezultata je napravljena izračunom BIAS-ova i RMSE-ova (tablica 9.) Iz izračunatih vrijednosti uočava se da i jadranski model i ASHELF-2 podcjenjuju mjerene vrijednosti za većinu postaja, pri čemu su iznosi vezani za ASHELF-2 manji od onih za jadranski model.

Tablica 9. Iznosi pristranosti (BIAS) i srednje kvadratne pogreške (RMSE) modela za temperaturu i salinitet za CTD mjerenja napravljena na postajama ST101, CJ007, CJ008, CJ009, FP07 i FP-P4A u razdoblju prvih pet mjeseci 2016. godine. T označava temperaturu, S salinitet, J jadranski model, A ASHELF-2 model.

Postaja	Lokacija postaje	Datum mjerenja	RMSE (T-J)	RMSE (T-A)	BIAS (T-J)	BIAS (T-A)	RMSE (S-J)	RMSE (S-A)	BIAS (S-J)	BIAS (S-A)
ST101	16°22'54"N, 43°31'6"E	20. siječnja	2.530	1.129	-1.335	**-0.452**	2.276	1.237	-1.624	**-0.605**
		25. veljače	0.302	0.185	-0.03	**-0.019**	1.469	0.409	-1.242	**-0.145**
		29. ožujka	0.420	0.162	-0.128	**0.001**	2.084	1.209	-1.519	**-0.734**
		30. travnja	0.316	0.342	-0.287	**-0.279**	3.891	1.626	-3.087	**-0.861**
CJ007	16°19'0"N, 43°12'0"E	20. siječnja	1.554	0.784	-0.844	**-0.431**	2.046	0.658	-1.31	**-0.323**
		25. veljače	0.314	0.095	-0.269	**-0.043**	2.151	0.479	-1.757	**-0.297**
		29. ožujka	0.297	0.208	-0.152	**0.053**	0.984	0.446	-0.567	**-0.009**
		30. travnja	0.843	0.882	-0.792	**-0.674**	2.428	1.097	-1.582	**-0.594**
CJ008	16°20'0"N, 43°0'0"E	20. siječnja	1.634	0.669	-1.518	**-0.553**	0.868	0.222	-0.818	**-0.183**
		25. veljače	0.801	0.287	-0.734	**-0.234**	0.445	0.081	-0.403	**0.026**
		29. ožujka	0.851	0.500	-0.831	**-0.411**	0.258	0.365	**0.234**	0.286
		30. travnja	1.083	1.16	-1.046	**-0.955**	0.242	0.537	0.120	**-0.108**
CJ009	17°19'42.6"N, 43°2'0"E	20. siječnja	1.594	0.778	-1.594	**-0.642**	0.465	0.229	-0.461	**-0.188**
		25. veljače	1.086	0.561	-1.085	**-0.461**	0.217	0.133	-0.216	**-0.108**
		29. ožujka	1.337	0.756	-1.298	**-0.621**	0.208	0.125	-0.178	**-0.083**
		30. travnja	1.229	1.12	-1.175	**-0.927**	0.302	0.583	**0.001**	-0.314
FP07	17°19'42.6"N, 43°2'0"E	2. svibnja	0.388	0.517	**-0.114**	-0.353	1.003	1.794	**-0.053**	0.604
FP-P4A	17°25'4.92"N, 43°0'53.28"E	1. svibnja	0.201	0.704	**-0.034**	-0.521	1.592	1.539	0.487	**-0.165**

4.3.2. Rezultati lagrangeovskih izračuna

U simulacijama unaprijed provedeni su pokusi s lagrangeovskim pasivnim česticama (pokus 1., 2. i 3., tablica 6.). Čestice su ispuštane s lokacija uzgajališta tuna kod otoka Ugljana i Brača u jadranskoj domeni, dok su u ASHELF-2 domeni ispuštane samo s lokacije kod Brača (slika 33.). Cilj svih pokusa je bila procjena povezanosti uzgajališta s rastilištima ranih razvojnih stadija komarči smještenih u području boćate vode na ušćima Neretve, Raše i Rike (Pantan) (slika 33.). U pokusu 1. čestice su se odbijale pri nailasku na obalu. Na taj način zadržane su sve čestice u lagrangeovskoj simulaciji i time se dobila gruba procjena potvrde hipoteze o povezanosti uzgajališta i rastilišta. Pozitivan rezultat pokusa unaprijed je bila zatečenost čestica unutar svakog od područja uspjeha 15. svibnja 2016. godine. Područje uspjeha za simulacije unaprijed je definirano kao kvadrat površine 400 km^2 u sredini kojeg se nalazila geografska lokacija rastilišta. Geografska lokacija Pantana se ne nalazi točno u središtu područja uspjeha, jer je Pantan u batimetriji modela prepoznat kao kopnena točka, i zbog toga je u domeni modela pomaknut na prvu najbližu mokru točku. Područja uspjeha oko rastilišta imaju nejednak udio kopna i mora. Zbog toga je broj čestica u području uspjeha pomnožen s težinskim faktorom, koji je za svako rastilište definiran kao postotak mokrih točaka u području uspjeha.

Rezultati jadranskih simulacija iz pokusa 1. potvrđuju povezanost uzgajališta kod Brača s rastilištima kod Neretve, Pantana i Raše (slika 43.a) kao i povezanost uzgajališta Ugljana s Rašom (slika 43.b). Rezultat ASHELF-2 simulacije pokazuje povezanost Brača s Neretvom i Pantanom (slika 43.c). U jadranskoj i ASHELF-2 simulaciji najveći broj čestica s Brača je završio u području oko Pantana, dok je najmanji u području oko Neretve. Udaljenost između Brača i Pantana je najmanja od svih drugih udaljenosti između uzgajališta i rastilišta. Čestice s Brača i čestice s Ugljana u jadranskoj simulaciji su transportirane istočnojadranskom strujom (slika 34.) do rastilišta na lokaciji Raše. Transporta između Ugljana i druga dva rastilišta nije bilo.

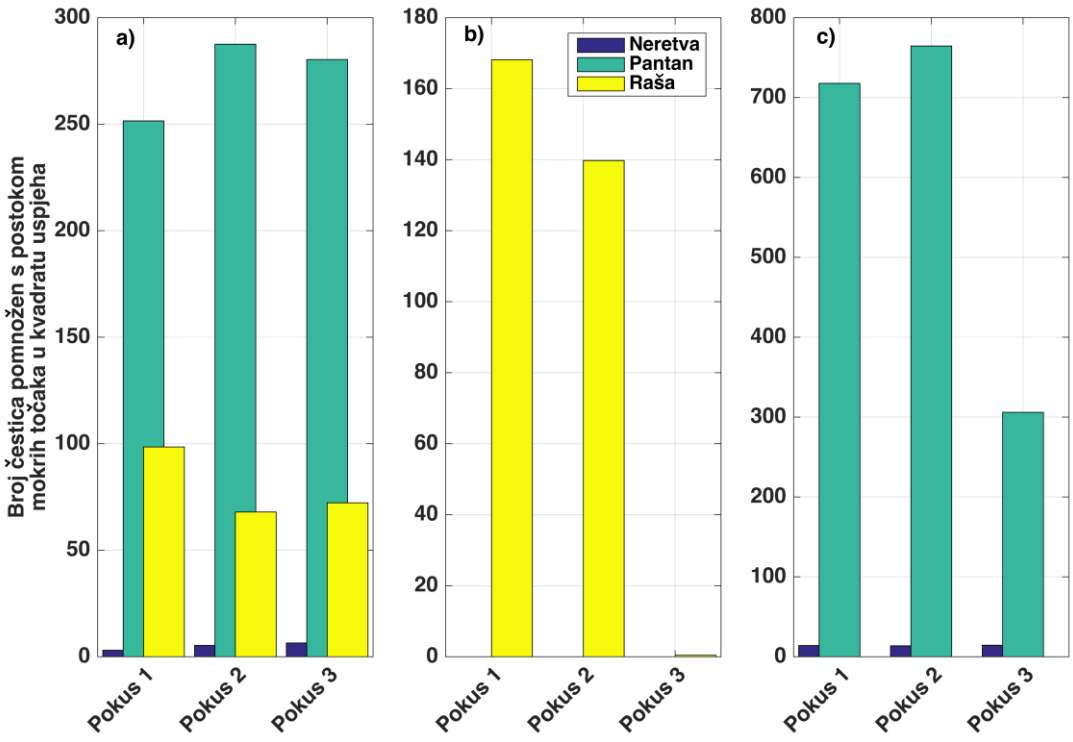

Slika 43. Prikaz broja čestica koje su se zatekle u kvadratu uspjeha 15. svibnja 2016. godine. Broj čestica je pomnožen s postotkom mokrih točaka u kvadratu uspjeha za svako od tri rastilišta (Neretva, Pantan i Raša) na dan 15. svibnja 2016. godine. Čestice su ispuštane u tri različito parametrizirana pokusa (pokus 1. – odbijanje, pokus 2. – naplavljivanje, pokus 3. – naplavljivanje i letalna temperatura; tablica 6.). Simulacije su rađene u jadranskoj domeni za lokacije uzgajališta kod otoka Brača (a) i Ugljana (b), te u ASHELF-2 domeni za lokaciju kod otoka Brača (c).

Rezultatima pokusa 2. je kvantificiran utjecaj naplavljivanja čestica pri nailasku na kopno na ukupni broj čestica zatečenih u kvadratu uspjeha. Čestice su na putu između uzgajališta i rastilišta bile naplavljivane na otoke ili kopno što ih je eliminiralo iz daljnjeg langrangeovskog računa. Na taj se način simulirao nepovoljni utjecaj okoliša na daljnje preživljavanje ihtioplanktona komarče. Naplavljivanje čestica u području uspjeha je smatrano uspješnim ishodom jer se na taj način simuliralo zadržavanje čestica u području koje je pogodno za daljnji razvoj ihtioplanktona komarče. Također se na taj način omogućilo zadržavanje čestica u području uspjeha do kojeg ne bi došlo da su se čestice odbijale od obale kao u pokusu 1. U jadranskoj simulaciji efekt naplavljivanja je povećao broj čestica koje su iz uzgajališta ispred Brača došle do područja uspjeha za Pantan i Neretvu i smanjio je broj čestica iz istog uzgajališta za Rašu. Sličan se rezultat može opaziti i za čestice puštene s Ugljana. U ASHELF-2 simulaciji zamjetan je porast broja čestica na

Pantanu u pokusu 2. u odnosu na pokus 1. Udio naplavljenih čestica puštenih u jadranskoj simulaciji s otoka Brača iznosio je 31%, a s Ugljana 21%. Udio naplavljenih čestica puštenih u ASHELF-2 simulaciji s Brača je iznosio 20%. Iako je veliki broj čestica naplavljen na preprekama u transportu, simuliranje zadržavanja je rezultiralo povećanjem ukupnog broja čestica u području.

U ASHELF-2 simulacijama zbog neposredne blizine lokacije ispuštanja čestica kod otoka Brača području u kojem je dominantna istočnojadranska struja došlo je do transporta čestica izvan domene. U pokusu 1. je 98% čestica transportirano van domene, dok je u pokusu 2. i 3. taj udio iznosio 79%. Smanjenje advektiranog broja čestica van domene je posljedica uvažavanja naplavljivanja. U jadranskim simulacijama do advekcije čestica izvan domene nije došlo jer čestice nošene ciklonalnom jadranskom cirkulacijom nisu uspjele tijekom 136 dana preći put duž hrvatske, a potom i talijanske obale.

U pokusu broj 3. uz opciju naplavljivanja primijenjena je i opcija letalne temperature. Sve čestice koje su se našle u području u kojem je temperatura mora bila ispod 12 °C odnosno iznad 32 °C su eliminirane iz daljnjeg lagrangeovskog proračuna. Na taj način je simuliran negativan utjecaj okoline na ihtioplankton komarče koji rezultira ugibanjem jedinke.

Uvođenje donje i gornje letalne temperature nije imalo zamjetan utjecaj na čestice puštene s otoka Brača u jadranskoj simulaciji (slika 43.a). Broj čestica koje su transportirane ka rastilištima je sličan onom u pokusu 2. Ukupno je 10% čestica uklonjeno iz izračuna zbog transporta u područje u kojem je temperatura mora manja od 12 °C. Najveći je utjecaj uvođenje letalne temperature imalo na čestice puštene s Ugljana (slika 43.b). Transport k Raši je zanemariv zbog nailaska čestica na područje gdje je temperatura mora bila niža od 12 °C. Na taj način eliminirano je 99% čestica. Ukupni transport prema Neretvi u ASHELF-2 simulaciji ostao je sličan onom u pokusu 2., dok je transport prema Pantanu drastično opao (slika 43.c). Razloge za ugibanje ihtioplanktona komarče treba tražiti u sličnim uzrocima kao i za čestice puštene s Ugljana.

Prostorne raspodjele čestica su izračunate brojanjem čestica koje se zatečene u blizini pojedinog čvora mreže modela ROMS za jadransku domenu prostorne rezolucije 2.5x2.5 km. Potom je prirodni logaritam broja čestica zatečenih na pojedinom čvoru pridružen njegovoj lokaciji. Na taj način u prostornim raspodjelama prikazana su samo područja gdje je bio grupiran veliki broj čestica. Računanje unutar

ćelije jadranskog ROMS-a je upotrijebljeno i za ASHELF-2 simulacije radi uniformnog prikaza koncentracija. U prvih 5 m tijekom cijele jadranske simulacije nalazilo se 13% čestica, u prvih 15 m 40%, a u prvih 35 m 79% (slika 44.). Slični iznosi su dobiveni i u ASHELF-2 simulaciji: u prvih 5 m 10%, u prvih 15 m 38% i u prvih 35 m 73% (slika 45.)

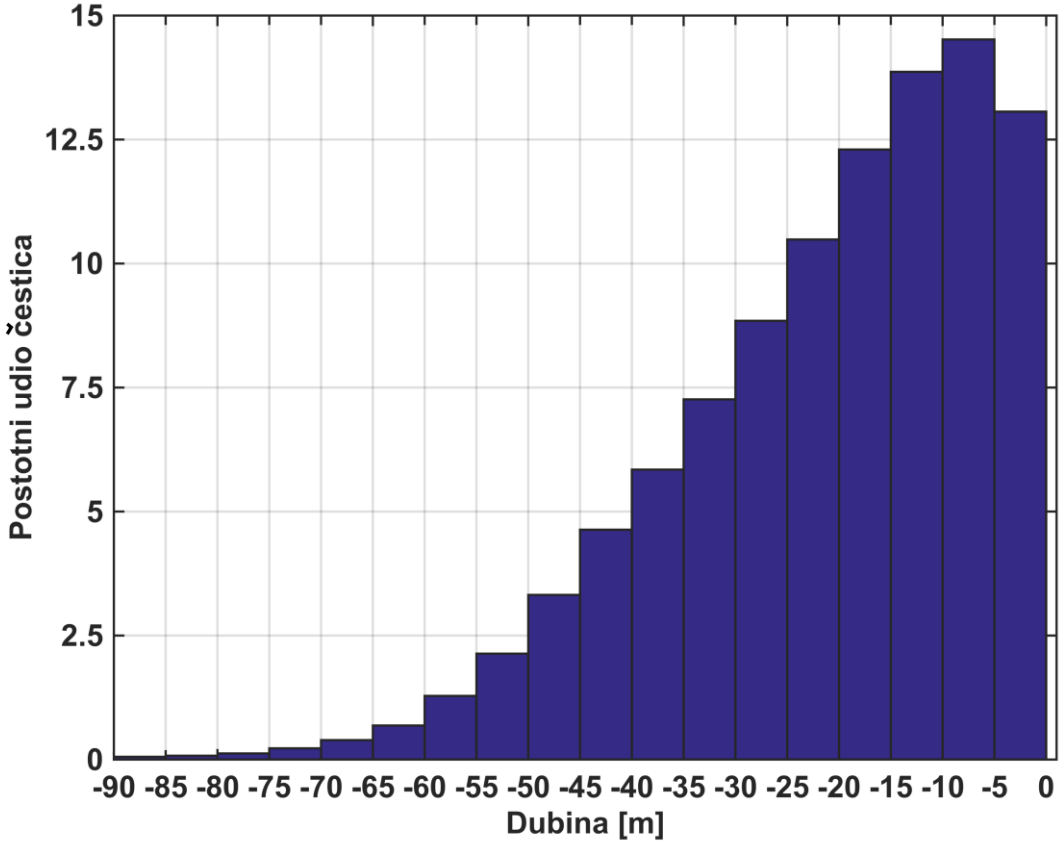

Slika 44. Ukupna razdioba čestica po dubini za cijeli period jadranske simulacije. Čestice su ispuštene s lokacija uzgajališta kod otoka Brača i Ugljana.

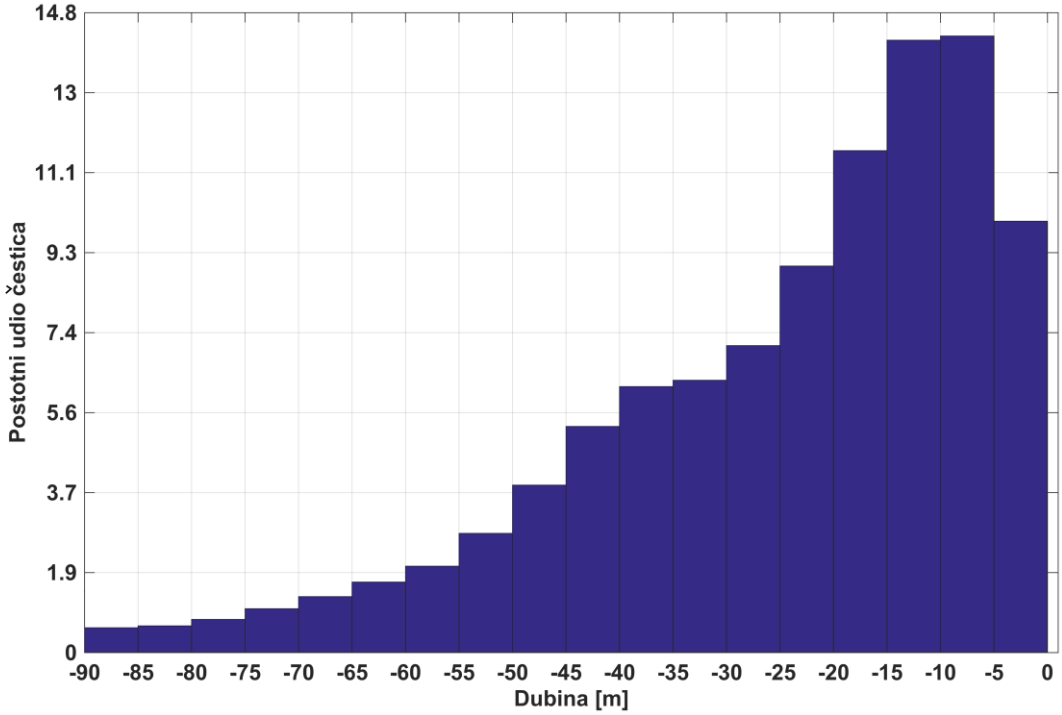

Slika 45. Ukupna razdioba čestica po dubini za cijeli period ASHELF-2 simulacije. Čestice su ispuštene s lokacije uzgajališta kod otoka Brača.

Prostorna raspodjela čestica u pokusu unaprijed (pokus 2., tablica 6.) je prikazana na kraju siječnja, veljače, ožujka, travnja i prve polovice svibnja kad završava jadranska simulacija za čestice ispuštene s lokacije kod otoka Brača (slika 46.) i kod otoka Ugljana (slika 47.). Raspodjela je prikazana za tri intervala dubina u kojima se nalazila većina čestica: od 0 do 5 m, od 5 do 15 m i od 25 do 35 m. Prostorna raspodjela čestica je prikazana samo za pokus 2. iz nekoliko razloga. Prostorne razdiobe dobivene u pokusima 1. i 2. su vrlo slične, a raspodjele iz pokusa 2. su realističnije zbog uvažavanja opcije naplavljivanja čestica na obalu. Nadalje, raspodjele iz pokusa 2. su najpogodnije za usporedbu s poljima LCS-ova jer su u oba slučaja polja pod dominantnim utjecajem struja, što nije slučaj i s raspodjelom iz pokusa 3. u kojem je određeni broj čestica eliminiran iz proračuna zbog preniskih temperatura. Na poljima srednjih mjesečnih strujanja u moru za mjesece siječanj, veljaču, ožujak, travanj i prvu polovicu svibnja 2016. godine dobivena su proračunom unaprijed FTLE polja (tablica 1.) (slika 48.). Polja struja na dubinama od 1 m, 10 m i 30 m su prikazana na slici 34. Metoda unaprijed je upotrijebljena s ciljem proračuna divergentnih područja, odnosno barijera koje utječu na prostornu raspodjelu čestica (Vaz i sur., 2013; Harrison i sur., 2013).

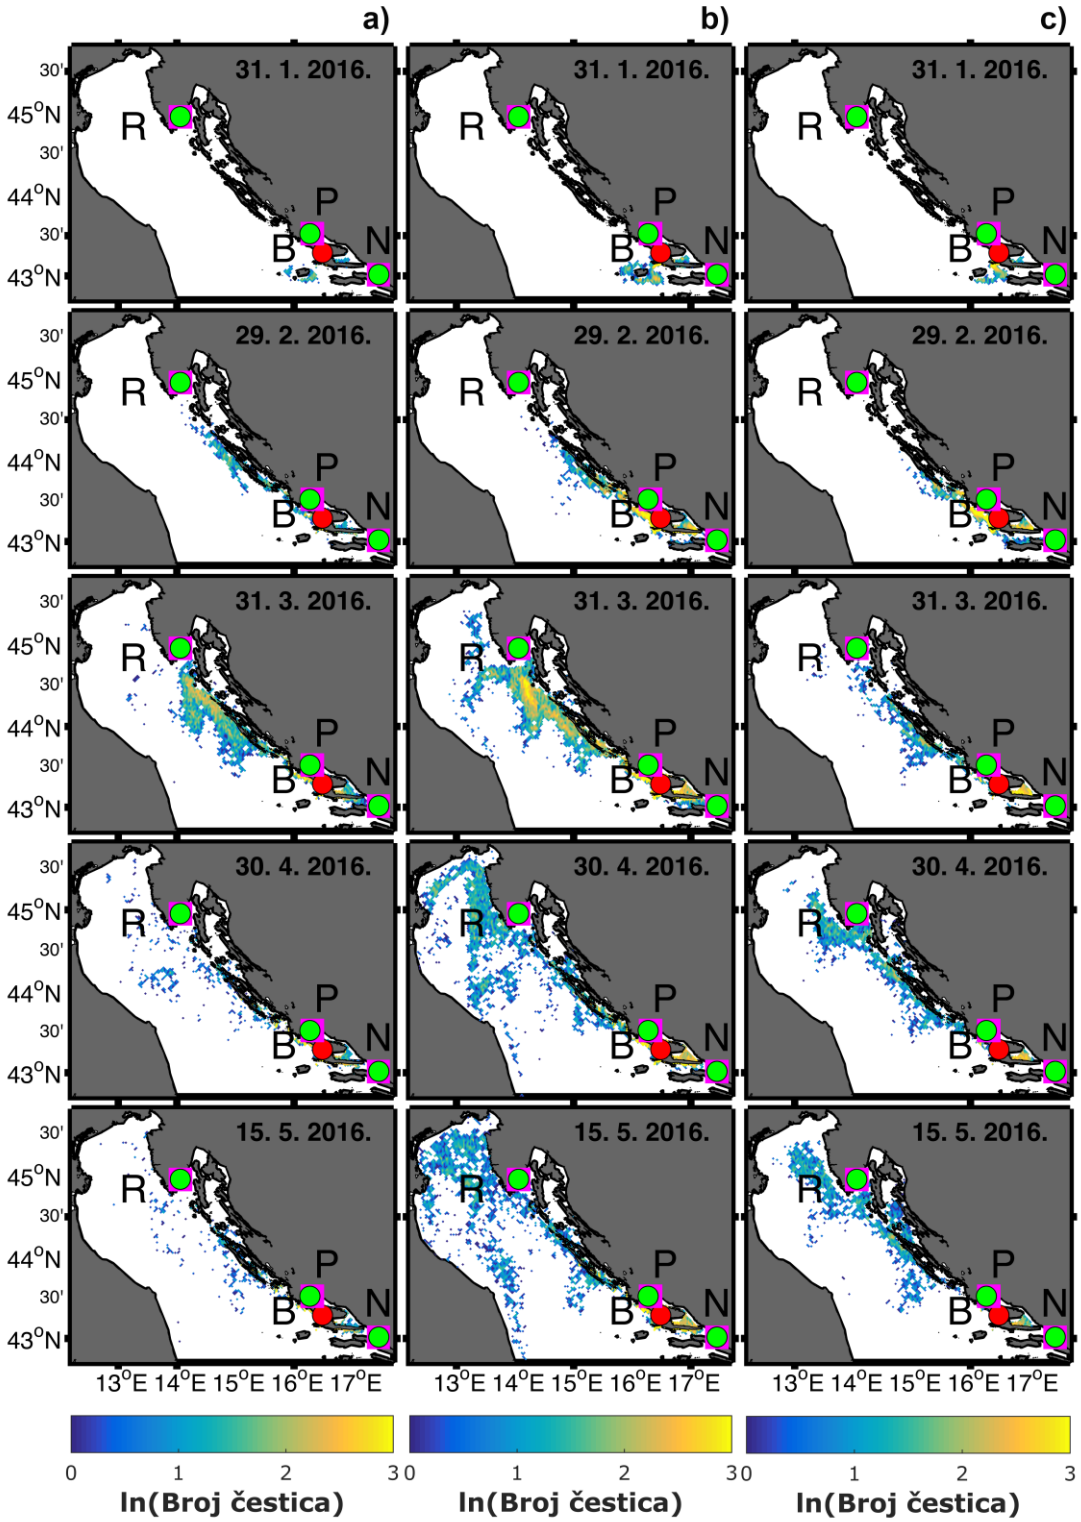

Slika 46. Prostorna raspodjela čestica na kraju siječnja, veljače, ožujka, travnja te na sredini svibnja 2016. godine. Raspodjela je dobivena u pokusu 2. za jadransku domenu u kojoj je s lokacije uzgajališta kod otoka Brača (B; crvena točka) svaki dan tijekom siječnja i veljače ispušteno 1000 čestica. Zelene točke predstavljaju lokacije rastilišta (R–Raša, N–Neretva, P–Pantan), dok su ružičasti kvadrati područja uspjeha u pokusu unaprijed. Razdioba je izračunata za tri raspona dubina: 0 - 5 m (stupac a), 5 - 15 m (stupac b) i 25 - 35 m (stupac c).

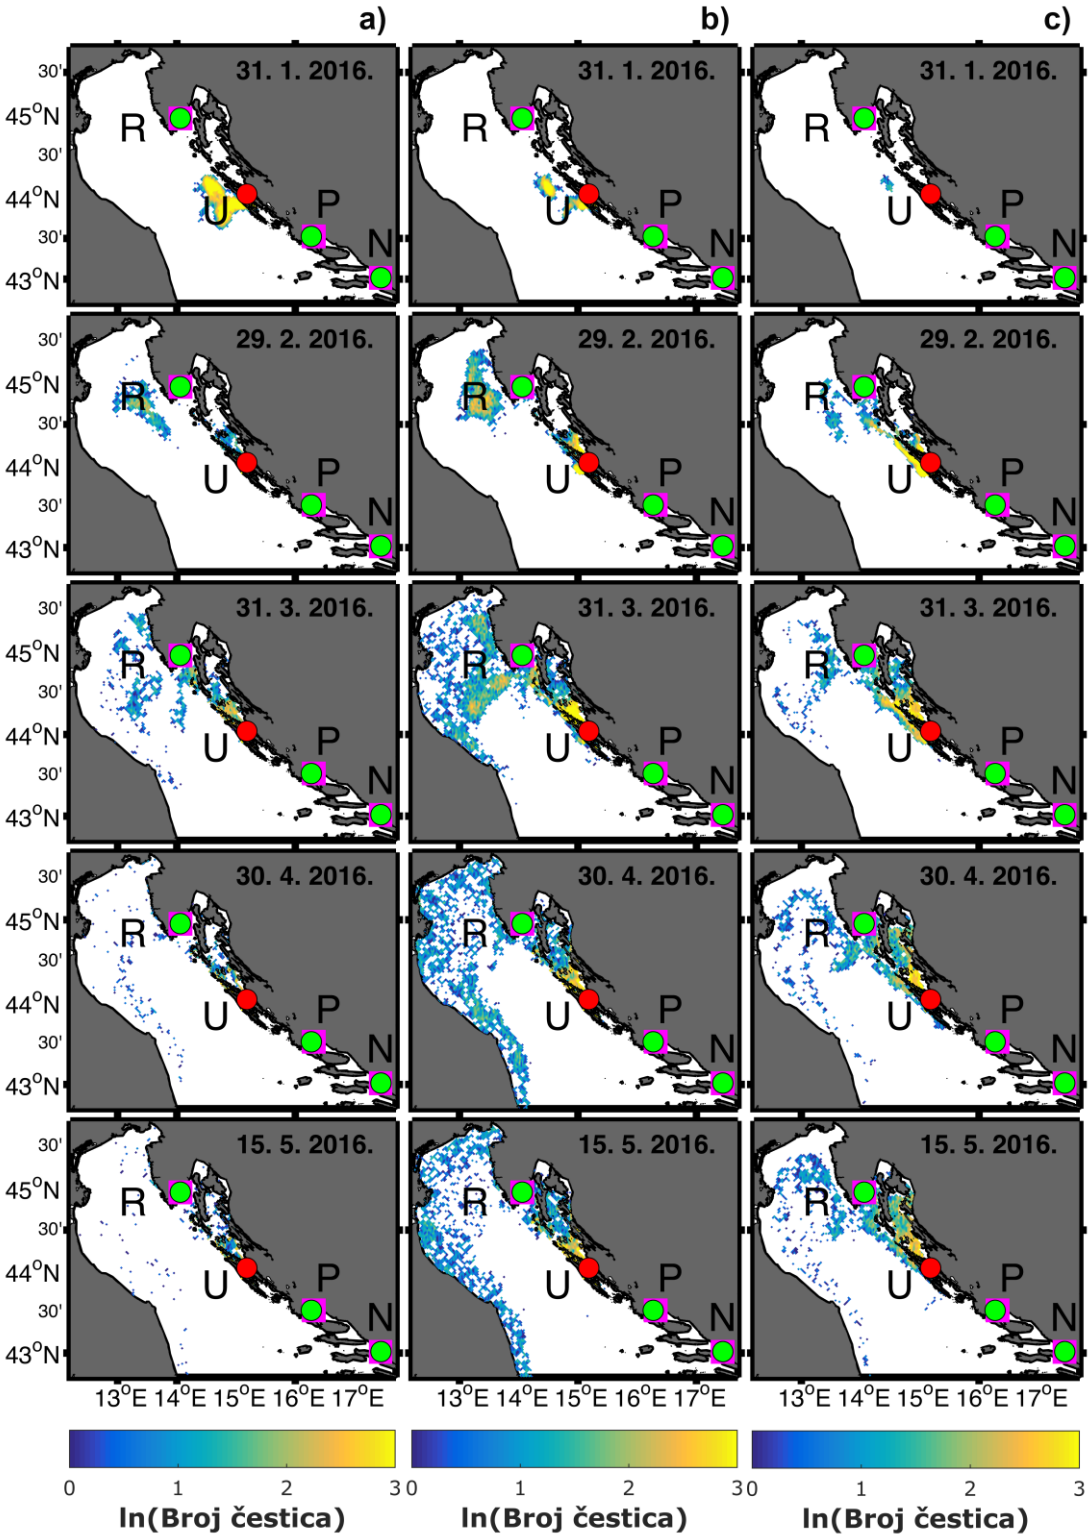

Slika 47. Prostorna raspodjela čestica na kraju siječnja, veljače, ožujka, travnja te na sredini svibnja 2016. godine. Raspodjela je dobivena u pokusu 2. za jadransku domenu u kojoj je s lokacije uzgajališta kod otoka Ugljana (U; crvena točka) svaki dan tijekom siječnja i veljače ispušteno 1000 čestica. Zelene točke predstavljaju lokacije rastilišta (R–Raša, N–Neretva, P–Pantan), dok su ružičasti kvadrati područja uspjeha u pokusu unaprijed. Razdioba je izračunata za tri raspona dubina: 0 - 5 m (stupac a), 5 - 15 m (stupac b) i 25 - 35 m (stupac c).

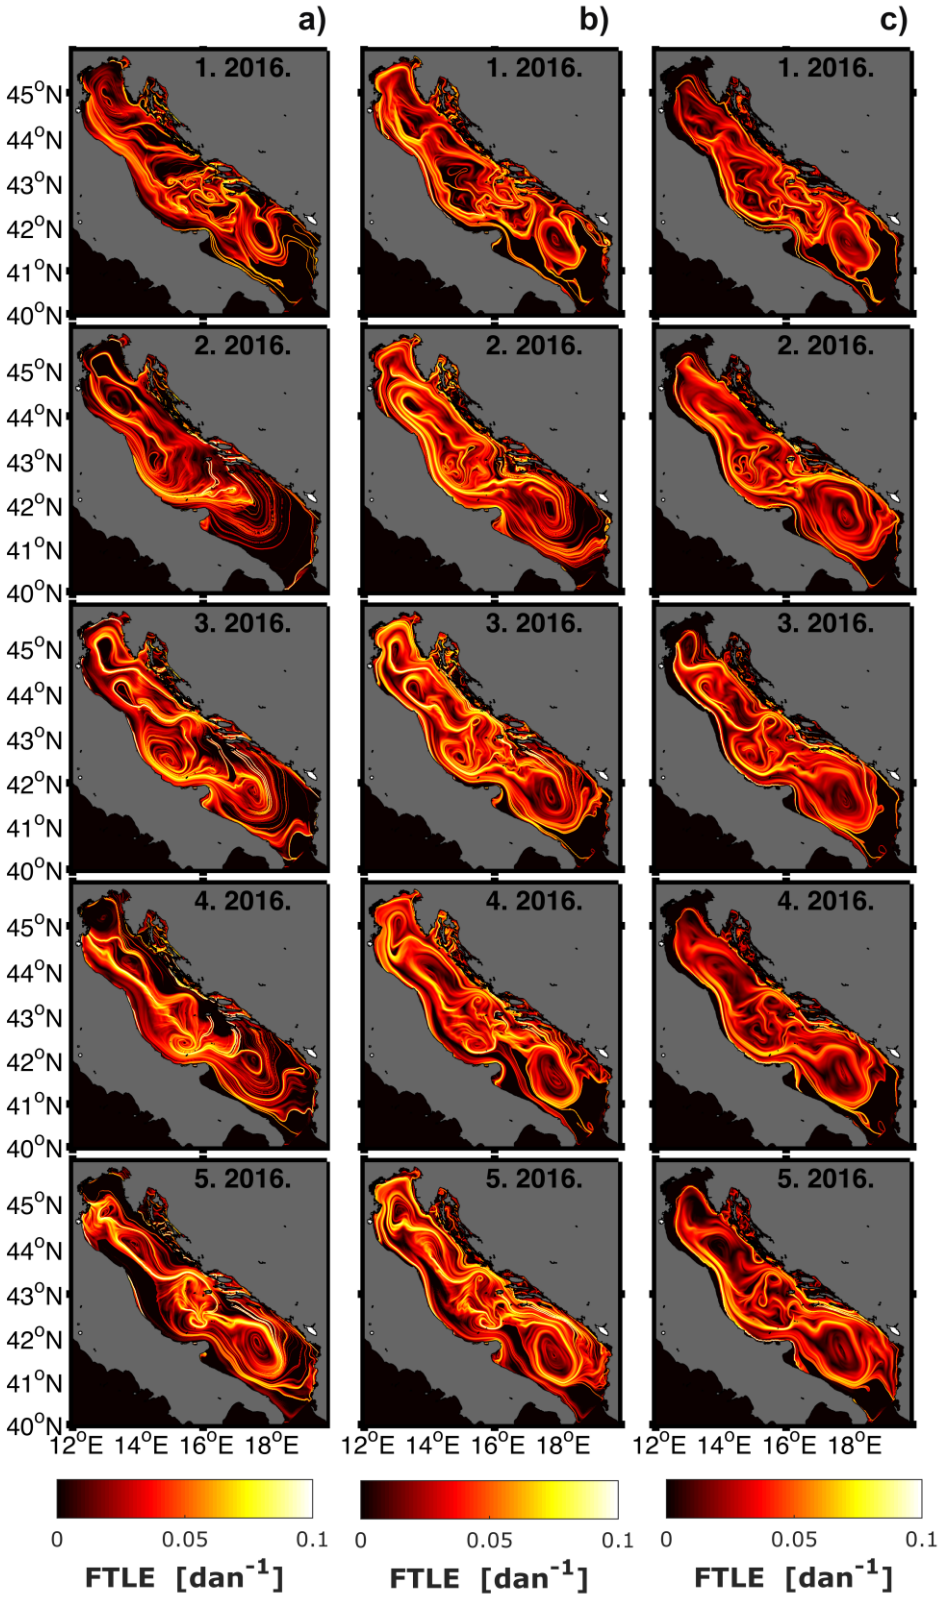

Slika 48. FTLE polja dobivena proračunom unaprijed u vremenu na poljima srednjih mjesečnih strujanja u moru za mjesece siječanj, veljaču, ožujak, travanj i prvu polovicu svibnja 2016. godine na tri dubine: 1 m (stupac a), 10 m (stupac b) i od 30 m (stupac c). Polja struja (slika 33.) su izračunata pomoću ROMS modela za jadransku domenu.

Dubine na kojima su izračunata FTLE polja su približno u sredini slojeva u vodenom stupcu na kojima su prikazane prostorne koncentracije čestica**.** Čestice ispuštene s otoka Brača na kraju siječnja su ostale zarobljene u neposrednoj blizini uzgajališta (slika 46.), kao i čestice ispuštane s otoka Ugljana (slika 47.). Iako mjesečni srednjak pokazuje prisutnost modelirane istočnojadranske obalne struje (slika 34.), do transporta prema sjeverozapadu nije došlo. Razlog je prisutnost barijere na svim dubinama sjeverno od lokacije Brača koja je spriječila transport prema SZ, odnosno barijere u blizini otoka Ugljana koja je usmjerila čestice prema otvorenom moru (slika 48.). Na kraju veljače dolazi do transporta čestica s lokacije kod otoka Brača ne samo prema Raši, gdje su čestice barijerom kanalizirane uz vanjske otoke srednjeg Jadrana, već i prema Pantanu te Neretvi. Uzrok tome je intenziviranje istočnojadranske obalne struje u veljači (slika 34.). Čestice s Ugljana na kraju veljače su transportirane do Raše, pri čemu jedan dio biva zarobljen u Kvarneriću, a drugi dio advektiran prema središnjem dijelu sjevernog Jadrana popunjavajući prostor između dvije odbojne barijere (slika 47.). Od ožujka do sredine svibnja sličan obrazac transporta za čestice podrijetlom s Ugljana uočen tijekom veljače se ponavlja. Veliki broj čestica je i dalje zarobljen u Kvarneriću zbog konstatnog postojanja odbojne barijere koja spriječava njihovo širenje po ostatku Jadrana. Čestice koje su se u veljači zatekle na sjeverenom Jadranu u sljedeća dva i pol mjeseca bivaju raspršene po cijelom Jadranu i pri tome veliki dio njih je nošen zapadnojadranskom strujom ka jugu u uskom obalnom području uz talijansku obalu (slika 34.). Čestice puštene s Brača u ožujku su imale najveću prostornu koncentraciju u srednjem i sjevernom Jadranu zapadno od Dugog otoka i Lošinja, pri tome ne prelazeći liniju na osi SZ-JI koja dijeli Jadran na dva dijela (slika 46.) zbog postojanja odbojnih struktura koje su organizirale transport u tom dijelu (slika 48.). U travnju i svibnju najveća koncentracija čestica s Brača je uz zapadnu obalu Istre (slika 46.), pri čemu položaj područja s maksimalnom koncentracijom čestica odgovara položaju vrtloga u sjevernom Jadranu koji se vidi u LCS-ovima na dubinama od 1 m i 10 m (slika 48.).

Prostorna raspodjela čestica (slika 49.) i FTLE polja (slika 50.) su izračunati za ASHELF-2 simulacije na isti način kao i za jadranske simulacije. Negativni faktor koji je imao velik utjecaj na mjesečne raspodjele, a time i na konačnu raspodjelu čestica 15. svibnja, je lokacija uzgajališta s južne strane otoka Brača (slika 33.). Uzgajalište se nalazi u neposrednoj blizini područja s istočnojadranskom strujom,

blizu je ruba domene, kao i područja u kojem prevladavaju snažna zapadna strujanja. Zbog toga je 99% čestica na kraju simulacije advektirano van granica domene.

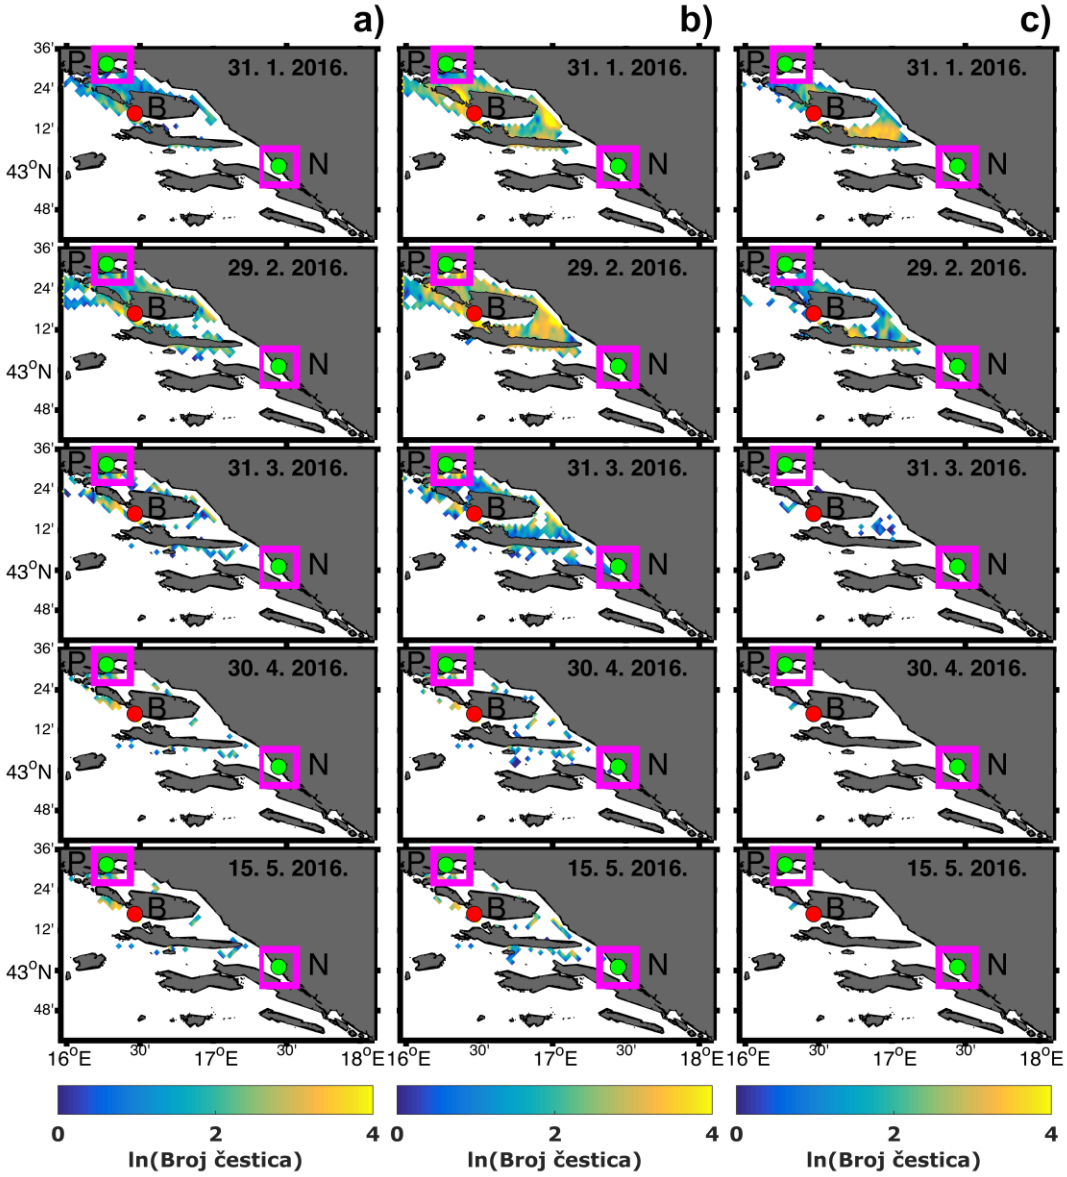

Slika 49. Prostorna raspodjela čestica na kraju siječnja, veljače, ožujka, travnja te na sredini svibnja 2016. godine. Raspodjela je dobivena u pokusu 2. za ASHELF-2 domenu u kojoj je s lokacije uzgajališta kod otoka Brača (B; crvena točka) svaki dan tijekom siječnja i veljače ispušteno 1000 čestica. Zelene točke predstavljaju lokacije rastilišta (N–Neretva, P–Pantan), dok su ružičasti kvadrati područja uspjeha u pokusu unaprijed. Razdioba je izračunata za tri raspona dubina: 0 - 5 m (stupac a), 5 - 15 m (stupac b) i 25 - 35 m (stupac c).

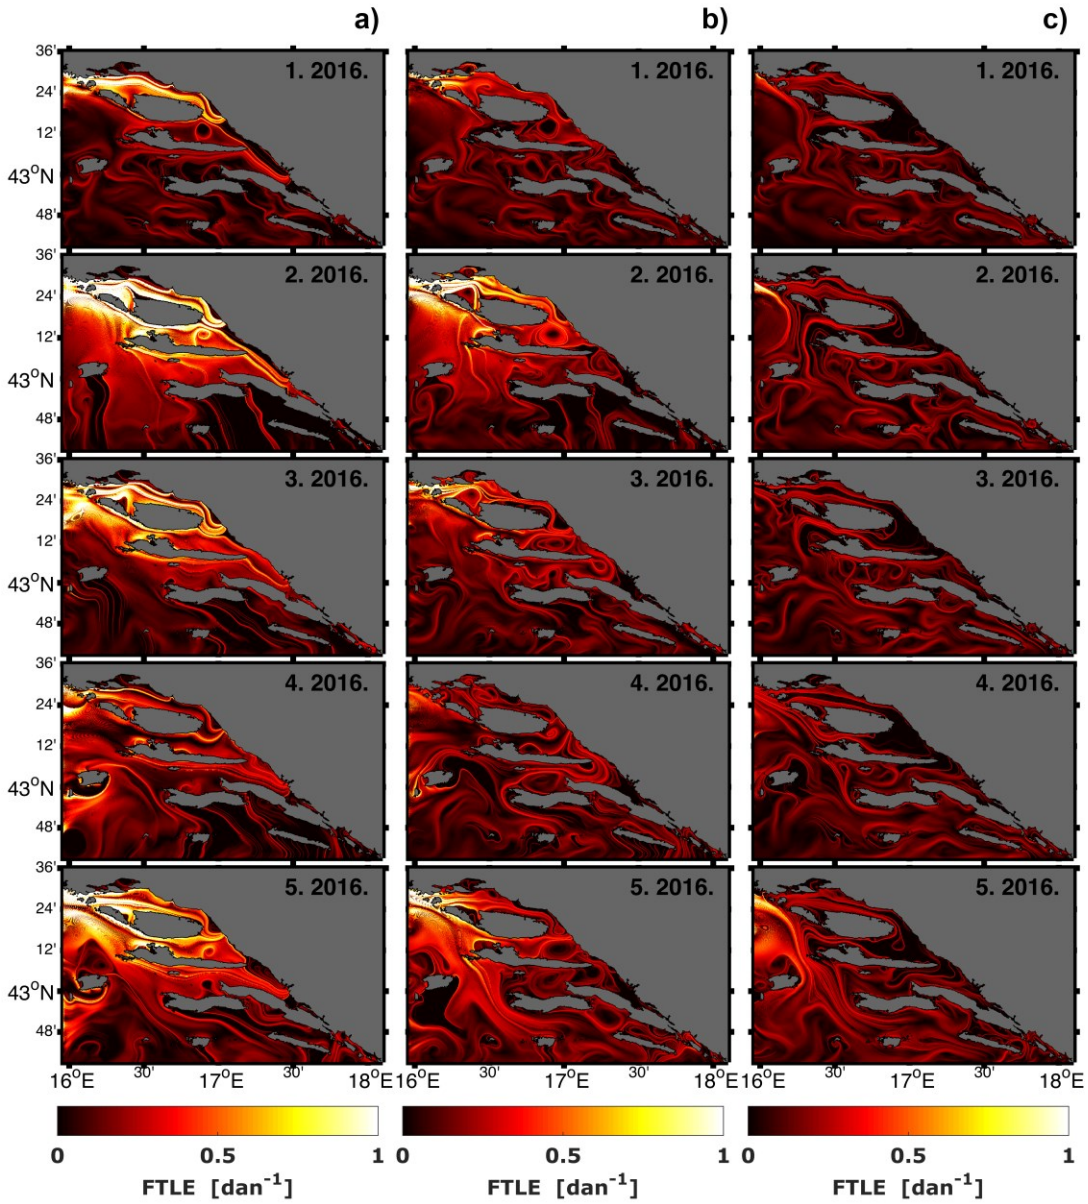

Slika 50. FTLE polja dobivena proračunom unaprijed u vremenu na poljima srednjih mjesečnih strujanja u moru za mjesece siječanj, veljaču, ožujak, travanj i prvu polovicu svibnja 2016. godine na tri dubine: 1 m (stupac a), 10 m (stupac b) i od 30 m (stupac c). Polja struja (slika 34.) su izračunata pomoću modela ROMS za ASHELF-2 domenu.

Prisutnost snažnog površinskog strujanja u uskim područjima između kopna i otoka se najbolje vidi po velikim FTLE iznosima u Splitskom kanalu (slika 50.).

Tijekom cijelog simuliranog razdoblja najveći broj čestica zadržava se u tri područja: Splitski kanal, južna strana Šolte i Brača, i prostor između istočnog dijela Brača i Hvara (slika 49.). Do transporta prema području uspjeha oko Pantana u Kaštelanskom zaljevu dolazi već krajem siječnja u prvih 15 m dubine. Čestice su

prisutne u blizini Pantana na istim dubinama i tijekom preostala tri i pol mjeseca. Pred kraj simulacije sve veći broj čestica biva advektiran van domene, što se vidi u sve manjim prostornim koncentracijama. Do transporta prema Neretvi dolazi krajem ožujka i pri tome je broj čestica daleko manji od onog u području uspjeha oko Pantana. Promjene u polju struja koje su transportirale čestice prema Neretvi ne mogu se razaznati na mjesečnom srednjaku. Mjesečna srednja strujanja pokazuju dominantno zapadni smjer u prvih 15 m na području između Brača i Neretva. U FTLE poljima mogu se uočiti barijere koje su zarobile čestice u Splitskom kanalu, uz južne obale Brača, Šolte i Hvara (slika 50.). FTLE polja tijekom prva tri mjeseca pokazuju u već prije spomenutom području između istočnog dijela Brača i Hvara prisustvo vrtloga (slika 50.) u kojem je zarobljen veći broj čestica, što se vidi u povećanoj prostornoj koncentraciji (slika 49.).

Dodatna potvrda uspješnosti disperzijskih simulacija unaprijed u vremenu u obje domene napravljena je simulacijama unazad u vremenu (pokus 4., tablica 6.). U simulacijama unazad provedeni su samo lagrangeovski pokusi s pasivnim česticama s uključenom opcijom naplavljivanja čestica. Motivacija za provođenje pojednostavljenih pokusa je bila povezivanje putanja čestica unazad s konvergentnim lagrangeovskim koherentnim strukturama. Konvergentne strukture se računaju primjenom FTLE metode unazad u vremenu. Linije izračunate FTLE metodom unaprijed pokazuju područja odnosno prostorne strukture na kojima se najveći broj čestica nakuplja. U pokusima unazad čestice su puštane s lokacija sva tri rastilišta (Neretva, Pantan i Raša) s ciljem utvrđivanja povezanosti s uzgajalaštima kod Ugljana i Brača u jadranskoj domeni (slika 51.), odnosno s dva rastilišta (Neretva i Pantan) i uzgajalištem kod Brača u ASHELF-2 domeni (slika 52.). Prostorna raspodjela nije prikazana na kraju simuliranog perioda (1. siječnja 2016. godine), već je prikazano 10% svih putanja koje se nalaze na određenim rasponima dubine tijekom cijelog simuliranog razdoblja. Putanje čestica koje su puštene s lokacija Pantan i Neretva u jadranskoj domeni nisu prikazane, iako je došlo do transporta do Brača (slika 53.) jer je u jadranskoj domeni glavni naglasak na povezanosti Ugljana i Raše. S druge strane, povezanost u obalnom području istočnog dijela Jadrana analizirana je detaljnije u ASHELF-2 domeni.

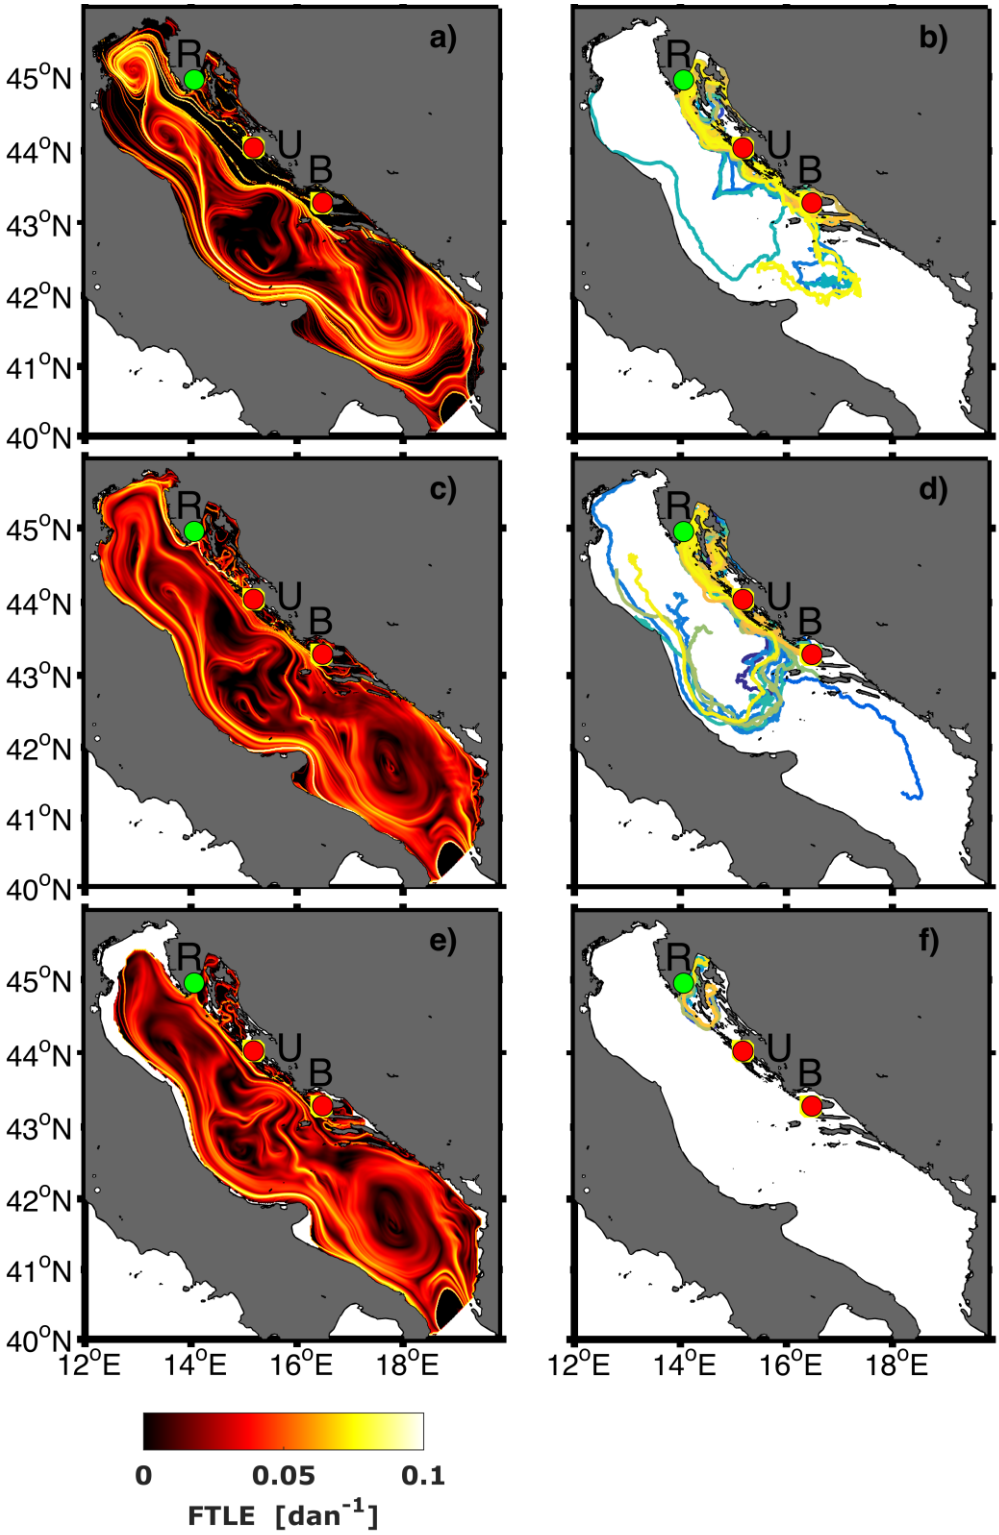

Slika 51. FTLE polja dobivena proračunom unazad u vremenu na strujnom polju usrednjenom za cijelo razdoblje trajanja jadranske simulacije (1. siječnja - 15. svibnja 2016. godine) na dubinama: 1 m (a), 10 m (c) i 30 m (e). Putanje čestica u pokusu unazad (pokus 4., tablica 6.) ispuštenih s lokacije rastilišta kod Raše (R; zeleni kružić) koje se nalaze na dubinama od 0 - 5 m (b), 5 - 15 m (d) i 25 - 35 m (f). Prikazana je svaka deseta putanja od ukupno 1727 u prvom rasponu dubina, 1875 u drugom i 117 u trećem. Različite putanje obojane su različitim bojama. Crveni kružići smješteni u žute kvadrate uspjeha su lokacije uzgajališta Ugljan (U) i Brač (B).

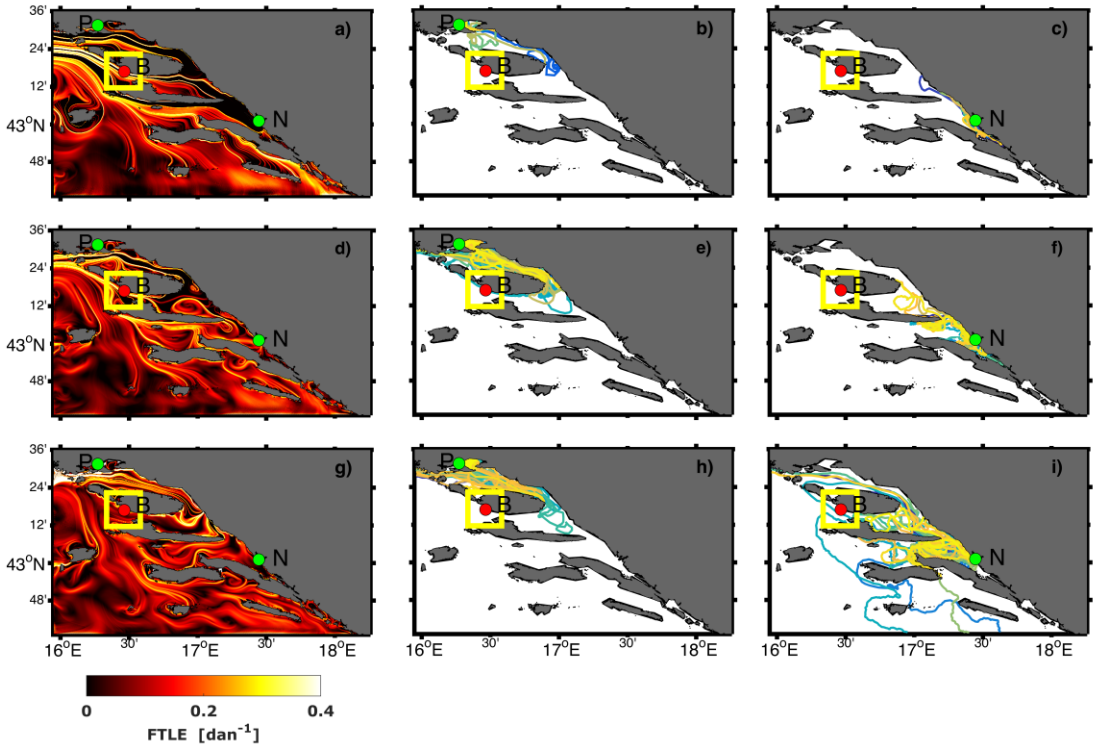

Slika 52. FTLE polja dobivena proračunom unazad u vremenu na strujnom polju usrednjenom za cijelo razdoblje trajanja ASHELF-2 simulacije (1. siječnja - 15. svibnja 2016. godine) na dubinama: 1 m (a), 10 m (d) i 30 m (g). Putanje čestica u pokusu unazad (pokus 4., tablica 6.) ispuštenih s lokacije rastilišta kod Pantana (P; zeleni kružić) i Neretve (N; zeleni kružić) koje se nalaze na dubinama 0 - 5 m (b), od 5 - 15 m (d) i 25 - 35 m (f). Prikazana je svaka deseta putanja od ukupno 156 u prvom rasponu dubina, 1687 u drugom i 550 u trećem. Različite putanje obojane su različitim bojama. Crveni kružić smješten u žuti kvadrat uspjeha je lokacija uzgajališta Brač (B).

Za raspon dubine od 0 do 5 m odabrane su sve čestice čija je srednja vrijednost dubine na kojoj su se nalazile tijekom cijele simulacije bila u rasponu između 0 i 2 m, a standardna devijacija je bila manja od 4 m. Za raspon dubine od 5 do 15 m, srednja vrijednost dubine je morala biti u rasponu od 8 do 12 m, a standardna devijacija manja od 4 m. Za raspon dubina od 25 do 35 m srednja vrijednost je bila od 18 do 32 m, a standardna devijacija je bila manja od 6 m. U grafičkom prikazu radi preglednosti odabrana je svaka deseta putanja. Na taj način je i grafički pokazano da je najveći broj čestica bio u sloju od 5 do 15 m u obje simulacije. Jadranska simulacija je imala veći broj čestica u površinskom sloju (slika 51.) u usporedbi s ASHELF-2 simulacijom (slika 52.), dok je sloju od 25 do 35 m bilo obrnuto. FTLE polja su dobivena proračunom unazad u vremenu na strujnom polju usrednjenom za cijelo vrijeme trajanja jadranske (slika 51.) i ASHELF-2 (slika 52.)

simulacije. Dubine na kojima je FTLE izračunat su 1 m, 10 m i 30 m i nalaze se otprilike na sredini slojeva u kojima su izračunate raspodjele čestica.

U jadranskoj simulaciji unazad, putanje čestica koje su većinu simulacije putovale u vodenom stupcu na rasponu dubina od 0 do 5 m odnosno od 5 do 15 m, su prošle kroz područja uspjeha za uzgajališta Ugljan i Brač (slika 51.b, d). Putanje čestica su se grupirale duž istočne obale slijedeći privlačnu lagrangeovsku kohrentnu strukturu. Nailaskom na područje u blizini rta Planka neke su čestice prešle na suprotnu stranu Jadranu i pritom nastavile putovati prema SZ na privlačnim LCS-ovima duž talijanske obale. U najdubljem promatranom sloju čestice su slijedile privlačne LCS-ove koji su ih odveli u Kvarnerić. Transporta do uzgajališta nije bilo.

U ASHELF-2 simulaciji unazad putanje čestica porijeklom s Pantana su bile koncentrirane u Splitskom kanalu na svim promatranim rasponima dubina (slika 52.b, e, h) na ili u neposrednoj blizini privlačnih LCS-ova u Splitskom kanalu (slika 52.a, d, g). Čestice podrijetlom s Neretve koje su provele najveći dio svog puta na dubinama od 25 do 35 m su došle u područje uspjeha kod uzgajališta u blizini Brača (slika 52.i).

Izračunata su dva vremenska niza broja čestica u kvadratu uspjeha u pokusima unazad: vremenski niz naplavljenih čestica i vremenski niz razlike zatečenih i naplavljenih čestica (slika 53.). Kvadrati uspjeha za simulacije unazad su konstruirani na isti način kao i za simulacije unaprijed. U središtu kvadrata uspjeha se nalazilo uzgajalište (Brač ili Ugljan) (slika 33.). Svaka stranica kvadrata bila je duga 20 km. Brojanje čestica u simulacijama unazad u kvadratu uspjeha počelo je 28. veljače, zadnjeg dana ispuštanja čestica, a završilo je 1. siječnja 2016. godine, prvog dana ispuštanja čestica. Radi davanja jednake težine svakom kvadratu uspjeha, broj zatečenih odnosno naplavljenih čestica u jednom danu je pomnožen s postotkom mokrih točaka. Kontinuiranost transporta čestica u pokusu unazad do lokacija uzgajališta je kvantificirana razlikom zatečenih i naplavljenih čestica u pripadajućem kvadratu uspjeha (slika 53.). Broj zatečenih čestica u kvadratu uspjeha je zbroj naplavljenih čestica i čestica koje su slobodne u tom kvadratu. Slobodne čestice mogu biti advektirane morskim strujama u sljedećem vremenskom koraku. Broj naplavljenih čestica je kumulativan i raste s približavanjem kraja simulacije unazad. Na dan 29. veljače (slika 53.) je prikazan broj čestica naplavljenih u blizinu uzgajališta izvan razdoblja mrijesta.

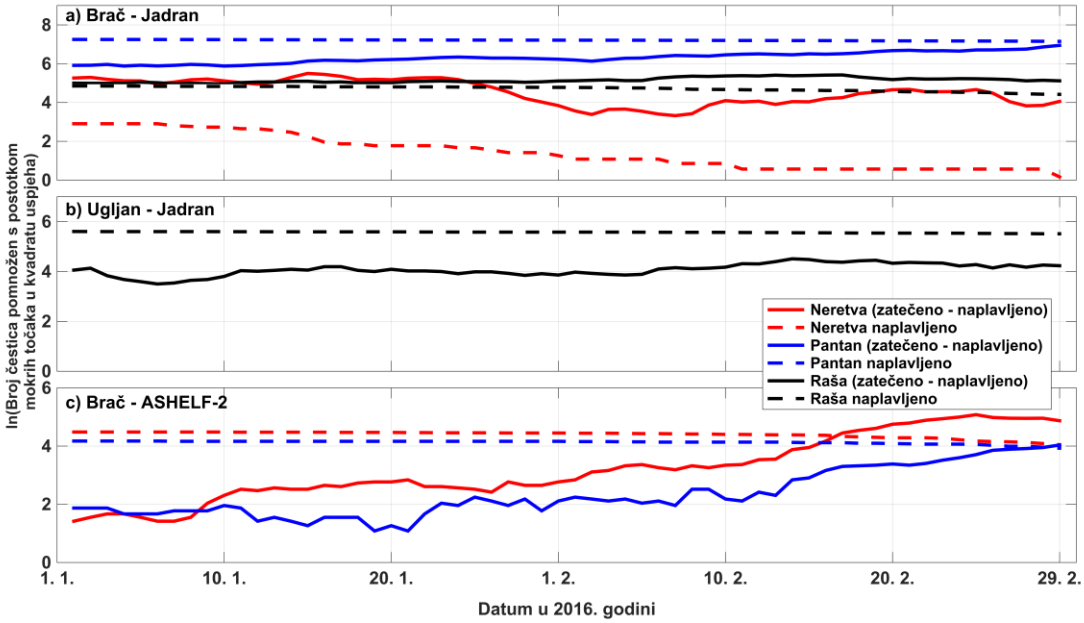

Slika 53. Vremenski nizovi broja čestica u simulaciji unazad (pokus 4., tablica 6.) unutar kvadrata uspjeha koji obuhvaća područje oko uzgajališta kod otoka Brača (a) i otoka Ugljana (b) u jadranskoj simulaciji, odnosno otoka Brača u ASHELF-2 simulaciji (c). Pune linije su razlike zatečenih i naplavljenih čestica unutar kvadrata uspjeha, dok su iscrtkane linije naplavljene čestice unutar kvadrata uspjeha. U svakom od pokusa unazad ispušteno je 59000 čestica 15. svibnja s lokacija rastilišta Neretva (crvene linije), Pantan (plave linije) i Raša (crne linije). Broj čestica je pomnožen s težinskim faktorom koji je jednak postotku mokrih točaka za svaki od kvadrata uspjeha u pokusu unazad.

U jadranskom pokusu unazad najviše slobodnih čestica u kvadrat uspjeha kod otoka Brača je došlo s Pantana, potom s ušća Neretve i na kraju s ušća Raše (slika 53. a). Porast broja naplavljenih čestica ispuštenih kod Neretve počinje tek nakon 29. veljače. U slučaju uzgajališta kod otoka Ugljana simulacija unazad je dala isti rezultat kao i simulacija unaprijed (slika 53.b). Ugljan je jedino povezan s Rašom (slika 20.b). Za ASHELF-2 simulaciju broj slobodnih čestica u blizini Brača opada s približavanjem kraja simulacije (slika 53.c). Za razliku od jadranske, u ASHELF-2 simulaciji nema zamjetne razlike u broju naplavljenih čestica pridošlih s Neretve i Pantana.

4.4. Diskusija

Na uspješnost transporta ihtioplanktona od područja mrijesta do područja rastilišta odlučujući faktor ima morski okoliš (Dias i sur., 2014; Huggett i sur., 2003). Lokacija mrijesta i vremenski trenutak ispuštanja jaja su čimbenici koji povećavaju ili smanjuju vjerojatnost transporta (Soto-Mendoza i sur., 2012; Santos i sur., 2018). Temperatura mora u kojem se nalazi ihtioplankton može ne samo usporiti njegov rast, već može dovesti i do ugibanja jedinke tijekom transporta ka rastilištu (Ospina-Álvarez i sur., 2013; Vikebø i sur., 2005). Da bi došlo do novačenja jedinke u odrasli stadiji, u rastilištu moraju biti zadovoljeni uvjeti za dovoljno dugo zadržavanje jedinki (Chen i sur., 1997; Lett i sur., 2007).

Ulov stotinjak dana starih jedinki komarče 15. svibnja na lokacijama rastilišta u Jadranskom moru tijekom rutinskog nadzora je otvorio pitanje povezanosti lokacija rastilišta s lokacijama mrijesta. Dodatna motivacija za istraživanje je utvrđena genetska povezanost između uhvaćenih jedinki s populacijom komarči, koja obitava u neposrednoj blizini uzgajališta tuna na Braču i Ugljanu (rad u pripremi za objavu). Kombinacija genetskih i fenotipskih analiza zajedno s numeričkim modeliranjem cirkulacije i disperzije ihtioplanktona je već primijenjena u Jadranskom moru u istraživanju opisanom u prethodnom poglavlju i objavljenom u radu Džoića i sur. (2017). Istovjetan multidisciplinarni pristup se koristio i u istraživanju transatlantskih obrazaca povezanosti kornjača (Naro-Maciel i sur., 2017) i u istraživanju korelacije između genetske i hidrodinamičke povezanosti algi (Thibaut i sur., 2016).

4.4.1. Ovisnost o danu ispuštanja čestica, tj. danu mrijesta

Rezultati simulacija pokazali su povezanost između uzgajališta kod Brača s rastilištima uz ušća Neretve, Rike (močvara Pantan) i Raše, te uzgajališta kod Ugljana s rastilištem uz ušće Raše (slika 33.). Postotak čestica u blizini rastilišta na dan 15. svibnja 2016. godine u iznosu od 1% ukupno ispuštenih čestica odgovara postotku jedinki komarče za koje je genetska analiza utvrdila da imaju sličnost s roditeljima lociranim u blizini uzgajališta (rad u pripremi za objavu). No ono što su rezultati simulacija pokazali je prostorno-vremenski slijed transporta čestica od uzgajališta ka rastilištu (slika 46., 47., i 48.). Utjecaj iznosa i smjera morskih struja je posebice

vidljiv na primjeru istočnojadranske struje u siječnju i veljači (slika 34.). Na kraju siječnja čestice puštene s otoka Brača su bile raspoređene u blizini uzgajališta, dok transporta prema sjeveru nije bilo (slika 46.). Uzrok tome je postojanje divergentnih barijera sjeverno od Brača, koje su spriječavale transport uzduž istočne jadranske obale prema sjeverozapadu (slika 48.). U veljači istočnojadranska struja intenzivira se u površinskom dijelu (slika 34.) i čestice su transportirane u neposrednu blizinu Raše (slika 46.). S ovakvom zavisnošću ukupnog mjesečnog transporta o prevladavajućim hidrodinamičkim uvjetima, koji potom generiraju barijere za transport čestica, otvara se novo pitanje: može li se izračunati uspješnost transporta čestica zavisna o danu ispuštanja?

Odgovor na to pitanje ima i biološku važnost. Komarče su riblja vrsta s parcijalnim mrijestom. Parcijalni mrijest označava mrijest u kojem se jedinka ne mrijesti u kratkom periodu, već se ona mrijesti svakodnevno kroz dugi period, u slučaju komarče od početka siječnja do kraja veljače (Ibarra-Zatarain i Duncan, 2015). Ženke komarče svaki dan tijekom mrijesta ispuste između 20000 i 80000 jajašaca (Cabrita i sur., 2008). Na taj način povećavaju vjerojatnost njihovog preživljavanja u hidrodinamičkoj okolini s izraženom prostorno-vremenskom varijabilnosti.

Odgovor na pitanje o zavisnosti uspjeha transporta o danu ispuštanja je dobiven sortiranjem čestica zatečenih u blizini rastilišta 15. svibnja (slika 43.) po danu ispuštanja čestica sa svake lokacije uzgajališta (slika 54.). U jadranskom modelu jedino kod transporta od Brača prema Neretvi ne postoji kontinuiranost (slika 52.b), koja se vidi na drugim relacijama transporta (slika 54.a, c i d). Primjena ugniježđenog ASHELF-2 modela s finijom rezolucijom potvrđuje kontinuiranost transporta na relaciji Brač–Pantan, ali pri tome broj pristiglih čestica nije ravnomjeran već se događa u pulsevima od kojih su najuočljiviji oni oko 5. i 20. siječnja (slika 54.e). Za primijetiti je porast broja transportiranih čestica od Brača prema Pantanu pri korištenju ASHELF-2 modela. I kod ASHELF-2 domene odlika transporta prema Neretvi je dolazak čestica u pulsevima s obzirom na dan ispusta čestica. Ukupni broj čestica koje su došle do ušća Neretve je isti u obje modelske realizacije, pri čemu je u ASHELF-2 domeni povećan transport čestica ispuštenih na kraju razdoblja mrijesta.

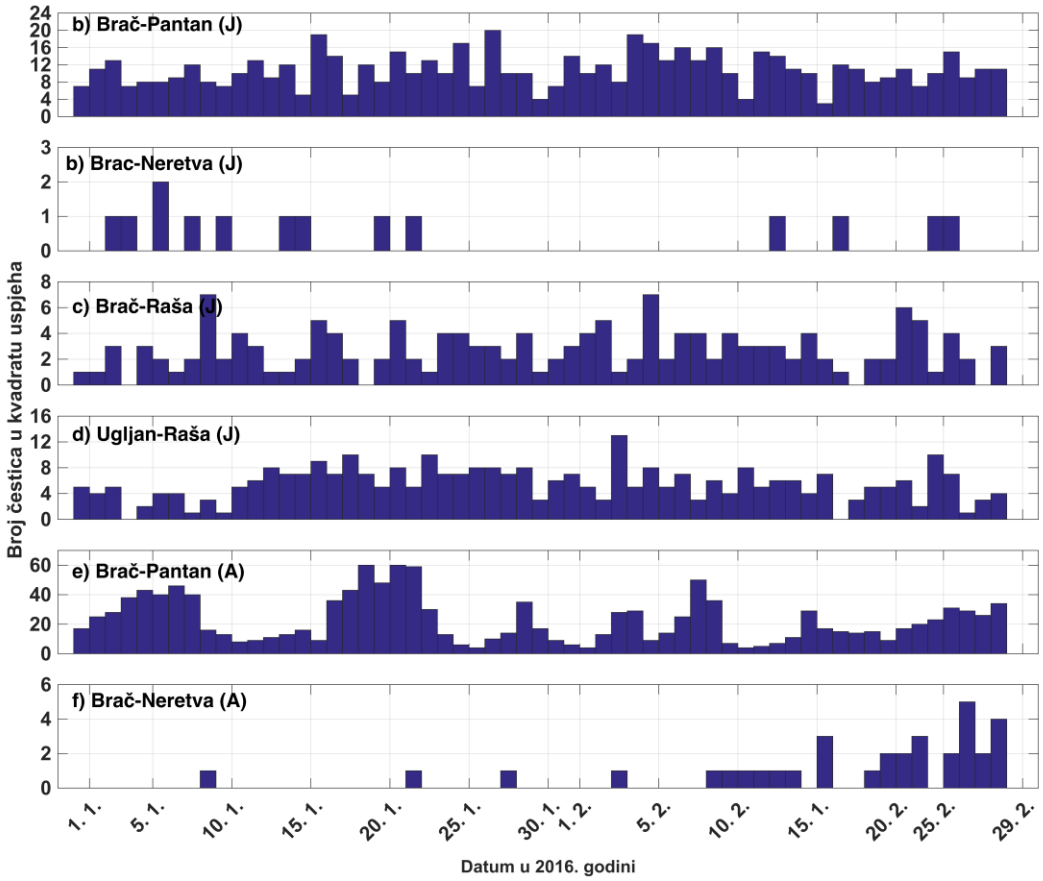

Slika 54. Raspodjela čestica zatečenih u kvadratu uspjeha zavisna o danu ispuštanja. Raspodjela je prikazana za čestice ispuštene u jadranskoj simulaciji (J) s Brača i transportirane do Pantana, Neretve i Raše (a, b, c), za čestice ispuštene u jadranskoj simulaciji s Ugljana i transportirane do Raše (c) i za čestice ispuštene u ASHELF-2 (A) simulaciji s Brača i transportirane do Pantana (e) i Neretve (f).

4.4.2. Ovisnost o sinoptičkoj situaciji

Odgovor na pitanje zašto je u pojedinim danima transport uspješniji nego u ostalim danima, odnosno zašto korištenje ASHELF-2 domene s finijom rezolucijom rezultira uspješnijim transportom u usporedbi s jadranskom domenom, potražen je analizom dviju karakterističnih vremenskih situacija. Zimsko razdoblje, koje obuhvaća prva tri mjeseca trajanja simulacije, karakterizirano je najjačim vjetrovima nad Jadranom, burom i jugom. Bura je hladni, obično suhi, vjetar sjeveroistočnog smjera čija srednja brzina rijetko prelazi 30 m/s, pri čemu maksimalni udari mogu doseći i do 50 m/s (Lepri i sur., 2017; Belušić i Klaić 2004, 2006; Belušić i sur., 2013) pri čemu bura može trajati od nekoliko sati do nekoliko dana (Jurčec, 1980; Enger i Grisogono, 1998; Kuzmić i sur., 2015). Jugo puše s jugoistoka tipičnom

brzinom od 10 m/s i donosi topli, vlažni mediteranski zrak nad Jadran (Brzović i Mahović, 1999). Znanstveno istraživanje modeliranjem je napravljeno za utjecaje bure i juga na cijeli jadranski bazen (Orlić i sur., 1994; Pullen, 2003), procese nastanka guste vode u Jadranu (Janeković i sur., 2014; Vilibić i sur., 2016) i ciljana istraživanja u obalnom sjeveroistočnom (Vilibić i sur., 2018) i srednjem dijelu Jadrana (Orlić i sur., 2006a, Klaić i sur., 2011). Tijekom siječnja, veljače i ožujka 2016. godine zabilježene su snažne epizode juga i bure (potpoglavlje 4.3.1.). Za analizu je odabrana epizoda jakog juga 8. ožujka (slika 55.a) i jake bure 13. ožujka 2016. godine (slika 55.b).

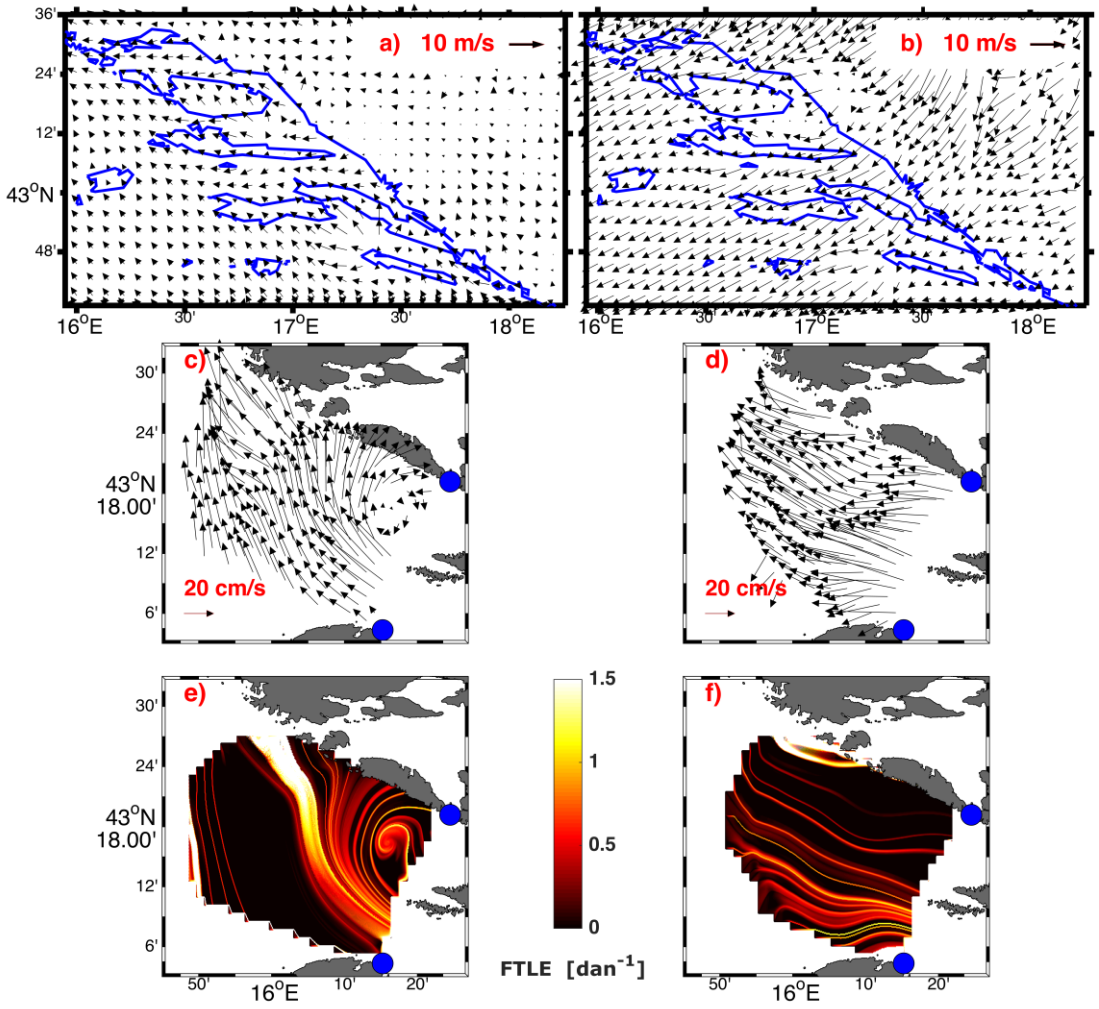

Slika 55. Srednje dnevno polje vjetra na 10 m dobiveno modelom ALADIN prikazano nad ASHELF-2 domenom za dvije karakteristične vremenske situacije: jugo 8. ožujka 2016. godine (a) i buru 13. ožujka (b). Prikazan je svaki treći vektor vjetra. Srednje dnevno polje morskih struja izmjereno VHF radarima za iste vremenske situacije: jugo (c) i bura (d). Plave točke su lokacije radarskih postaja na Visu i Braču. Prikazan je svaki treći vektor morskog strujanja. Izračunato FTLE polje na srednjem dnevnom radarskom polju struja za jugo (e) i buru (f).

Vjetar je prikazan nad ASHELF-2 domenom za koju postoje rezultati i jadranskog i ASHELF-2 ROMS modela, a na istom području su dostupna radarska mjerenja površinskih morskih struja (slika 55.c, d) s kojima se može napraviti direktna usporedba modeliranih struja. Također se u ASHELF-2 domeni nalazi jedno od dva uzgajališta i dva od tri rastilišta. Za istu domenu je provedeno intenzivno modeliranje u okviru projekata ADRICOSM i ECOOP (Orlić i sur., 2006a; Klaić i sur., 2011). Kako se istraživanje provodi za zimsko i proljetno razdoblje, odabrane su dvije epizode jakog vjetra i strujanja u moru s ciljem prikaza jednog dijela dinamičkih procesa koji su se odvijali u atmosferi i moru i pritom utjecali na transport čestica.

Analiza utjecaja vjetra promatrana je za 8. i 13. ožujka 2016. god. na srednjim dnevnim vrijednostima morskih struja izmjerenih radarom (slika 55.c, d), LCS-ovima izračunatim na tim istim radarskim poljima (slika 55.e, f), modeliranim srednjim dnevnim poljima morskih struja na jadranskoj i ASHELF-2 domeni (slike 56. i 58.), LCS-ovima izračunatim na tim modeliranim strujnim poljima (slike 57. i 59.) i prostornoj raspodjeli čestica ispuštenih 26., 27. i 28. veljače (slike 57. i 59.). Također je ta analiza poslužila za usporedbu dvije modelske izvedbe.

Pod utjecajem juga u polju površinskih struja formira se sjeverozapadna struja koja u blizini južne obale Šolte zakreće prema zapadu da bi formirala mali anticiklonalni vrtlog (slika 55.c). Izračunato FTLE polje pokazuje divergentnu barijeru koja dijeli radarsko područje na dva dijela i proteže se u smjeru sjeverozapada zajedno s barijerima koje ukazuju na postojanje vrtloga u strujnom polju (slika 55.e). Pod utjecajem bure formira se sjeverozapadna struja (slika 55.d) koju LCS-ovi dijele na nekoliko područja (slika 55.f). U poljima struja (slike 56. i 58.) i iz njih izračunatih FTLE polja najbolje se vide poboljšanja (slike 57. i 59.) koja su nastala zbog korištenja finije rezolucije u ASHELF-2 domeni. Iako ASHELF-2 u slučaju juga nije uspio reproducirati površinski anticiklonalni vrtlog iz radarskih mjerenja, uspio je reproducirati varijabilnost u sjeverozapadnoj površinskoj struji koja se ne vidi u jadranskom modelu. Anticiklonalni vrtlog je reproduciran u potpovršinskom sloju ASHELF-2 domene nešto zapadnije od vrtloga iz radarskih mjerenja (slika 56.c i e) Za puhanja bure nema velike razlike između rezultata modela u usporedbi s mjerenjima koja daju snažnu sjeverozapadnu struju.

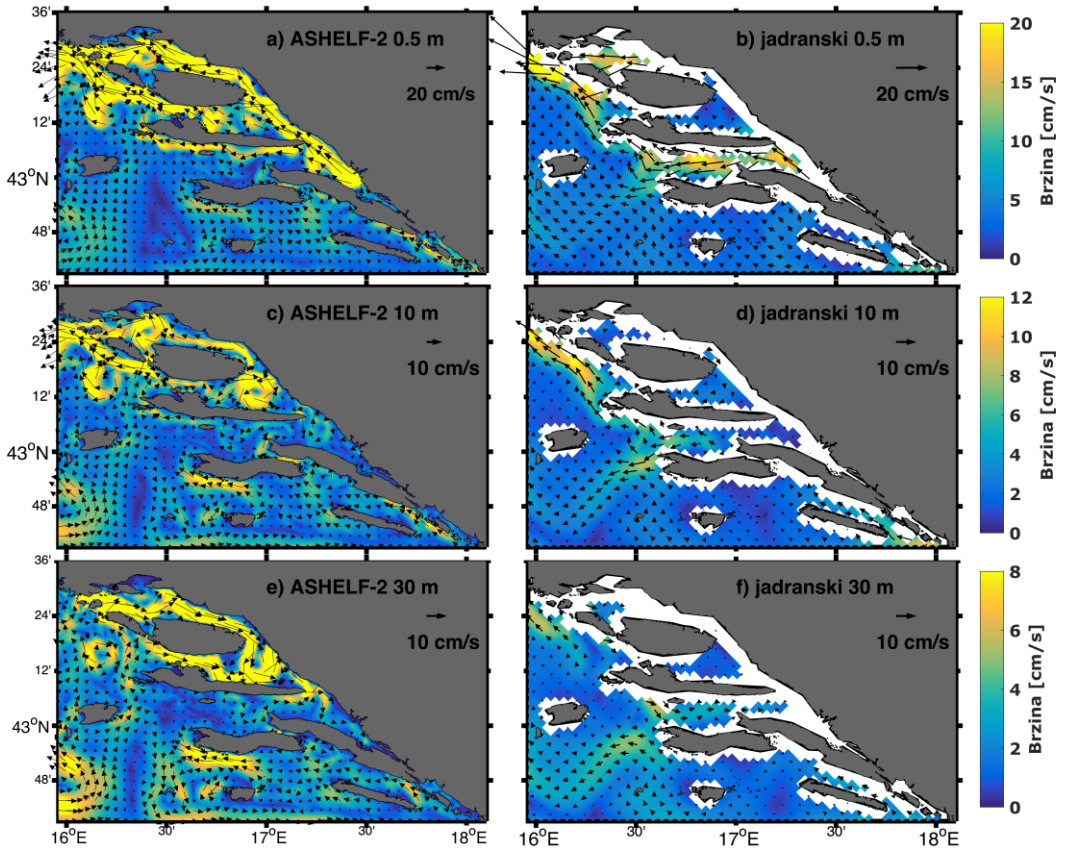

Slika 56. Srednje dnevne vrijednosti strujanja u moru 8. ožujka 2016. godine izračunate pomoću modela ROMS za ASHELF-2 (a, c, e) i jadransku (b, d, f) domenu na dubini od 0.5 m, 10 m i 30 m. Za ASHELF-2 crtani su vektori za svaku četvrtu točku, dok su za jadransku domenu crtani za svaku drugu točku.

Izračuni FTLE polja na srednjim dnevnim vrijednostima površinskog strujanja pokazuju da modelski rezultati (slika 57.a, b; 58.a, b) daju potpuno drugačije rezultate u usporedi s radarskim mjerenjima (slika 55.e, f). Jadranski model s rezolucijom od 2.5 km ne uspijeva uhvatiti finu dinamiku u kompleksnom obalnom području, dok blizina otvorene granice ASHELF-2 domene dovodi do pojave šuma u izračunu uzrokovanog snažnim strujama u rubnom području. Šum se može anulirati proširenjem domene tako da zahvati područje u kojem struje na rubovima neće biti intenzivne kao u ovom primjeru. ASHELF-2 simulacije zahtijevaju bolju parametrizaciju, jer iako im je prostorna rezolucija od 1 km bolja od radarske 1.5 km, i dalje ne mogu precizno reproducirati fine strukture poput anticiklonalnog vrtloga uz Šoltu.

Usporedbom FTLE polja i raspodjele čestica dobiva se uvid u dinamiku koja kontrolira transport čestica. U slučaju juga (slika 57.) čestice u ASHELF-2 domeni

koje nisu advektirane van domene raspoređene su oko otoka Brača pod utjecajem LCS-ova, dok su u slučaju jadranske domene čestice zarobljene LCS-ovima u uskom području uz otok Brač iako je od ispuštanja prošlo više od tjedan dana.

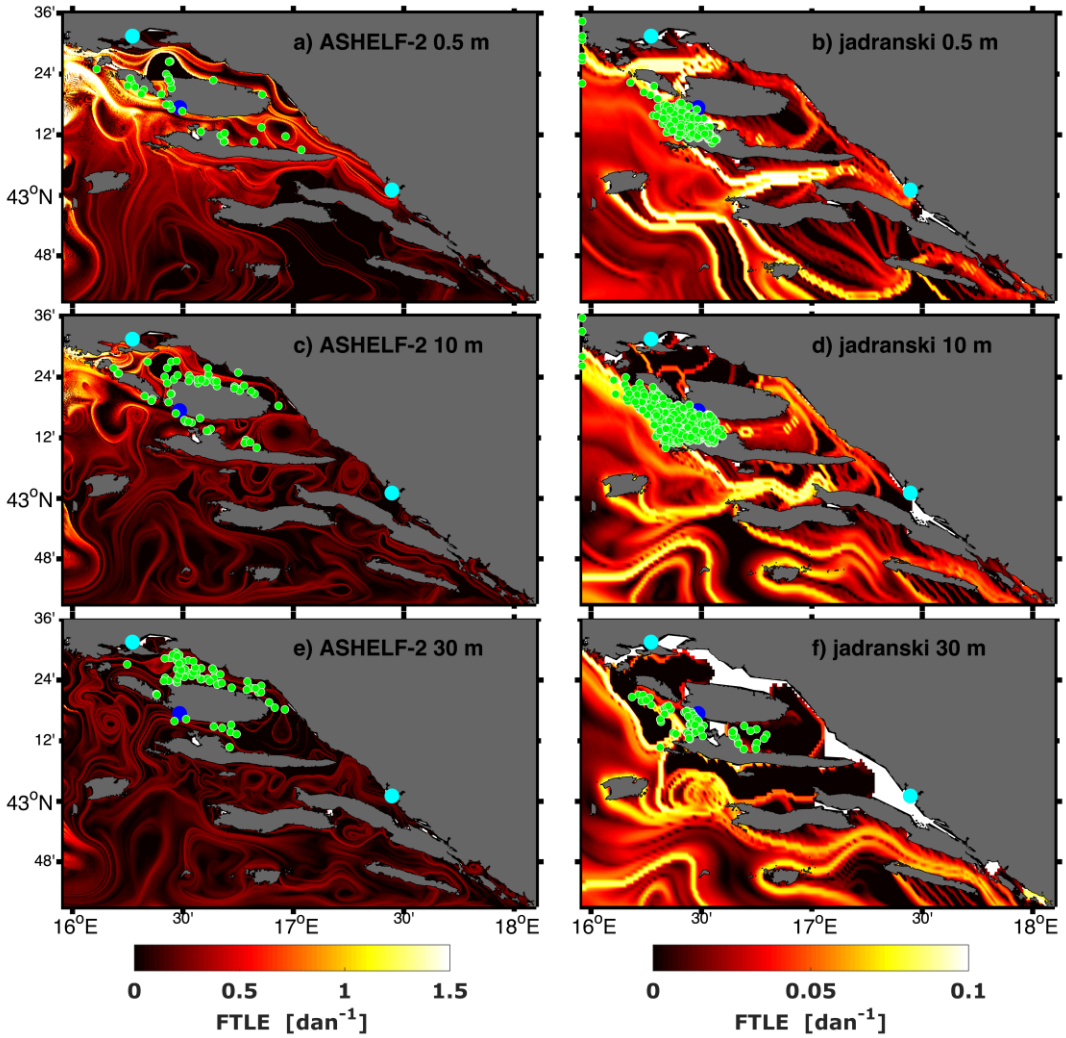

Slika 57. Položaji čestica (zeleni kružići) ispuštenih s uzgajališta kod otoka Brača (plava točka) na dan 8. ožujka 2016. godine. Čestice su ispuštene 26., 27. i 28. veljače u 1700 h. Razdiobe čestica i FTLE polja prikazani su za ASHELF-2 (a, c, e) i jadransku domenu (b, d, f). Dubine na kojima su prikazana FTLE polja su: 0.5 m (a, b), 10 m (c, d) i 30 m (e, f). Čestice su prikazane za raspone dubina od 0 do 3 m (a, b), od 8 do 12 m (c, d) i od 29 do 31 m (e, f). Svjetloplave točke su lokacije rastilišta. FTLE polja su dobivena proračunom unprijed u vremenu na polju srednjeg dnevnog strujanja u moru izračunatog pomoću modela ROMS.

Sličan se rezultat javlja i na primjeru bure (slika 59.) gdje dolazi do transporta u sjeverozapadnom smjeru, ali su pritom čestice u jadranskoj domeni i dalje zarobljene u uskom pojasu, dok su čestice u ASHELF-2 domeni organizirane pod utjecajem odbojnih barijera. ROMS model grublje rezolucije u kompleksnom

području uz obale otoka simulira veliku promjenjivost vektora struja po smjeru i iznosu. Velika razlika u smjeru vektora u FTLE izračunu uzrokuje brzo razdvajanje dviju susjednih čestica koje su položene na te vektore. Brzo razdavajanje daje visoki iznos FTLE koeficijenta i formira se odbojna barijera u strujnom polju.

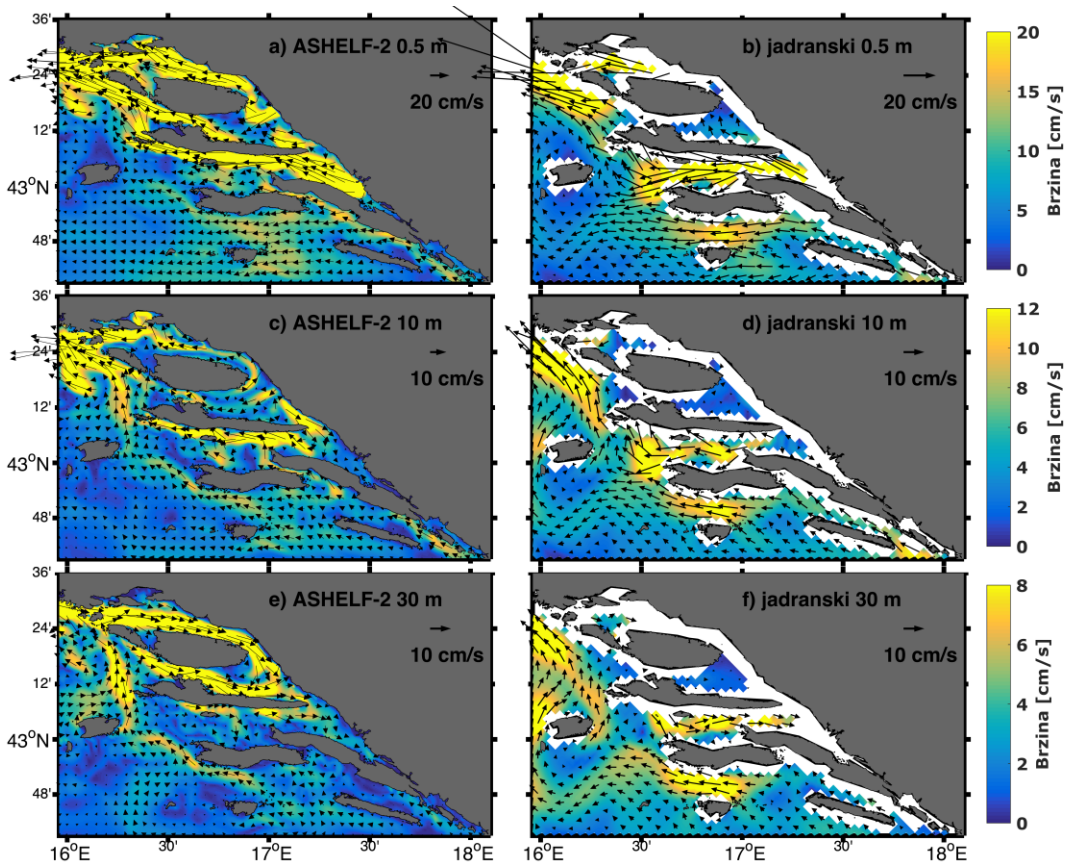

Slika 58. Srednje dnevne vrijednosti strujanja u moru 13. ožujka 2016. godine izračunate pomoću modela ROMS za ASHELF-2 (a, c, e) i jadransku (b, d, f) domenu na dubini od 0.5 m, 10 m i 30 m. Za ASHELF-2 crtani su vektori za svaku četvrtu točku, dok su za jadransku domenu crtani za svaku drugu.

ROMS u ASHELF-2 domeni je u usporedbi s jadranskom domenom realističnije simulirao dužobalno sjeverozapadno strujanje u Bračkom kanalu (Klaić i sur., 2011).

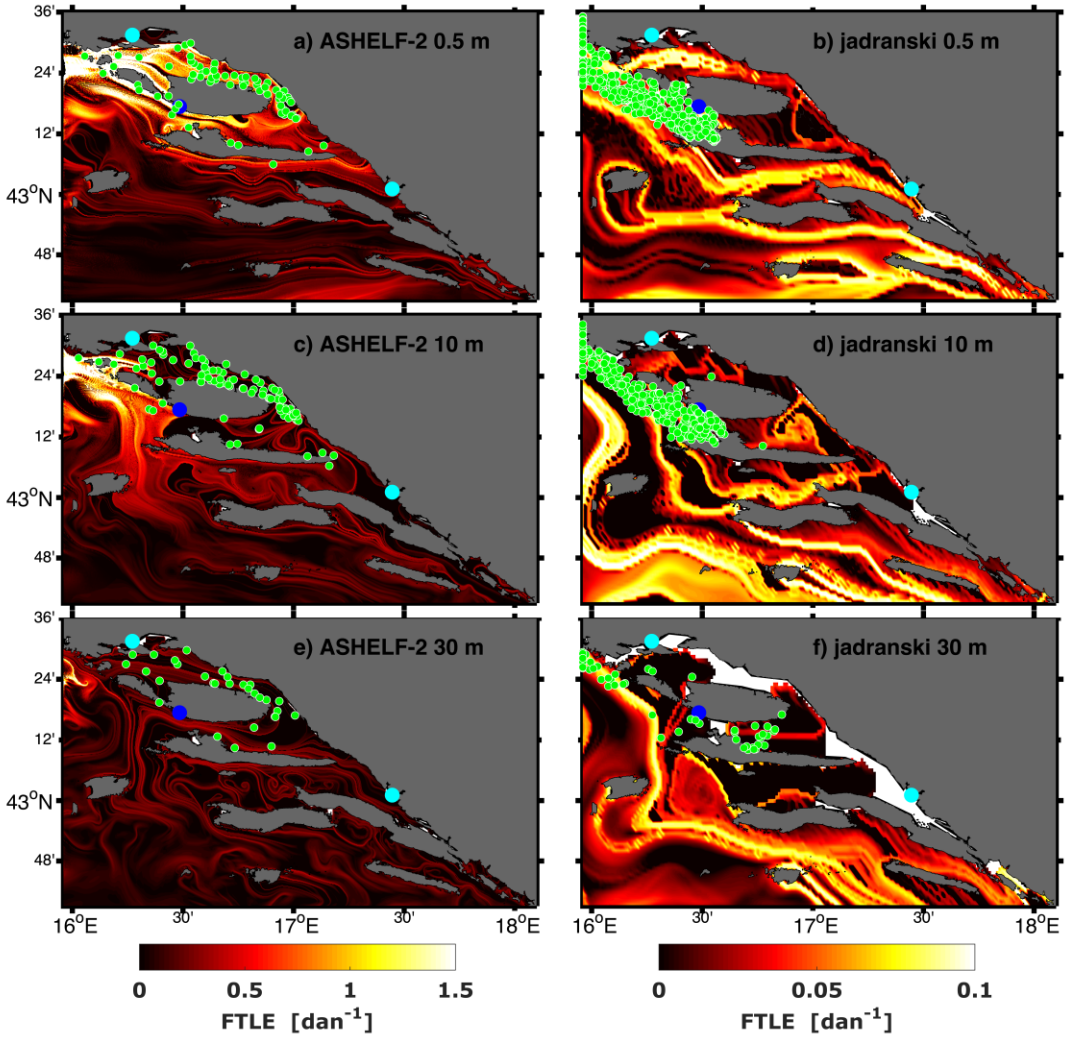

Slika 59. Položaji čestica (zeleni kružići) ispuštenih s uzgajališta kod otoka Brača (plava točka) na dan 13. ožujka 2016. godine. Čestice su ispuštene 26., 27. i 28. veljače u 1700 h. Razdiobe čestica i FTLE polja prikazani su za ASHELF-2 (a, c, e) i jadransku domenu (b, d, f). Dubine na kojima su prikazana FTLE polja su: 0.5 m (a, b), 10 m (c, d) i 30 m (e, f). Čestice su prikazane za raspone dubina od 0 do 3 m (a, b), od 8 do 12 m (c, d) i od 29 do 31 m (e, f). Svjetloplave točke su lokacije rastilišta. FTLE polja su dobivena proračunom unprijed u vremenu na polju srednjeg dnevnog strujanja u moru izračunatog pomoću modela ROMS.

4.4.3. Utjecaj letalne temperature

U pokusu 3. uključivanjem smrtnosti uzrokovanom donjom letalnom temperaturom za čestice koje su se našle u području s temperaturom mora nižom od 12 °C zamijećen je drastičan pad u uspješnosti transporta u jadranskom pokusu na relaciji Ugljan – Raša i ASHELF-2 pokusu na relaciji Brač – Pantan. Objašnjenje je pronađeno u detaljnijoj analizi temperature mora u blizini Ugljana, koje je obuhvaćalo

lokaciju ispuštanja čestica. Za Ugljan, Hovmöllerov dijagram temperature vodenog stupca otkriva da je u prva tri mjeseca temperatura u vodenom stupcu u nekoliko slučajeva bila ispod 12 °C (slika 60.) što je uzrokovalo smrtnost 99% čestica (slika 43.). Povezivanjem s meteorološkom situacijom utvrđeno je da su u navedenom razdoblju puhale jake bure (Meteorološki bilten 01/2016, 02/2016, 03/206) koje su izazvale hlađenje cijelog vodenog stupca u plitkom obalnom moru (Vilibić i sur., 2018).

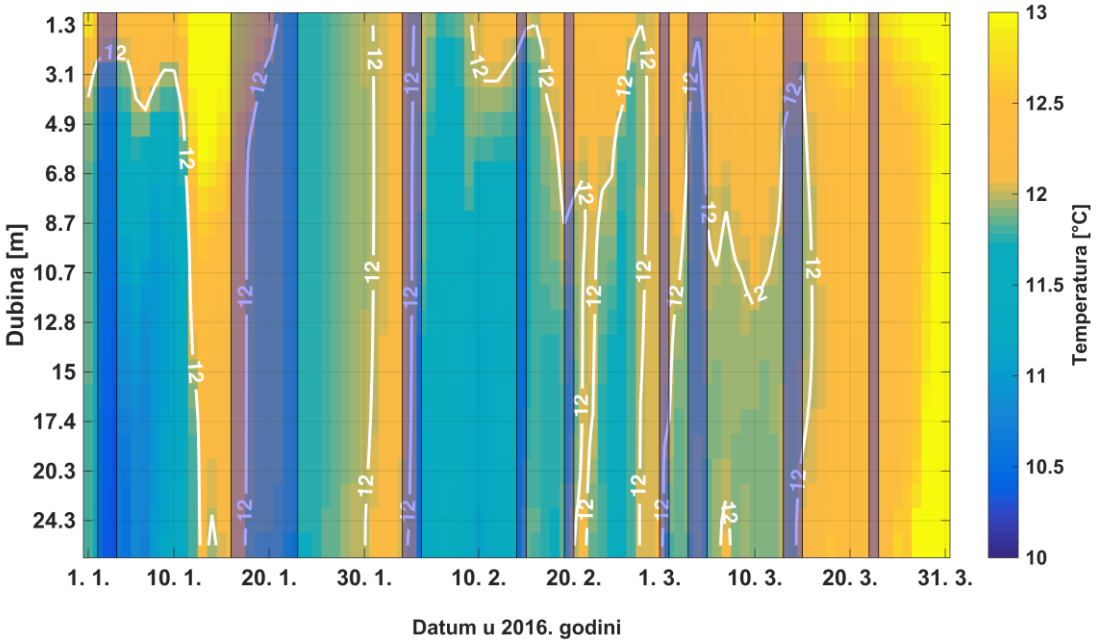

Slika 60. Hovmöllerov diagram temperature vodenog stupca kroz prva tri mjeseca 2016. godine na lokaciji uzgajališta Ugljan. Temperaturni niz je dobiven usrednjavanjem temperature u točki modela koja odgovara lokaciji Ugljana i temperature četiri susjedne točke. Sivim poljima su označeni vremenski periodi puhanja jake bure.

U ASHELF-2 domeni do najvećeg ugibanja čestica zbog pothlađenosti je došlo 23. siječnja (slika 61.a). Najveći broj pothlađenih čestica bio je u površinskom sloju (slika 61.b). Iz polja površinske temperature mora za 23. siječnja uočava se da su pothlađene čestice grupirane u područja u kojima je temperatura mora manja od 12 °C. Od 16. do 22. siječnja (Meteorološki bilten 02/2016) puhala je jaka bura, koja je uzrokovala pad površinske temperature mora. Ova analiza pokazuje koliki utjecaj imaju ispravno modelirana polja fizikalnih parametara na konačan rezultat. Posebice u biološkoj primjeni, gdje je temperatura habitata jedan od ključnih čimbenika preživljavanja.

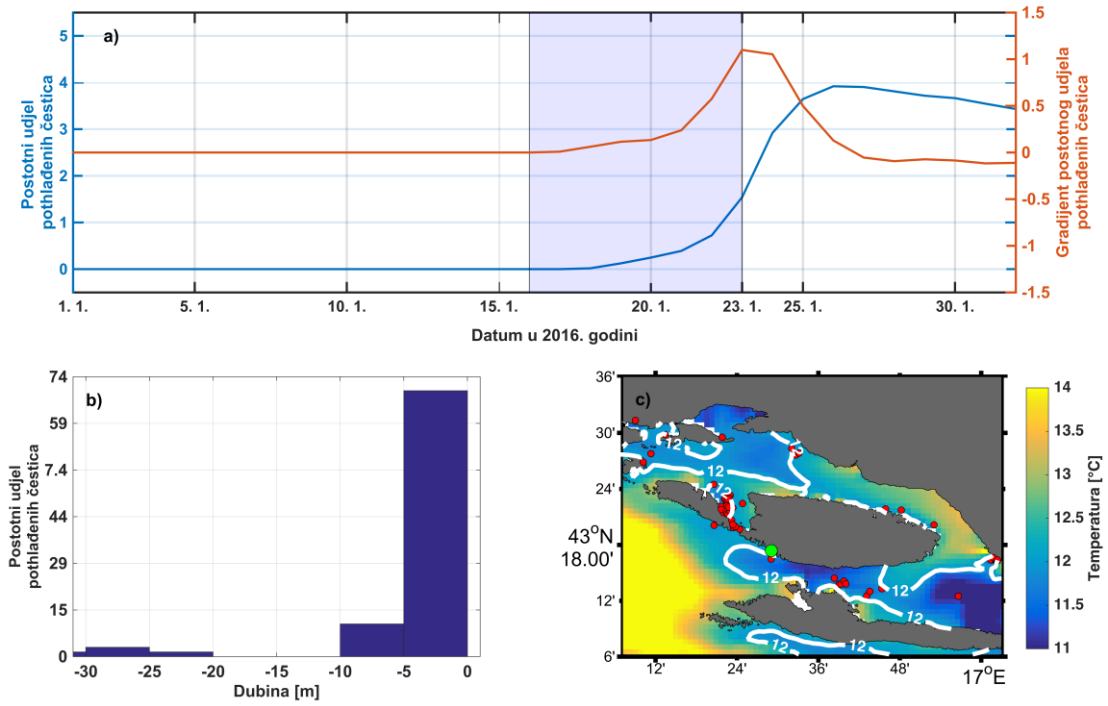

Slika 61. Vremenski niz postotnog udjela pothlađenih čestica u ukupnom broju čestica zajedno s gradijentom postotnog udjela pothlađenih čestica tijekom siječnja 2016. godine (a). Distribucija pothlađenih čestica u vodenom stupcu (b) i modelirano površinsko polje temperature mora u ASHELF-2 domeni za 23. siječnja 2016. godine (c). Zelenom točkom je označena lokacija ispuštanja čestica kod otoka Brača.

4.4.4. Prostorna razdioba koherentnih struktura

U dosadašnjem dijelu rada prostorne koncentracije čestica dobivene u simulacijama unaprijed su promatrane u paru s FTLE poljima dobivenim izračunom unaprijed, odnosno prostorne koncentracije čestica dobivene u simulacijama unazad s FTLE poljima dobivenim izračunom unazad. Razlog za odabir analize raspodjele čestica i FTLE polja u prvom paru je bila ideja da se promotre jasne granice područja kroz koji se odvija najveći dio transporta. Razlog za odabir analize u drugom paru je bila ideja da se promotre područja u koja konvergira najveći broj čestica, odnosno da se odgovori na pitanje postoji li povezanost konvergentnih područja s lokacijama uzgajališta. Usporedba prostorne razdiobe čestica dobivene simulacijom unaprijed (slika 62.a) zajedno s prikazom odbojnih odnosno privlačnih LCS-ova (slika 62.c) pokazuje njihovu zajedničku ulogu u organizaciji transporta. Navedeno se može bolje uočiti na transektu prostorne raspodjele čestice (slika 62.b) odnosno LCS-ova (slika 62.d). Na prostornoj raspodjeli čestica na dan 31. ožujka 2016. godine dobivenoj

zbrojem prostornih raspodjela čestica puštenih s otoka Brača (slika 44.) i Ugljana (slika 45.) najviše čestica je grupirano u Kvarneriću i duž vanjske obale Lošinja, Dugog otoka i Šolte (slika 62.a).

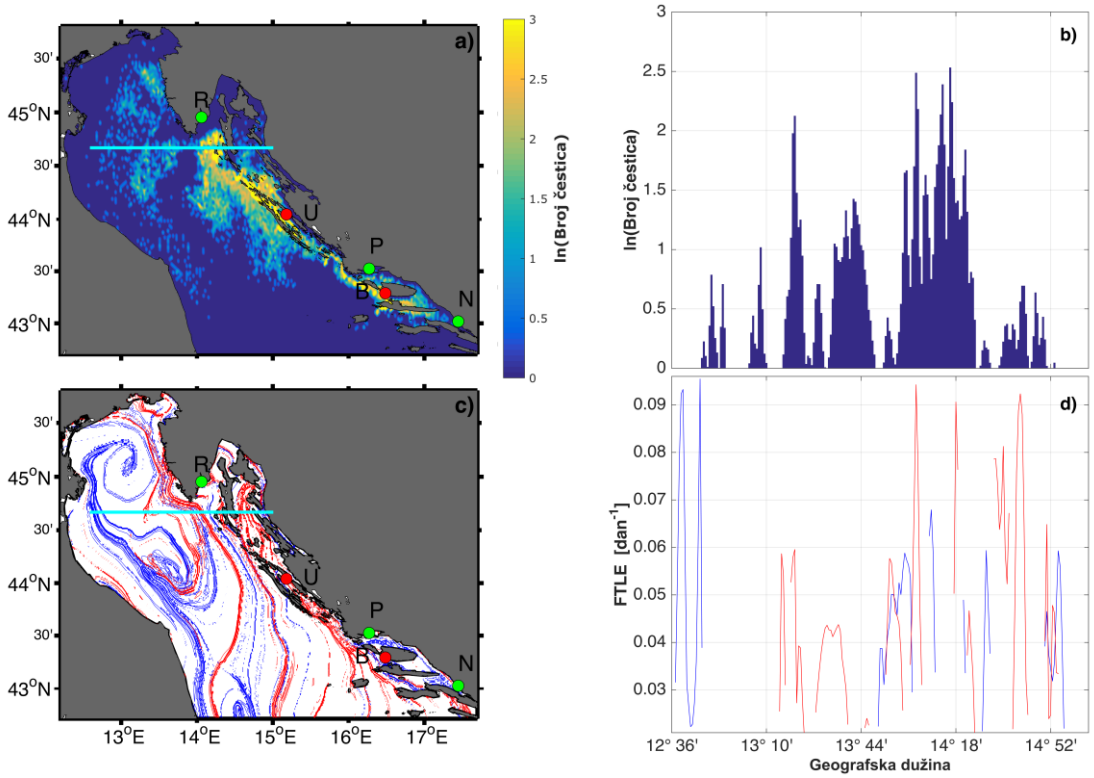

Slika 62. Prostorna raspodjela čestica 31. ožujka 2016. godine u prvih 5 m vodenog stupca (a). Čestice su ispuštene s lokacija kod uzgajališta označenih crvenim točkama kod otoka Brača (B) i Ugljana (U). Zelene točke su lokacije rastilišta Neretve (N), Pantana (P) i Raše (R). Svijetloplava linija je transekt na kojem je prikazana raspodjela čestica na (b). Prikaz odbojnih (plave linije) i privlačnih (crvene linije) LCS-a izračunatih FTLE metodom unaprijed odnosno unazad u vremenu na polju dnevnih srednjih vrijednosti površinskih morskih struja dobivenih modelom ROMS na dan 31. ožujka 2016. godine (c). Prikazane su vrijednosti veće od 0.02. Svijetloplava linija je transekt na kojem je prikazan FTLE na (d).

Iz polja LCS-ova se uočava da su to područja u kojima dominiraju privlačni LCS-ovi i pritom su omeđeni odbojnim LCS-ovima. Do neslaganja između rezultata prostorne raspodjele čestica i distribucije LCS-ova dolazi zbog toga što je proračun LCS-ova rađen na polju srednjih dnevnih morskih struja na dubini od 1 m, koja je poslužila kao aproksimacija za prostornu raspodjelu čestica u prvih 5 m vodenog stupca. Iako je opaženo podudaranje velikih grupacija čestica u prostornoj raspodjeli s privlačnim LCS-ovima, važno je napomenuti da postoje i privlačni LCS-ovi na kojima se ne nalazi veliki broj čestica. Razlog je taj što ti LCS-ovi nisu povezani s izvorištem čestica. Zorniji uvid u povezanost LCS-ova i broja čestica se vidi na

proizvoljno odabranom transektu LCS-ova (slika 62.b) i prostorne distribucije čestica (slika 62.d). Područja privlačnih LCS-ova odgovaraju visokim koncentracijama čestica, dok su područja na kojima se ne vidi prisustvo čestica karakterizirana negativnim LCS-ovima. Iz prikaza LCS-ova uočava se bliskost pozitivnih i negativnih LCS-ova, skoro i podudaranje. Do toga dolazi jer privlačni LCS-ovi povezani s jednom sedlenom točkom često formiraju odbojne LCS-ove druge sedlene točke (heterokline trajektorije) ili se kruženjem vrate nazad na istu sedlenu točku (homokline trajektorije) (Harrison i Glatzmaier 2012; Harrison i sur., 2013).

U ovom istraživanju dodatni napredak bi se ostvario pokretanjem ROMS modela na jadranskoj domeni s rezolucijom od 1 km kojom bi se bolje uhvatila kompleksna dinamika, pogotovo jer se najveći dio transporta odvijao u obalnom području istočnog Jadranskog mora. U ASHELF-2 domeni se vide poboljšanja u rezultatima zbog korištenja finije rezolucije, no ASHELF-2 domena obuhvaća samo srednji dio istočne jadranske obale. Kao i u prethodnom poglavlju o disperziji ihtioplantkonskih stadija tune, realističnije rezultate IBM-a bi dale dodatne biološke parametrizacije za dnevno-noćne migracije, uvođenje uzgona, zavisnosti rasta jedinki o temperaturi, te usmjereno plivanje. Navedene parametrizacije bi morale biti zasnovane na istraživanjima provedenim u Jadranskom moru.

5. ZAKLJUČCI

Multidisciplinarno istraživanje koje je uključivalo fizikalne i biološke analize i izračune je napravljeno s ciljem proučavanja utjecaja hidrodinamičkog okoliša na transport ihtioplanktona i mladih jedinki tune i komarče. Biološki dio istraživanja se sastojao od fenotipske i genetske analize, koja je poslužila kao početna motivacija za numeričko modeliranje putanja ihtioplanktona. Istraživanja provedena u radu su, koliko je poznato na temelju dostupne literature, prva istraživanja ovog tipa provedena za tune i komarče u kojima je potvrđena hipoteza o hidrodinamičkoj i genetskoj korelaciji. Zbog preglednosti zaključci će biti u grupirani u dvije cjeline (iako su istraživanja provedena za dvije različite riblje vrste i to u različitim godinama): fizikalnu, koja će obuhvatiti mjerenja i rezultate hidrodinamičkog modela ROMS, i lagrangeovsku, koja će obuhvatiti rezultate disperzijskog modeliranja i proračune LCS-a.

Združivanje numeričkog oceanografskog modela ROMS i individualno temeljenog modela Ichthyop je primijenjeno u simulacijama disperzije ihtioplanktonskih stadija kao i juvenilnih jedinki tuna i komarči. Rezolucija ROMS modela na jadranskoj domeni od 2.5 km pokazala se dobrom za modeliranje strujanja u otvorenom moru, dok se rezolucija ASHELF-2 domene pokazala, što je i očekivano, boljom za simulacije strujanja u kompleksnom obalnom području istočnog dijela Jadranskog mora. Modelirano strujanje na otvorenom moru verificirano je usporedbom putanja Argo plovaka i virtualnih plovaka. Podudaranje putanja virtualnih plovaka s putanjom Argo plovka je dobiveno za ljetno razdoblje 2011. godine u Jabučkoj kotlini, odnosno za zimsko-proljetno razdoblje 2016. godine u Južnojadranskoj kotlini. U oba slučaja rezultati modela su podcijenjivali izmjerene temperature i salinitete. Najveća odstupanja u ljeto 2011. godine su bila na dubini termokline što je posljedica prejakog miješanja u modelu (Orlić i sur., 2006a). Primjena ROMS modela s rezolucijom od 2.5 km je reproducirala obrat istočnojadranske struje u površinskom sloju tijekom ljeta 2011. godine. Tijekom srpnja i kolovoza 2011. godine nad Jadranom je puhao sjeverozapadni vjetar koji se može povezati s nastankom jugoistočne površinske struje. Klimatološka svojstva ljetnog razdoblja 2011. godine, u kojem se dogodio obrat, su bila slična onima u 2003. godini kada su rezultati prognostičkog oceanografskog sustava u ASHELF-2

području također pokazali povezanost obrata površinske struje s dominantnim vjetrom. ROMS model s rezolucijom od 2.5 km je također u 2016. godini reproducirao jačanje istočnojadranske struje u zimskom razdoblju, koje je bilo posljedica intenzivnijeg puhanja vjetra iz JI smjera. U simulacijama za 2016. godinu ASHELF-2 model se pokazao uspješniji u reproduciranju vertikalnih profila temperature i saliniteta u usporedbi s jadranskim ROMS modelom, što je rezultiralo manjim iznosima BIAS-ova i RMSE-ova. Vertikalni profili u modelu simuliraju sezonski hod temperature u vodenom stupcu i nastajanje termokline u travnju. Modelirane struje u obalnom dijelu verificirane su radarskim mjerenjima. Radarska mjerenja su se pokazala korisnom metodom mjerenja površinskog strujanja u moru u području u kojem se javlja kanalizirana mlazna struja kao i brazda u strujanju nastala u zavjetrini otoka. Obje realizacije modela u 2016. godini su reproducirale generalni smjer SZ strujanja istočnojadranske struje, efekt kanaliziranja struje između Visa i Šolte kao i brazdu na sjevernoj strani Visa. ASHELF-2 model ne uspijeva simulirati precizno pojavu anticiklonalnog vrtloga tijekom epizode juga. Modelirani vrtlog smješten je južnije od izmjerenog, iako rezolucija ASHELF-2 modela iznosi 1 km, a ona radarskih mjerenja 1.5 km.

Na temelju provedenih disperzijskih simulacija zaključeno je da je najvjerojatnija lokacija mrijesta Atlantske plavoperajne tune pronađene 1. rujna 2011. godine južno od otoka Mljeta komercijalno uzgajalište tuna južno od otoka Brača. U prilog tome ide opaženi mrijest na uzgajalištima u Jadranskom moru (Grubišić i sur., 2013). Mogućnost da je tuna došla s područja prirodnog mrijesta uz obale Sicilije u Jonskom moru eliminirana je na dva načina. Ponajprije, analizom modeliranih površinskih strujnih polja iz mediteranskog modela u kojem je smjer strujanja suprotan smjeru pretpostavljene putanje tune iz Jonskog mora u Jadransko more. Dodatna potvrda je dobivena ispuštanjem čestica s ruba jadranske domene u Otrantskim vratima. Sve ispuštene čestice advektirane su u smjeru Jonskog mora. Numeričkim simulacijama je potvrđeno da čestice pasivnim plivanjem, to jest nošene morskim strujama, ako su ispuštene s otoka Brača mogu u 20 dana doći u neposrednu blizinu lokacije ulova. Jedinke tune starije od 20 dana imaju mogućnost plivanja koje im omogućava da se odvoje od hidrodinamičke okoline, što povećava vjerojatnost transporta čestica prema lokaciji ulova. Uvođenje plivanja, s dva različita načina parametrizacije iznosa brzine plivanja, nije pokazalo promjene u konačnim rezultatima. Razlog je taj što je u svakom vremenskom koraku smjer plivanja slučajno

izabran. Ukupni pomak plivanjem je zbog toga bio gotovo jednak nuli. Realističniji rezultati se mogu dobiti uvođenjem smjera plivanja uvjetovanog određenim biološkim ili fizikalnim parametrom poput gradijenta klorofila ili gradijenta temperature. Uvođenje dnevno-noćne vertikalne migracije tuna parametrizirane na temelju istraživanja u zapadnom Sredozemnom moru je rezultiralo advekcijom čestica prema zapadnoj obali. Dobiveni rezultat ukazuje na dvije bitne stvari: važnost poznavanja bioloških parametara izmjerenih u području u kojem je napravljena simulacija i važnost ispravnog smještaja čestica u vodenom stupcu radi utjecaja morskih struja na konačnu prostornu razdiobu.

Na temelju provedenih disperzijskih simulacija za razdoblje zime i proljeća 2016. godine potvrđena je hidrodinamička povezanost lokacija mrijesta komarči koje se nalaze u blizini uzgajališta tuna smještnih kod otoka Brača i Ugljana i rastilišta ranih stadija komarči koja se nalaze u boćatom području ušća Neretve, Rike (močvara Pantan) i Raše. Prije simulacija disperzije genetska povezanost je potvrđena DNK analizom. Uspješnost transporta čestica od mrijestilišta ka rastilištima jednaka je postotku genetske povezanosti. Realističniji rezultati simulacija su dobiveni uvažavanjem mogućnosti naplavljivanja čestica na otoke i kopno. Na taj način je u simulaciju uključen negativni efekt zadržavanja čestica u nepovoljnom okolišu. Nadalje, uvođenje donje letalne temperature u simulacije IBM-om ihtioplanktonskih stadija komarče pokazalo je važnost primjene naprednijih bioloških opcija koje mogu rezultirati realističnijim rezultatom. U simulacijama u kojima su se čestice ispuštale s lokacije kod otoka Ugljana transport je gotovo prestao. Smrtnost čestica je iznosila 99%. Razlog je hlađenje cijelog plitkog vodenog stupca u neposrednoj blizini Ugljana ispod donje letalne temperature koje se dogodilo pod utjecajem bure u prva dva mjeseca 2016. godine. Negativni utjecaj hlađenja zabilježen je i u ASHELF-2 simulaciji. Epizoda bure 23. siječnja 2016. godine je ohladila površinu i prvih 10 m vodenog stupca što je dovelo do toga da manji broj čestica dođe do rastilišta. Parametrizacija utjecaja letalne temperature provedena je na temelju laboratorijskih istraživanja komarči uhvaćenih u Alantskom oceanu, što pokazuje isti problem nepostojanja lokalnih bioloških mjerenja kao i u slučaju s tunama. Prostorno-vremenska varijabilnost strujanja je bitan čimbenik o kojem ovisi transport ihtioplanktona. Na temelju distribucije čestica pristiglih u područje uspjeha na kraju simuliranog razdoblja, koje su potom razvrstane po danu kad su ispuštene, kvantificiran je utjecaj varijabilnosti fizikalnih uvjeta okoliša. Ukoliko su mrijestilišta

smještena u blizini snažnog strujanja poput istočnojadranske struje, koje nije pokazivalo veliku vremensku varijabilnost tijekom simulacije, transport je bio kontinuiran. Dolazak čestica u pulsevima je zabilježen za lokaciju kod Neretve. Trajektorije čestica koje su stigle do Neretve su prolazile kroz područje na kojem je strujanje pod utjecajem protoka rijeka i vremenski varijabilnog vjetra. Parcijalni mrijest komarče, pri kojem jedinke ispuštaju veliki broj jajašaca u dugom vremenskom intervalu, je prirodno riješenje kojim se povećava uspješnost transporta do rastilišta. Na taj način je bio moguć transport ihtioplanktona u područje poput onog u blizini ušća Neretve.

Upotreba LCS-ova pokazala se kao dobra dijagnostička metoda koja daje dodatni uvid u transport čestica. Iz LCS-ova izračunatih FTLE metodom unazad i unaprijed dobiven je prikaz organizacije transporta duž jadranske obale. Istočnojadranska i zapadnojadranska struja su kanalizirane u užem obalnom prostoru. Područje u kojem su struje kanalizirane je omeđeno odbojnim barijerima, dok se u području u kojem se odvija najveći dio transporta nalaze privlačne strukture. Potvrda povezanosti privlačnih struktura i povećanog transporta je dobivena prikazom transekta koji presijeca privlačne i odbojne strukture. Visoke koncentracije čestica se podudaraju s visokim iznosima privlačnih struktura. Odbojne barijere izračunate FTLE metodom unazad na modeliranim poljima struja su bile vizualni pokazatelji zašto dolazi, odnosno ne dolazi, do transporta.

Tijekom simulacije transporta ranih stadija tune 2011. godine u jadranskoj ROMS domeni, postojanje odbojnih barijera sjeverno od Šolte je spriječilo transport čestica s uzgajališta kod Ugljana i Gire prema lokaciji ulova kod Mljeta. Osim onemogućavanja transporta iz jednog područja u drugo, odbojne barijere su oblikovale prostorne raspodjele čestica, što se posebice vidjelo u obrascu nakupljanja čestica duž rubova vrtloga. U kompleksnom području razvedene istočne jadranske obale, simulacije ROMS modelom u jadranskoj domeni 2016. godine dale su vektore struja koji nisu omogućili transport ihtioplanktonskih stadija komarče na veće udaljenosti od lokacije ispuštanja. Nemogućnost transporta je potvrđena izračunom FTLE polja, koji je pokazao postojanje odbojne barijere. U ASHELF-2 simulaciji odbojna barijera koja bi blokirala transport čestica na lokaciji ispuštanja nije postojala, pa su čestice u domeni finije rezolucije dospjele do područja uspjeha, tj. do rastilišta. Osim vizualiziranja uloge u organizaciji transporta čestica, korištenje LCS-ova se pokazalo i kao alat kojim je moguće detektirati vrtloge u moru, pri čemu

promjeri vrtloga mogu varirati na skalama od nekoliko kilometara do nekoliko stotina kilometara.

Simulacije transporta ihtioplanktona korištenjem uparenog Ichthyop i ROMS modela mogu poslužiti za buduća istraživanja transporta tijekom višegodišnjeg razdoblja. U ovom radu modelski sustav je korišten za istraživanja povezanosti između mrijestilišta i rastilišta ranih stadija dvije riblje vrste u određenim kratkim vremenskim razdobljima. Rezultati višegodišnjih simulacija uparenim modelima mogu poslužiti za proučavanje uspješnosti transporta iz područja mrijesta u područje rastilišta, te tako olakšati donošenje zakonskih regulativa za zaštitu područja važnih za opstanak populacija. Trendove dobivene modeliranjem treba usporediti s trendovima iz višegodišnjih mjerenja bioloških parametara. Podudaranje modeliranih trendova i trendova dobivenih in situ mjerenjima omogućilo bi da se, uzimajući u obzir klimatske projekcije, daju odgovori na pitanja vezana uz prilagodbe pojedinih vrsta očekivanim promjenama u okolišu.

6. LITERATURA

Alemany, F., L. Quintanilla, P. Velez-Belchí, A. García, D. Cortés, J. M. Rodríguez, M. L. Fernández de Puelles, C. González-Pola, i J. L. López-Jurado. 2010. "Characterization of the spawning habitat of Atlantic bluefin tuna and related species in the Balearic Sea (western Mediterranean)." *Progress in Oceanography* 86 (1–2): 21–38. https://doi.org/10.1016/j.pocean.2010.04.014.

Andrello, M., F. Guilhaumon, C. Albouy, V. Parravicini, J.Scholtens, P. Verley, M. Barange, U. Rashid Sumaila, S. Manel, i D. Mouillot. 2017. "Global mismatch between fishing dependency and larval supply from marine reserves." *Nature Communications* 8. https://doi.org/10.1038/ncomms16039.

Andročec, V., G. Beg Paklar, V. Dadić, T. Đakovac, B. Grbec, I. Janeković, N. Krstulović, G. Kušpilić, N. Leder, G. Lončar, I. Marasović, R. Precali i M. Šolić. *The Adriatic Sea monitoring program - Final report.* Zagreb: MZOUPG, 2009.

Artegiani, A., E. Paschini, A. Russo, D. Bregant, F. Raicich, i N. Pinardi. 1997a. "The Adriatic Sea general circulation. Part I: air–sea interactions and water mass structure." *Journal of Physical Oceanography* 27 (8): 1492–1514. https://doi.org/10.1175/1520-0485(1997)027<1492:TASGCP>2.0.CO;2.

Artegiani, A., E. Paschini, A. Russo, D. Bregant, F. Raicich, i N. Pinardi 1997b. "The Adriatic Sea general circulation. Part II: baroclinic circulation structure." *Journal of Physical Oceanography* 27 (8): 1515–32. https://doi.org/10.1175/1520-0485(1997)027<1515:TASGCP>2.0.CO;2.

Avignon, S., E. Tastard, S.Weston, G. Duhamel, i F. Denis. 2017. "Morphological identification and DNA barcoding used for diet analysis of gilthead seabream (Sparus aurata) in its expanding northerly range." *Aquatic Living Resources* 30 (1): 1–11. https://doi.org/10.1051/alr/2016034.

Basaran, F. H. Ozbilgin, i Y. Doganyilmaz Ozbilgin. 2007. "Comparison of the swimming performance of farmed and wild gilthead sea bream, Sparus aurata." *Aquaculture Research* 38 (5): 452–56. https://doi.org/10.1111/j.1365-2109.2007.01670.x.

Beg Paklar, G., N. Žagar, M. Žagar, R. Vellore, D. Koračin, P. M. Poulain, M. Orlić,

I. Vilibić, i V. Dadić. 2008. “Modeling the trajectories of satellite-tracked drifters in the Adriatic Sea during a summertime bora event.” *Journal of Geophysical Research: Oceans* 113 (11). https://doi.org/10.1029/2007JC004536.

Belušić, D., M. Hrastinski, Ž. Večenaj, i B. Grisogono. 2013. “Wind regimes associated with a mountain gap at the northeastern Adriatic coast.” *Journal of Applied Meteorology and Climatology* 52 (9): 2089–2105. https://doi.org/10.1175/JAMC-D-12-0306.1.

Belušić, D., i Z. B. Klaić. 2006. “Mesoscale dynamics, structure and predictability of a severe Adriatic bora case.” *Meteorologische Zeitschrift* 15 (2): 157–68. https://doi.org/10.1127/0941-2948/2006/0116.

Belušić, D., i Z. B. Klaić. 2004. “Estimation of bora wind gusts using a limited area model.” *Tellus, Series A: Dynamic Meteorology and Oceanography* 56 (4): 296–307. https://doi.org/10.1111/j.1600-0870.2004.00068.x.

Bergamasco, A., M. Gačić, G. Redaelli, i A. Vulpiani. 1996. “Winter oceanographic conditions and water mass balance in the Northern Adriatic (February 1993).” *Journal of Marine Systems*. 7(1): 67-94. https://doi.org/10.1016/0924-7963(94)00037-9.

Bergamasco, A., i M. Gačić. 1996. “Baroclinic response of the Adriatic Sea to an episode of bora wind.” *Journal of Physical Oceanography* 26 (7): 1354–69. https://doi.org/10.1175/1520-0485(1996)026<1354:BROTAS>2.0.CO;2.

Bernardi Aubry., F., F. Marcello Falcieri, J. Chiggiato, A. Boldrin, G. M. Luna, S. Finotto, E. Camatti, F.Acri, M. Sclavo, S. Carniel, i L. Bongiorni. 2018. “Massive shelf dense water flow influences plankton community structure and particle transport over long distance.” *Scientific Reports* 8 (1). https://doi.org/10.1038/s41598-018-22569-2.

Berta, M., L. Ursella, F. Nencioli, A. M. Doglioli, A. A. Petrenko, i S. Cosoli. 2014. “Surface transport in the Northeastern Adriatic Sea from FSLE analysis of HF radar measurements.” *Continental Shelf Research* 77: 14–23. https://doi.org/10.1016/j.csr.2014.01.016.

Bianchi, N., i C. Morri. 2000. “Marine biodiversity of the Mediterranean Sea:

situation, problems and prospects for future research." *Marine Pollution Bulletin* 40 (5): 367–76. https://doi.org/10.1016/S0025-326X(00)00027-8.

Boffetta, G., G. Lacorata, G. Redaelli, i A. Vulpiani. 2001. "Detecting barriers to transport: A review of different techniques." *Physica D: Nonlinear Phenomena* 159 (1–2): 58–70. https://doi.org/10.1016/S0167-2789(01)00330-X.

Bray, L., D. Kassis, i J. M. Hall-Spencer. 2017. "Assessing larval connectivity for marine spatial planning in the Adriatic." *Marine Environmental Research* 125: 73–81. https://doi.org/10.1016/j.marenvres.2017.01.006.

Brickman, D., i P. C. Smith. 2002. "Lagrangian stochastic modeling in coastal oceanography." *Journal of Atmospheric and Oceanic Technology* 19 (1): 83–99. https://doi.org/10.1175/1520-0426(2002)019<0083:LSMICO>2.0.CO;2.

Brzović, N., i N. Strelec Mahović. 1999. "Cyclonic activity and severe jugo in the Adriatic." *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere* 24 (6): 653–57. https://doi.org/10.1016/S1464-1909(99)00061-1.

Budgell, W. P. 2005. "Numerical simulation of ice-ocean variability in the Barents Sea region." *Ocean Dynamics* 55 (3–4): 370–87. https://doi.org/10.1007/s10236-005-0008-3.

Buongiorno Nardelli, B., C. Tronconi, A. Pisano, i R. Santoleri. 2013. "High and Ultra-High resolution processing of satellite Sea Surface Temperature data over Southern European Seas in the framework of MyOcean project." *Remote Sensing of Environment* 129: 1–16. https://doi.org/10.1016/j.rse.2012.10.012.

Cabrita, E., V. Robles, i P.Herráez. *Methods in Reproductive Aquaculture. Marine and Freshwater Species*. CRC Press, 2008.

Carniel, S., L. H. Kantha, J. W. Book, M. Sclavo, i H. Prandke. 2012. "Turbulence variability in the upper layers of the Southern Adriatic Sea under a variety of atmospheric forcing conditions." *Continental Shelf Research* 44: 39–56. https://doi.org/10.1016/j.csr.2011.01.003.

Catalán, I. A., D. Macías, J. Solé, A. Ospina-Álvarez, i Javier Ruiz. 2013. "Stay off the motorway: Resolving the pre-recruitment life history dynamics of the European anchovy in the SW Mediterranean through a spatially-explicit

individual-based model (SEIBM).” *Progress in Oceanography* 111: 140–53. https://doi.org/10.1016/j.pocean.2013.02.001.

Cermeño, P., G. Quílez-Badia, A. Ospina-Alvarez, S. Sainz-Trápaga, A. M. Boustany, A. C. Seitz, S. Tudela, i B. A. Block. 2015. “Electronic tagging of Atlantic bluefin tuna (Thunnus thynnus, L.) reveals habitat use and behaviors in the Mediterranean Sea.” *PLoS ONE* 10 (2): e0116638. https://doi.org/10.1371/journal.pone.0116638.

Chapman, R., i H. Graber. 1997. “Validation of HF Radar Measurements.” *Oceanography* 10 (2): 76–79. https://doi.org/10.5670/oceanog.1997.28.

Chen, Y. H., P. T. Shaw, i T. G. Wolcott. 1997. “Enhancing estuarine retention of planktonic larvae by tidal currents.” *Estuarine, Coastal and Shelf Science* 45 (4): 525–33. https://doi.org/10.1006/ecss.1996.0217.

Chiggiato, J., E. Jarosz, J. W. Book, J. Dykes, L. Torrisi, P. M. Poulain, R. Gerin, J. Horstmann, i Ş. Beşiktepe. 2012. “Dynamics of the circulation in the Sea of Marmara: Numerical modeling experiments and observations from the Turkish straits system experiment.” *Ocean Dynamics* 62 (1): 139–59. https://doi.org/10.1007/s10236-011-0485-5.

Christensen, A., P. Mariani, i M. R. Payne. 2018. “A generic framework for individual-based modelling and physical-biological interaction.” *PLoS ONE* 13 (1):e0189956. https://doi.org/10.1371/journal.pone.0189956.

Collett, R. S., i K. Oduyemi. 1997. “Air quality modelling: A technical review of mathematical approaches.” *Meteorological Applications* 4 (3): 235–46. https://doi.org/10.1017/S1350482797000455.

Collette, B. B., K. E. Carpenter, B. A. Polidoro, M. J. Juan-Jordá, A. Boustany, D. J. Die, C. Elfes, W. Fox, J. Graves, L. R. Harrison, R. McManus, C. V. Minte-Vera, R. Nelson, V. Restrepo, J. Schratwieser, C. L. Sun, A. Amorim, M. Brick Peres, C. Canales, G. Cardenas, S. K. Chang, W. C. Chiang, N. de Oliveira Leite Jr., H. Harwell, R. Lessa, F. L. Fredou, H. A. Oxenford, R. Serra, K .T. Shao, R. Sumaila, S. P. Wang, R. Watson, i E. Yanez. 2011. “High value and long life - Double jeopardy for tunas and billfishes.” *Science* 333 (6040): 291-292. https://doi.org/10.1126/science.1208730.

Collette, Bruce B. 1999. “Mackerels, molecules, and morphology.” *Societe Francaise d'Ichtyologie* 149–64.

Corriero, A., S. Karakulak, N. Santamaria, M. Deflorio, D. Spedicato, P. Addis, S. Desantis, F. Cirillo, A. Fenech-Farrugia, R. Vassallo-Agius, J.M. de la Serna, Y. Oray, A. Cau, P. Megalofonou, i G. De Metrio. 2005. “Size and age at sexual maturity of female bluefin tuna (Thunnus thynnus L. 1758) from the Mediterranean Sea.” *Journal of Applied Ichthyology* 21 (6): 483–86. https://doi.org/10.1111/j.1439-0426.2005.00700.x.

Coulliette, C., F. Lekien, J. D. Paduan, G. Haller, i J. E. Marsden. 2007. “Optimal pollution mitigation in Monterey Bay based on coastal radar data and nonlinear dynamics.” *Environmental Science and Technology* 41 (18): 6562–72. https://doi.org/10.1021/es0630691.

Crombie, D. D. 1955. “Doppler spectrum of sea echo at 13.56 Mc./s. [3].” *Nature*. 175: 681–682. https://doi.org/10.1038/175681a0.

Di Lorenzo, E., N. Schneider, K. M. Cobb, P. J. S. Franks, K. Chhak, A. J. Miller, J. C. McWilliams, S.J. Bogard, H. Arango, E. Curchitser, T. M. Powell, i P. Riviere. 2008. “North Pacific Gyre Oscillation links ocean climate and ecosystem change.” *Geophysical Research Letters* 35 (8): L08607. https://doi.org/10.1029/2007GL032838.

d’Ovidio, F., S. De Monte, S. Alvain, Y. Dandonneau, i M. Levy. 2010. “Fluid dynamical niches of phytoplankton types.” *Proceedings of the National Academy of Sciences* 107 (43): 18366–70. https://doi.org/10.1073/pnas.1004620107.

d’Ovidio, F., V. Fernández, E. Hernández-García, i C. López. 2004. “Mixing structures in the Mediterranean Sea from finite-size Lyapunov exponents.” *Geophysical Research Letters* 31 (17). https://doi.org/10.1029/2004GL020328.

DeAngelis, D. L., i V. Grimm. 2014. “Individual-based models in ecology after four decades.” *F1000Prime Reports* 6:39. https://doi.org/10.12703/P6-39.

Denny, M. W. *Air and water: the biology and physics of life's media.* Princeton: Princeton University Press, 1993.

de la Gándara, F., A. Ortega, A. Belmonte, i C. Mylonas. 2011. “Spontaneous

spawning of Atlantic bluefin tuna Thunnus thynnus kept in captivity." *Proceedings of the Aquaculture 2011* 249-250.

Dias, D. Faggiani, L. P. Pezzi, D. F. Marcolino Gherardi, i R. Camargo. 2014. "Modeling the spawning strategies and larval survival of the Brazilian sardine (Sardinella brasiliensis). " *Progress in Oceanography* 123: 38–53. https://doi.org/10.1016/j.pocean.2014.03.009.

Dutour Sikirić, M., I. Janeković, M. Kuzmić. 2009. "A new approach to bathymetry smoothing in sigma-coordinate ocean models ". *Ocean Modelling*. 29(2): 128-136. https://doi.org/10.1016/j.ocemod.2009.03.009

Druon, J.-N., J.-M. Fromentin, A. R. Hanke, H. Arrizabalaga, D. Damalas, V. Tičina, G. Quílez-Badia, K. Ramirez, I. Arregui, G. Tserpes, P. Reglero, M. Deflorio, I. Oray, F. Saadet Karakulak, P. Megalofonou, T. Ceyhan, L. Grubišić, B. R. MacKenzie, J. Lamkin, P. Alfonso, i P. Addis. 2016. "Habitat suitability of the Atlantic bluefin tuna by size class: An ecological niche approach." *Progress in Oceanography* 142: 30–46. https://doi.org/10.1016/j.pocean.2016.01.002.

Državni hidrometeorološki zavod (2011): Meteorološki i hidrološki bilten, 7, 52 pp.

Državni hidrometeorološki zavod (2011): Meteorološki i hidrološki bilten, 8, 54 pp.

Državni hidrometeorološki zavod (2016): Meteorološki i hidrološki bilten, 1, 52 pp.

Državni hidrometeorološki zavod (2016): Meteorološki i hidrološki bilten, 2, 58 pp.

Državni hidrometeorološki zavod (2016): Meteorološki i hidrološki bilten, 3 47 pp.

Državni hidrometeorološki zavod (2016): Meteorološki i hidrološki bilten, 4 52 pp.

Državni hidrometeorološki zavod (2016): Meteorološki i hidrološki bilten, 5, 59 pp.

Državni hidrometeorološki zavod (2013): Prikazi br. 23, 31 pp.

Državni hidrometeorološki zavod (2017): Prikazi br. 28, 48 pp.

Džoić, T., G. Beg Paklar, B. Grbec, S. Ivatek-Šahdan, B. Zorica, T. Šegvić-Bubić, V. Čikeš Keč, I. Lepen Pleić, I. Mladineo, L. Grubišić, i P. Verley. 2017. "Spillover of the Atlantic bluefin tuna offspring from cages in the Adriatic Sea: A multidisciplinary approach and assessment." *PLoS ONE* 12 (11): e0188956.

https://doi.org/10.1371/journal.pone.0188956.

Enger, L., i B. Grisogono. 1998. “The response of bora-type flow to sea surface temperature.” *Quarterly Journal of the Royal Meteorological Society* 124 (548): 1227–44. https://doi.org/10.1256/smsqj.54809.

Fairall, C. W., E F Bradley, D P Rogers, J B Edson, i G S Young. 1996. “Bulk parameterization of air-sea fluxes for Tropical Ocean-Global Atmosphere Coupled-Ocean Atmosphere Response Experiment.” *Journal of Geophysical Research: Oceans* 101 (C2): 3747–64. https://doi.org/10.1029/95JC03205.

Falcieri, F. M., L. Kantha, A. Benetazzo, A. Bergamasco, D. Bonaldo, F. Barbariol, V. Malačić, M. Sclavo, i S. Carniel. 2016. “Turbulence observations in the Gulf of Trieste under moderate wind forcing and different water column stratification.” *Ocean Science* 12 (2): 433–49. https://doi.org/10.5194/os-12-433-2016.

Falco, P., A. Griffa, P. M. Poulain, i E. Zambianchi. 2000. “Transport properties in the Adriatic Sea as deduced from drifter data.” *Journal of Physical Oceanography* 30 (8): 2055–71. https://doi.org/10.1175/1520-0485(2000)030<2055:TPITAS>2.0.CO;2.

FEAP (Federation of European Aquaculture Producers) (2015): Annual Report 2015, 37 pp.

Fennel, K., J. Wilkin, J. Levin, J. Moisan, J. O’Reilly, i D. Haidvogel. 2006. “Nitrogen cycling in the Middle Atlantic Bight: Results from a three-dimensional model and implications for the North Atlantic nitrogen budget.” *Global Biogeochemical Cycles* 20 (3). https://doi.org/10.1029/2005GB002456.

Flather, R. A. 1976. “A tidal model of the northwest European continental shelf.” *Memoires de la Societe Royale des Sciences de Liege* 10 (6): 141–64.

Fossette, S., N. F. Putman, K. J. Lohmann, R. Marsh, i G. C. Hays. 2012. “A biologist’s guide to assessing ocean currents: A review.” *Marine Ecology Progress Series*.457: 285-301. https://doi.org/10.3354/meps09581.

Gačić, M., G. Civitarese, V. Kovačević, L. Ursella, M. Bensi, M. Menna, V. Cardin, P. M. Poulain, S. Cosoli, G. Notarstefano, i C. Pizzi. 2014. “Extreme winter

2012 in the Adriatic: An example of climatic effect on the BiOS rhythm." *Ocean Science* 10 (3): 513–22. https://doi.org/10.5194/os-10-513-2014.

Gallego, A., E. W. North, i P. Petitgas. 2007. "Introduction: Status and future of modelling physical-biological interactions during the early life of fishes." *Marine Ecology Progress Series* 347: 122–26. https://doi.org/10.3354/meps06972.

Galuardi, B., i M. Lutcavage. 2012. "Dispersal routes and habitat utilization of juvenile atlantic bluefin tuna, thunnus thynnus, tracked with mini PSAT and archival tags." *PLoS ONE* 7 (5): e37289. https://doi.org/10.1371/journal.pone.0037829.

Glamuzina, B., A. Pešić, A. Joksimović, L. Glamuzina, S. Matić-Skoko, A. Conides, D. Klaoudatos, i P. Zacharaki. 2014. "Observations on the increase of wild gilthead seabream, Sparus aurata abundance, in the eastern Adriatic Sea: problems and opportunities." *International Aquatic Research* 6 (3): 127–34. https://doi.org/10.1007/s40071-014-0073-7.

Goldhirsch, I, P L Sulem, i S A Orszag. 1987. "Stability and Lyapunov stability of dynamical systems: A differential approach and a numerical method " *Physica D: Nonlinear Phenomena* 27 (3): 311–37. https://doi.org/10.1016/0167-2789(87)90034-0.

Gordoa, A., i G. Carreras. 2014. "Determination of temporal spawning patterns and hatching time in response to temperature of atlantic bluefin tuna (thunnus thynnus) in the Western Mediterranean." *PLoS ONE* 9 (3): e90691. https://doi.org/10.1371/journal.pone.0090691.

Grbec, B., I. Vilibić, A. Bajić, M. Morović, G. Beg Paklar, F. Matić, i V. Dadić. 2007. "Response of the Adriatic Sea to the atmospheric anomaly in 2003." *Annales Geophysicae* 25 (4): 835–46. https://doi.org/10.5194/angeo-25-835-2007.

Grbec, B., A. Bajić, i Vilab team. 2016. Virtual laboratoy. Institute of Oceanography and Fisheries, Split. Meteorological and Hydrological Service, Zagreb.

Grbec, B., F. Matić, G. Beg Paklar, M. Morović, R. Popović, i I. Vilibić. 2018. "Long-term trends, variability and extremes of in situ sea surface temperature

measured along the eastern Adriatic coast and its relationship to hemispheric processes." *Pure and Applied Geophysics*, 175 (11): 4031-4046. https://doi.org/10.1007/s00024-018-1793-1.

Grigorakis, K., i G. Rigos. 2011. "Aquaculture effects on environmental and public welfare - The case of Mediterranean mariculture." *Chemosphere*. 85: 899–919. https://doi.org/10.1016/j.chemosphere.2011.07.015.

Grubišić, L., T. Šegvić-Bubić, I. Lepen Pleić, K. Mišlov-Jelavić, V. Tičina, I. Katavić, i I. Mladineo. 2013. "Morphological and genetic identification of spontaneously spawned larvae of captive bluefin tuna in the Adriatic Sea." *Fisheries* 38 (9): 410–17. https://doi.org/10.1080/03632415.2013.826201.

Gurgel, K.-W., G Antonischski, H.-H. Essen, i T Schlick. 1999. "Wellen radar (WERA): a new ground wave radar for remote sensing." *Coastal Engineering* 37: 219–34. https://doi.org/10.1016/S0378-3839(99)00027-7.

Haller, G. 2002. " Lagrangian coherent structures from approximate velocity data." *Physics of Fluids* 14 (6): 1851–61. https://doi.org/10.1063/1.1477449.

Haller, G., i G. Yuan. 2000. "Lagrangian coherent structures and mixing in two-dimensional turbulence." *Physica D: Nonlinear Phenomena* 147 (3–4): 352–70. https://doi.org/10.1016/S0167-2789(00)00142-1.

Harrison, C. S., i G. A. Glatzmaier. 2012. "Lagrangian coherent structures in the California Current System - sensitivities and limitations." *Geophysical and Astrophysical Fluid Dynamics* 106 (1): 22–44. https://doi.org/10.1080/03091929.2010.532793.

Harrison, C. S., D. A. Siegel, i S. Mitarai. 2013. "Filamentation and eddy-eddy interactions in marine larval accumulation and transport." *Marine Ecology Progress Series* 472: 27–44. https://doi.org/10.3354/meps10061.

Haza, A. C., A. Griffa, P. Martin, A. Molcard, T. M. Özgökmen, A. C. Poje, R. Barbanti, J.W. Book, P.M. Poulain, M. Rixen, i P.Zanasca. 2007. "Model-based directed drifter launches in the Adriatic Sea: Results from the DART experiment." *Geophysical Research Letters* 34 (10): 1–5. https://doi.org/10.1029/2007GL029634.

Haza, A. C., T. M. Özgökmen, A. Griffa, Z. D. Garraffo, i L. Piterbarg. 2012. "Parameterization of particle transport at submesoscales in the Gulf Stream region using Lagrangian subgridscale models." *Ocean Modelling* 42: 31–49. https://doi.org/10.1016/j.ocemod.2011.11.005.

Haza, A. C., T. M. Özgökmen, A. Griffa, A. Molcard, P. M. Poulain, i G. Peggion. 2010. "Transport properties in small-scale coastal flows: Relative dispersion from VHF radar measurements in the Gulf of la Spezia." *Ocean Dynamics* 60 (4): 861–82. https://doi.org/10.1007/s10236-010-0301-7.

Haza, A. C., L. I. Piterbarg, P. Martin, T. M. Özgökmen, i A. Griffa. 2007. "A Lagrangian subgridscale model for particle transport improvement and application in the Adriatic Sea using the Navy Coastal Ocean Model." *Ocean Modelling* 17 (1): 68–91. https://doi.org/10.1016/j.ocemod.2006.10.004.

Haza, A. C., A. C. Poje, T. M. Özgökmen, i P. Martin. 2008. "Relative dispersion from a high-resolution coastal model of the Adriatic Sea." *Ocean Modelling* 22 (1–2): 48–65. https://doi.org/10.1016/j.ocemod.2008.01.006.

Hedström, K. S. *Technical manual for a coupled sea-ice/ocean circulation model (Version 3)*. University of Alaska Fairbanks, 2009

Hernández-Carrasco, I., C. López, E. Hernández-García, i A. Turiel. 2011. "How reliable are finite-size Lyapunov exponents for the assessment of ocean dynamics?" *Ocean Modelling* 36 (3–4): 208–18. https://doi.org/10.1016/j.ocemod.2010.12.006.

Huggett, J., P. Fréon, C. Mullon, i P. Penven. 2003. "Modelling the transport success of anchovy Engraulis encrasicolus eggs and larvae in the southern Benguela: The effect of spatio-temporal spawning patterns." *Marine Ecology Progress Series* 250: 247–62. https://doi.org/10.3354/meps250247.

Huhn, F., A. Von Kameke, V. Pérez-Muñuzuri, M. J. Olascoaga, i F. J. Beron-Vera. 2012. "The impact of advective transport by the South Indian Ocean Countercurrent on the madagascar plankton bloom." *Geophysical Research Letters* 39 (6). https://doi.org/10.1029/2012GL051246.

Ibarra-Zatarain, Z., i N. Duncan. 2015. "Mating behaviour and gamete release in

gilthead seabream (Sparus aurata, Linnaeus 1758) held in captivity." *Spanish Journal of Agricultural Research* 13 (1): e04-001. https://doi.org/10.5424/sjar/2015131-6750.

Ivić, S., I. M. Haber, i T. Legović. 2017. "Lagrangian coherent structures in the Rijeka Bay current field." *Acta Adriatica* 58 (3): 373–89.

Janeković, I., H. Mihanović, I. Vilibić, i M. Tudor. 2014. "Extreme cooling and dense water formation estimates in open and coastal regions of the Adriatic Sea during the winter of 2012." *Journal of Geophysical Research: Oceans* 119 (5): 3200–3218. https://doi.org/10.1002/2014JC009865.

Jonsson, B., i N. Jonsson. 2006. "Cultured Atlantic salmon in nature: a review of their ecology and interaction with wild fish." *ICES Journal of Marine Science* 63 (7): 1162–81. https://doi.org/10.1016/j.icesjms.2006.03.004.

Juan-Jorda, M. J., I. Mosqueira, A. B. Cooper, J. Freire, i N. K. Dulvy. 2011. "Global population trajectories of tunas and their relatives." *Proceedings of the National Academy of Sciences* 108 (51): 20650–55. https://doi.org/10.1073/pnas.1107743108.

Jurčec, V. 1980. "On mesoscale characteristics of bora conditions in Yugoslavia." *Pure and Applied Geophysics* 119 (3): 640–57. https://doi.org/10.1007/BF00878165.

Karakulak, S., I. Oray, A. Corriero, M. Deflorio, N. Santamaria, S. Desantis, i Gregorio De Metrio. 2004. "Evidence of a spawning area for the bluefin tuna (Thunnus thynnus L.) in the eastern Mediterranean." *Journal of Applied Ichthyology* 20 (4): 318–20. https://doi.org/10.1111/j.1439-0426.2004.00561.x.

Klaić, Z. B., Z. Pasarić, G. Beg Paklar, i P. Oddo. 2011. "Coastal sea responses to atmospheric forcings at two different resolutions." *Ocean Science* 7: 521–532. https://doi.org/10.5194/os-7-521-2011.

Kos, I., D. Belušić; A. Jeričević; K. Horvath, D. Koračin, M. Telišman Prtenjak. 2004. "Education and research: Initial development of the Atmospheric Lagrangian Particle Stochastic (ALPS) Dispersion Model. " *Geofizika* 21: 37–52.

Kundu, P. K. 1976. "Ekman veering observed near the ocean bottom." *Journal of*

Physical Oceanography. 6: 238-242. https://doi.org/10.1175/1520-0485(1976)006<0238:EVONTO>2.0.CO;2.

Kuzmić, M., B. Grisogono, X. Li, i S. Lehner. 2015. "Examining deep and shallow Adriatic bora events." *Quarterly Journal of the Royal Meteorological Society* 141: 3434–3438. https://doi.org/10.1002/qj.2578.

Large, W. G., J. C. McWilliams, i S. C. Doney. 1994. "Oceanic vertical mixing: A review and a model with a nonlocal boundary layer parameterization." *Reviews of Geophysics* 32: 363–403. https://doi.org/10.1029/94RG01872.

Lepri, P., Ž. Večenaj, H. Kozmar, i B. Grisogono. 2017. "Bora wind characteristics for engineering applications." *Wind and Structures, An International Journal* 24 (6): 579–611. https://doi.org/10.12989/was.2017.24.6.579.

Lett, C., P. Penven, P. Ayón, i P. Fréon. 2007. "Enrichment, concentration and retention processes in relation to anchovy (Engraulis ringens) eggs and larvae distributions in the northern Humboldt upwelling ecosystem." *Journal of Marine Systems* 64 (1–4): 189–200. https://doi.org/10.1016/j.jmarsys.2006.03.012.

Lett, Christophe, Philippe Verley, Christian Mullon, Carolina Parada, Timothée Brochier, Pierrick Penven, and Bruno Blanke. 2008. "A Lagrangian tool for modelling ichthyoplankton dynamics." *Environmental Modelling and Software* 23 (9): 1210–14. https://doi.org/10.1016/j.envsoft.2008.02.005.

Lipizer, M., E. Partescano, A. Rabitti, A. Giorgetti, i A. Crise. 2014. "Qualified temperature, salinity and dissolved oxygen climatologies in a changing Adriatic Sea." *Ocean Science* 10 (5): 771–97. https://doi.org/10.5194/os-10-771-2014.

Maps, F., S. Plourde, I. H. McQuinn, S. St-Onge-Drouin, D. Lavoie, J. Chassé, i V. Lesage. 2015. "Linking acoustics and finite-time lyapunov exponents reveals areas and mechanisms of krill aggregation within the gulf of St. Lawrence, eastern Canada " *Limnology and Oceanography* 60 (6): 1965–75. https://doi.org/10.1002/lno.10145.

Marchesiello, P., J. C. McWilliams, i A. Shchepetkin. 2001. "Open boundary conditions for long-term integration of regional oceanic models." *Ocean Modelling* 3 (1–2): 1–20. https://doi.org/10.1016/S1463-5003(00)00013-5.

Mariani, P., B. R. MacKenzie, D. Iudicone, i A. Bozec. 2010. “Modelling retention and dispersion mechanisms of bluefin tuna eggs and larvae in the northwest Mediterranean Sea.” *Progress in Oceanography* 86 (1–2): 45–58. https://doi.org/10.1016/j.pocean.2010.04.027.

Mather, F. J., J. M. Mason, i C. Jones. 1995. “Historical document: Life history and fisheries of Atlantic bluefin tuna.” *NOAA Technical Memorandum* NMFS-SEFSC (370): 165. https://doi.org/10.5962/bhl.title.4783.

Melià, P., M. Schiavina, M. Rossetto, M. Gatto, S. Fraschetti, i R. Casagrandi. 2016. “Looking for hotspots of marine metacommunity connectivity: A methodological framework.” *Scientific Reports* 6. https://doi.org/10.1038/srep23705.

Mellor, G. L., i T. Yamada. 1974. “A hierarchy of turbulence closure models for planetary boundary layers.” *Journal of the Atmospheric Sciences* 31 (7): 1791–1806. https://doi.org/10.1175/1520-0469(1974)031<1791:AHOTCM>2.0.CO;2.

Mellor, G. L., i T. Yamada. 1982. “Development of a turbulence closure model for geophysical fluid problems.” *Reviews of Geophysics*. 20: 851–875. https://doi.org/10.1029/RG020i004p00851.

Mesa, M. L. A., M. Sinopoli, i F. Andaloro. 2005. “Age and growth rate of juvenile bluefin tuna Thunnus thynnus from the Mediterranean Sea (Sicily , Italy).” *Growth (Lakeland)* 69 (2): 241–49.

Mihanović, H., I. Vilibić, N. Dunić, i J. Šepić. 2015. “Mapping of decadal middle Adriatic oceanographic variability and its relation to the BiOS regime.” *Journal of Geophysical Research: Oceans* 120 (8): 5615–30. https://doi.org/10.1002/2015JC010725.

Mitarai, S., D. A. Siegel, i K. B. Winters. 2008. “A numerical study of stochastic larval settlement in the California Current system.” *Journal of Marine Systems* 69 (3–4): 295–309. https://doi.org/10.1016/j.jmarsys.2006.02.017.

Monin, A. S., i R.V. Ozmidov. *Ocean turbulence*. Leningrad: Gidrometeoizdat, 1981.

Morel, X., M. A. Lucas, i F. Dos Santos. 2014. “A Lagrangian study of the Brazil-Malvinas confluence: Lagrangian coherent structures and several lyapunov

exponents." *Journal of Operational Oceanography* 7 (2): 13–23. https://doi.org/10.1080/1755876X.2014.11020155.

Moretti, A., M. Pedini Fernandez-Criado, G. Cittolin, i R. Guidastri. 1999. "Manual on Hatchery Production of Seabass and Gilthead Seabream, Volume 1." *Organization* 2: 194.

Munk, P., M. M. Hansen, G. E. Maes, T. G. Nielsen, M. Castonguay, L. Riemann, H. Sparholt, i sur. 2010. "Oceanic fronts in the Sargasso Sea control the early life and drift of Atlantic eels." *Proceedings of the Royal Society B: Biological Sciences* 277:3593–99. https://doi.org/10.1098/rspb.2010.0900.

Mylonas, C. C., C. Bridges, H. Gordin, A. B. Ríos, A. García, F. De La Gándara, C. Fauvel, M. Suquet, A. Medina, M. Papadaki, G. Heinisch, G. De Metrio, A. Corriero, R. Vassallo-Agius, J. M. Guzman, E. Mananos, i Y. Zohar. 2007. "Preparation and administration of gonadotropin-releasing hormone agonist (GnRHa) implants for the artificial control of reproductive maturation in captive-reared Atlantic bluefin tuna (Thunnus thynnus thynnus)." *Reviews in Fisheries Science* 15 (3): 183–210. https://doi.org/10.1080/10641260701484572.

Naro-Maciel, E., K. M. Hart, R. Cruciata, i N. F. Putman. 2017. "DNA and dispersal models highlight constrained connectivity in a migratory marine megavertebrate." *Ecography* 40 (5): 586–97. https://doi.org/10.1111/ecog.02056.

Nicolle, A., P. Garreau, i B. Liorzou. 2009. "Modelling for anchovy recruitment studies in the Gulf of Lions (Western Mediterranean Sea)." *Ocean Dynamics* 59 (6): 953–68. https://doi.org/10.1007/s10236-009-0221-6.

Oddo, P., N. Pinardi, M. Zavatarelli, i A. Coluccelli. 2006. "The Adriatic basin forecast system." *Acta Adriatica* 47: 169–84.

Orlić, M., G. Beg Paklar, Z. Pasarić, B. Grbec, i M. Pasarić. 2006a. "Nested modeling of the east Adriatic coastal waters." *Acta Adriatica* 47: 219-45.

Orlić, M., V. Dadić, B. Grbec, N. Leder, A. Marki, F. Matić, H. Mihanović, G. Beg Paklar, M. Pasarić, Z. Pasarić, i I. Vilibić. 2006b. "Wintertime buoyancy forcing, changing seawater properties, and two different circulation systems produced in the Adriatic." *Journal of Geophysical Research: Oceans*. 111: C03S07.

https://doi.org/10.1029/2005JC003271.

Orlić, M., M. Kuzmić, i Z. Pasarić. 1994. "Response of the Adriatic Sea to the bora and sirocco forcing." *Continental Shelf Research* 14 (1): 91–116. https://doi.org/10.1016/0278-4343(94)90007-8.

Ospina-Álvarez, A., M. Bernal, I. A. Catalán, D. Roos, J. L. Bigot, i I. Palomera. 2013. "Modeling fish egg production and spatial distribution from acoustic data: A step forward into the analysis of recruitment." *PLoS ONE* 8 (9): e73687. https://doi.org/10.1371/journal.pone.0073687.

Ospina-Álvarez, A., I. Palomera, i C. Parada. 2012. "Changes in egg buoyancy during development and its effects on the vertical distribution of anchovy eggs." *Fisheries Research* 117–118: 86–95. https://doi.org/10.1016/j.fishres.2011.01.030.

Ospina-Alvarez, A., C. Parada, i I. Palomera. 2012. "Vertical migration effects on the dispersion and recruitment of European anchovy larvae: From spawning to nursery areas." *Ecological Modelling* 231: 65–79. https://doi.org/10.1016/j.ecolmodel.2012.02.001.

Ourmieres, Y., J. Mansui, A. Molcard, F. Galgani, i I. Poitou. 2018. "The boundary current role on the transport and stranding of floating marine litter: The French Riviera case." *Continental Shelf Research* 155: 11–20. https://doi.org/10.1016/j.csr.2018.01.010.

Parada, C., C. D. Van Der Lingen, C. Mullon, i P. Penven. 2003. "Modelling the effect of buoyancy on the transport of anchovy (Engraulis capensis) eggs from spawning to nursery grounds in the southern Benguela: An IBM approach." *Fisheries Oceanography* 12 (3): 170–84. https://doi.org/10.1046/j.1365-2419.2003.00235.x.

Parada, C., F. Colas, S. Soto-Mendoza, i L. Castro. 2012. "Effects of seasonal variability in across- and alongshore transport of anchoveta (Engraulis ringens) larvae on model-based pre-recruitment indices off central Chile." *Progress in Oceanography* 92–95: 192–205. https://doi.org/10.1016/j.pocean.2011.07.015.

Peacock, T., i G. Haller. 2013. "Lagrangian coherent structures: The hidden skeleton of fluid flows." *Physics Today* 66 (2): 41–47. https://doi.org/10.1063/PT.3.1886.

Peikert, R., A. Pobitzer, F. Sadlo, i B. Schindler. 2014. "A Comparison of finite-time and finite-size lyapunov exponents." In *Mathematics and Visualization*, 187–200. https://doi.org/10.1007/978-3-319-04099-8_12.

Peliz, A., P. Marchesiello, J. Dubert, M. Marta-Almeida, C. Roy, i H. Queiroga. 2007. "A study of crab larvae dispersal on the Western Iberian Shelf: Physical processes." *Journal of Marine Systems* 68 (1–2): 215–36. https://doi.org/10.1016/j.jmarsys.2006.11.007.

Penven, P., C. Roy, G. B. Brundrit, A. Colin de Verdière, P. Fréon, A. S. Johnson, J. R.E. Lutjeharms, i F. A. Shillington. 2001. "A regional hydrodynamic model of upwelling in the Southern Benguela." *South African Journal of Science* 97 (11–12): 472–75.

Polo, A., M. Yúfera, i E. Pascual. 1991. "Effects of temperature on egg and larval development of Sparus aurata L." *Aquaculture* 92 (C): 367–75. https://doi.org/10.1016/0044-8486(91)90042-6.

Poulain, P. M. 2001. "Adriatic Sea surface circulation as derived from drifter data between 1990 and 1999." *Journal of Marine Systems*, 29: 3–32. https://doi.org/10.1016/S0924-7963(01)00007-0.

Poulain, P. M. i B. Cushman-Roisin, B. *Physical oceanography of the Adriatic Sea*. Uredili Cushman-Roisin, B., M. Gačić, P. M. Poulain, i A. Artegiani. Dordrecht: Kluwer Academic Publishers, 2001. https://doi.org/10.1007/978-94-015-9819-4.

Prieto, L., D. Macĺas, A. Peliz, i J. Ruiz. 2015. "Portuguese Man-of-War (Physalia physalis) in the Mediterranean: A permanent invasion or a casual appearance?" *Scientific Reports* 5: 11545. https://doi.org/10.1038/srep11545.

Pullen, J., J. D. Doyle, R. Hodur, A. Ogston, J. W. Book, H. Perkins, i R. Signell. 2003. "Coupled ocean-atmosphere nested modeling of the Adriatic Sea during winter and spring 2001." *Journal of Geophysical Research* 108 (C10): 3320. https://doi.org/10.1029/2003JC001780.

Putman, N. F., J. M. Bane, i K. J. Lohmann. 2010. "Sea turtle nesting distributions and oceanographic constraints on hatchling migration." *Proceedings of the Royal Society B: Biological Sciences*, 277: 3631–37.

https://doi.org/10.1098/rspb.2010.1088.

Putman, N. F., i R. He. 2013. “Tracking the long-distance dispersal of marine organisms: Sensitivity to ocean model resolution.” *Journal of the Royal Society Interface* 10 (81). https://doi.org/10.1098/rsif.2012.0979.

Putman, Nathan F., Rick Lumpkin, Alexander E. Sacco, and Katherine L. Mansfield. 2016. “Passive drift or active swimming in marine organisms ?” *Proceedings of the Royal Society B: Biological Sciences* 283 (1844). https://doi.org/10.1098/rspb.2016.1689.

Raicich, F. 1994. “Note on the flow rates of the Adriatic rivers.” *Consiglio Nazionale delle Ricerche Istituto Sperimentale Talassografico Technical Report RF 02/94.* 1–8.

Reglero, P., N. Zaragoza, E. Blanco, F. De La Gandara, A. P. Torres, i A. Ortega. 2015. “Routine swimming speed of bluefin tuna larvae measured in the laboratory” *Proceedings of the 39th Annual Larval Fish Conference* 1–1.

Renault, L., J. Chiggiato, J. C. Warner, M. Gomez, G. Vizoso, i J. Tintoré. 2012. “Coupled atmosphere-ocean-wave simulations of a storm event over the Gulf of Lion and Balearic Sea.” *Journal of Geophysical Research: Oceans* 117 (9). https://doi.org/10.1029/2012JC007924.

Renka, R. J. 1984. “Algorithm 624: Triangulation and interpolation at arbitrarily distributed points in the plane.” *ACM Transactions on Mathematical Software* 10 (4): 440–42. https://doi.org/10.1145/2701.356108.

Rixen M, Book JW, Cavanna JA, i DART partneri. *Dynamics of the Adriatic in real-time - DART06A. DVD.* La Spezia, 2006.

Rixen, M., E. Ferreira-Coelho, i R. Signell. 2008. “Surface drift prediction in the Adriatic Sea using hyper-ensemble statistics on atmospheric, ocean and wave models: Uncertainties and probability distribution areas.” *Journal of Marine Systems* 69 (1–2): 86–98. https://doi.org/10.1016/j.jmarsys.2007.02.015.

Ross, O. N., i J. Sharples. 2004. “Recipe for 1-D Lagrangian particle tracking models in space-varying diffusivity.” *Limnology and Oceanography: Methods* 2 (9): 289–302. https://doi.org/10.4319/lom.2004.2.289.

Rubio, A., J. Mader, L. Corgnati, C. Mantovani, A. Griffa, A. Novellino, C. Quentin, L. Wyatt, J. Schulz-Stellenfleth, J. Horstmann, P. Lorente, E. Zambianchi, M. Hartnett, C. Fernandes, V. Zervakiss, P. Gorringe, A. Melet, i I. Puillat. 2017. "HF radar activity in European coastal seas: Next steps toward a Pan-European HF radar network." *Frontiers in Marine Science* 4. https://doi.org/10.3389/fmars.2017.00008.

Russo, T., C. Costa, i S. Cataudella. 2007. "Correspondence between shape and feeding habit changes throughout ontogeny of gilthead sea bream Sparus aurata L. 1758." *Journal of Fish Biology* 71 (3): 629–56. https://doi.org/10.1111/j.1095-8649.2007.01528.x.

Rypina, I. I., M. G. Brown, i H. Koçak. 2009. "Transport in an idealized three-gyre system with application to the Adriatic Sea." *Journal of Physical Oceanography* 39 (3): 675–90. https://doi.org/10.1175/2008JPO3975.1.

Sabates, A., P. Martin, J. Lloret, i V. Raya. 2006. "Sea warming and fish distribution: the case of the small pelagic fish, Sardinella aurita, in the western Mediterranean." *Global Change Biology* 12 (11): 2209–19. https://doi.org/10.1111/j.1365-2486.2006.01246.x.

Santos, A.M.P., A. E. Nieblas, P. Verley, A. Teles-Machado, S. Bonhommeau, C. Lett, S. Garrido, i A. Peliz. 2018. "Sardine (Sardina pilchardus) larval dispersal in the Iberian upwelling system, using coupled biophysical techniques." *Progress in Oceanography* 162: 83–97. https://doi.org/10.1016/j.pocean.2018.02.011.

Schroeder, K., J. Chiggiato, A. C. Haza, A. Griffa, T. M. Zgkmen, P. Zanasca, A. Molcard, M. Borghini, P.M. Poulain, R. Gerin, E. Zambianchi, P. Falco, i C. Trees. 2012. "Targeted Lagrangian sampling of submesoscale dispersion at a coastal frontal zone." *Geophysical Research Letters* 39 (11): 4–9. https://doi.org/10.1029/2012GL051879.

Shadden, S. C., F. Lekien, i J. E. Marsden. 2005. "Definition and properties of Lagrangian coherent structures from finite-time Lyapunov exponents in two-dimensional aperiodic flows." *Physica D: Nonlinear Phenomena* 212 (3–4): 271–304. https://doi.org/10.1016/j.physd.2005.10.007.

Shaltout, M., i A. Omstedt. 2014. “Recent dynamic topography changes in the Mediterranean Sea analysed from satellite altimetry data.” *Current Development in Oceanography* 7 (1–2): 1–26.

Shchepetkin, A. F. 2003. “A method for computing horizontal pressure-gradient force in an oceanic model with a nonaligned vertical coordinate.” *Journal of Geophysical Research* 108 (C3): 3090. https://doi.org/10.1029/2001JC001047.

Shchepetkin, A. F., i J. C. McWilliams. 2005. “The regional oceanic modeling system (ROMS): a split-explicit, free-surface, topography-following-coordinate oceanic model..” *Ocean Modelling* 9 (4): 347–404. https://doi.org/10.1016/j.ocemod.2004.08.002.

Siegel, D. A., S. Mitarai, C. J. Costello, S. D. Gaines, B. E. Kendall, R. R. Warner, i K. B. Winters. 2008. “The stochastic nature of larval connectivity among nearshore marine populations.” *Proceedings of the National Academy of Sciences* 105 (26): 8974–79. https://doi.org/10.1073/pnas.0802544105.

Simoncelli, S., N. Pinardi, P. Oddo, A. J. Mariano, G. Montanari, A. Rinaldi, i M. Deserti. 2011. “Coastal rapid environmental assessment in the northern Adriatic Sea.” *Dynamics of Atmospheres and Oceans* 52 (1–2): 250–83. https://doi.org/10.1016/j.dynatmoce.2011.04.004.

Somarakis, S., M. Pavlidis, C. Saapoglou, C. S. Tsigenopoulos, i T. Dempster. 2013. “Evidence for “escape through spawning” in large gilthead sea bream Sparus aurata reared in commercial sea-cages.” *Aquaculture Environment Interactions* 3 (2): 135–52. https://doi.org/10.3354/aei00057.

Song, Y., i D. Haidvogel. 1994. “A semi-implicit ocean circulation model using a generalized topography-following coordinate system.” *Journal of Computational Physics* 115 (1): 228–44. https://doi.org/10.1006/jcph.1994.1189.

Soto-Mendoza, S., C. Parada, L. Castro, F. Colas, i W. Schneider. 2012. “Modeling transport and survival of anchoveta eggs and yolk-sac larvae in the coastal zone off central-southern Chile: Assessing spatial and temporal spawning parameters.” *Progress in Oceanography* 92–95: 178–91. https://doi.org/10.1016/j.pocean.2011.07.001.

Stagličić, N., T. Šegvić-Bubić, P. Ugarković, I. Talijančić, I. Žužul, V. Tičina, i L. Grubišić. 2017. "Ecological role of bluefin tuna (Thunnus thynnus) fish farms for associated wild fish assemblages in the Mediterranean Sea." *Marine Environmental Research* 132: 79–93. https://doi.org/10.1016/j.marenvres.2017.10.015.

Supić, N., i M. Orlić. 1992. "Annual cycle of sea surface temperature along the east Adriatic coast." *Geofizika* 9: 79–97.

Šegvić-Bubić, T., I. Talijančić, L. Grubišić, D. Izquierdo-Gomez, i I. Katavić. 2014. "Morphological and molecular differentiation of wild and farmed gilthead sea bream sparus aurata: Implications for management." *Aquaculture Environment Interactions* 6 (1): 43–54. https://doi.org/10.3354/aei00111.

Šegvić-Bubić, T., L. Grubišić, Ž. Trumbić, R. Stanić, J. Ljubković, J. Maršić-Lučić, i I. Katavić. 2017. "Genetic characterization of wild and farmed european seabass in the Adriatic Sea: Assessment of farmed escapees using a Bayesian approach." *ICES Journal of Marine Science* 74 (1): 369–78. https://doi.org/10.1093/icesjms/fsw155.

Thibaut, T., L. Bottin, D. Aurelle, C.-F. Boudouresque, A. Blanfuné, M. Verlaque, I. Pairaud, i B. Millet. 2016. "Connectivity of populations of the seaweed Cystoseira amentacea within the Bay of Marseille (Mediterranean Sea): Genetic structure and hydrodynamic connections." *Cryptogamie Algologie* 37 (4): 233–55. https://doi.org/10.7872/crya/v37.iss4.2016.233.

Thomson, D. J., i J. D. Wilson. 2012. "History of Lagrangian stochastic models for turbulent dispersion." *Lagrangian Modeling of the Atmosphere*, 200: 19–36. https://doi.org/10.1029/2012gm001238.

Trujillo, P., C. Piroddi, i J. Jacquet. 2012. "Fish farms at sea: The ground truth from Google Earth." *PLoS ONE* 7 (2): e0134745. https://doi.org/10.1371/journal.pone.0030546.

Tudor, M., Stj. Ivatek-Šahdan, A. Stanić, K. Horvath, i A. Bajić. 2013. "Forecasting weather in Croatia using ALADIN numerical weather prediction model." *Climate Change and Regional/Local Responses*. InTech. https://doi.org/10.5772/55698.

Umlauf, L., i H. Burchard. 2003. “A generic length-scale equation for geophysical turbulence models..” *Journal of Marine Research* 61 (2): 235–65. https://doi.org/10.1357/002224003322005087.

Vaz, A. C., K. J. Richards, Y. Jia, i C. B. Paris. 2013. “Mesoscale flow variability and its impact on connectivity for the island of Hawai’i” *Geophysical Research Letters* 40 (2): 332–37. https://doi.org/10.1029/2012GL054519.

Vikebø, F., S. Sundby, B. Ådlandsvik, i Ø. Fiksen. 2005. “The combined effect of transport and temperature on distribution and growth of larvae and pelagic juveniles of Arcto-Norwegian cod.” *ICES Journal of Marine Science* 62: 1375–86. https://doi.org/10.1016/j.icesjms.2005.05.017.

Vilibić, I., J. W. Book, G. Beg Paklar, M. Orlić, V. Dadić, M. Tudor, P. J. Martin, M. Pasarić, B. Grbec, F. Matić, H. Mihanović, i M. Morović. 2009. “West Adriatic coastal water excursions into the east Adriatic.” *Journal of Marine Systems* 78: 132- 156. https://doi.org/10.1016/j.jmarsys.2009.01.015.

Vilibić, I., i H. Mihanović. 2013. “Observing the bottom density current over a shelf using an Argo profiling float.” *Geophysical Research Letters* 40 (5): 910–15. https://doi.org/10.1002/grl.50215.

Vilibić, I., H. Mihanović, I. Janeković, C. Denamiel, P. M. Poulain, M. Orlić, N. Dunić,V. Dadić, M. Pasarić, S. Muslim, R. Gerin, F. Matić, J. Šepić, E. Mauri, Z. Kokkini, M. Tudor. Ž. Kovač, i T. Džoić. 2018. “Wintertime dynamics in the coastal northeastern Adriatic Sea: the NAdEx 2015 experiment.” *Ocean Science* 14 (2): 237–58. https://doi.org/10.5194/os-14-237-2018.

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

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

Vilibić, I., J. Šepić, i N. Proust. 2013. “Weakening thermohaline circulation in the Adriatic Sea.” *Climate Research* 55 (3): 217–25.

https://doi.org/10.3354/cr01128.

Visser, AW. 1997. “Using random walk models to simulate the vertical distribution of particles in a turbulent water column.” *Marine Ecology Progress Series* 158: 275–81. https://doi.org/10.3354/meps158275.

Vodopivec, M., A. J. Peliz, i A. Malej. 2017. “Offshore marine constructions as propagators of moon jellyfish dispersal.” *Environmental Research Letters* 12 (8). https://doi.org/10.1088/1748-9326/aa75d9.

Warner, J. C., C. R. Sherwood, R. P. Signell, C. K. Harris, i H. G. Arango. 2008. “Development of a three-dimensional, regional, coupled wave, current, and sediment-transport model.” *Computers and Geosciences* 34 (10): 1284–1306. https://doi.org/10.1016/j.cageo.2008.02.012.

Wiggins, S. 2005. “The dynamical systems approach to Lagrangian transport in oceanic flows.” *Annual Review of Fluid Mechanics* 37 (1): 295–328. https://doi.org/10.1146/annurev.fluid.37.061903.175815.

Wilkin, J. L., H. G. Arango, D. B. Haidvogel, C. S. Lichtenwalner, S. M. Glenn, i K. S. Hedström. 2005. “A regional ocean modeling system for the Long-term Ecosystem Observatory.” *Journal of Geophysical Research: Oceans* 110 (6): 1–13. https://doi.org/10.1029/2003JC002218.

Willis, J. 2011. “Modelling swimming aquatic animals in hydrodynamic models.” *Ecological Modelling*. 222(23-24): 3869-87 https://doi.org/10.1016/j.ecolmodel.2011.10.004.

Zavatarelli, M., i N. Pinardi. 2003. “The Adriatic Sea modelling system: a nested approach.” *Annales Geophysicae* 21 (1): 345–64. https://doi.org/10.5194/angeo-21-345-2003.

Zore-Armanda, M. 1968. “The system of currents in the Adriatic Sea.” *Études et Revues–Conseil Général Des Peches Pour La Méditerranée, FAO, Rome* 34: 1–48.

Zore-Armanda, M. 1969. “Temperature relations in the Adriatic Sea.” *Acta Adriatica* 13 (5): 1–51.

7. ŽIVOTOPIS

Tomislav Džoić rođen je 15. studenog 1985. godine u Slavonskom Brodu. Pohađao je Osnovnu školu Trilj i Osnovnu školu Ivana Kozarca u Županji. Prirodoslovno-matematički smjer gimnazije je završio u Gimnaziji Županja, nakon čega upisuje Prirodoslovno-matematički fakultet Sveučilišta u Zagrebu. Godine 2009. završava preddiplomski sveučilišni studij i postaje sveučilišni prvostupnik geofizike. U siječnju 2012. godine brani diplomski rad „Procjena kvalitete zraka regionalnim kemijskim modelom" pod mentorstvom prof. dr. sc Zvjezdane Bencetić Klaić i komentorstvom dr. sc. Amele Jeričević i time završava sveučilišni diplomski studij fizike-geofizike, smjer meteorologija i fizička oceanografija. Zapošljava se u ožujku 2012. godine kao znanstveni novak u Laboratoriju za fiziku mora Instituta za oceanografiju i ribarstvo. Iste godine upisuje poslijediplomski doktorski studij fizike, smjer geofizika na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu.

Sudjelovao je u znanstveno-istraživačkom projektu Istraživanje i sustavi praćenja neubičajene dinamike Jadrana od 2012. do 2013. godine i MESSI – Meteotsunamis, destructive long ocean waves in the tsunami frequency band: from observations and simulations towards a warning system od 2015. do 2017. godine. Trenutno sudjeluje na znanstveno-istraživačkim projektima MARIPLAN – Morski plankton kao alat za procjenu klimatskog i antropogenog utjecaja i MAUD – Izranjanje i poniranje u području srednjeg Jadrana.

Stručno se usavršavao na INDO-MARECLIM Winterschool on Climate Change and Variability, Marine Ecosystems and Coastal Zone Menagment 2013. godine u Indiji, ROMS User Workshop 2014. godine u Hrvatskoj, COAWST Training Workshop 2016. godine na Woods Hole Oceanographic Institute u SAD-u, Operational Marine Surface Analysis using EUMETSAT's Copernicus Marine Data Stream 2016. godine u Hrvatskoj. Koautor je na sedam sažetaka sa znanstvenih skupova. Prvi autor je na jednom, a koautor na pet znanstvenih radova.

8. POPIS OBJAVLJENIH RADOVA

Beg Paklar, G., **T. Džoić**, i V. Dadić. 2015. "Numerical study of the north Adriatic circulation during two successive bora episodes." *Acta Adriatica* 56 (1): 115-138.

Vilibić, I., V. Čikeš Keč, B. Zorica, J. Šepić, S. Matijević, i **T. Džoić**. 2016. "Hydrographic conditions driving sardine and anchovy populations in a land-locked sea." *Mediterranean Marine Science* 17 (1): 1-2. https://doi.org/10.12681/mms.1120.

Džoić, T., G. Beg Paklar, B. Grbec, S. Ivatek-Šahdan, B. Zorica, T. Šegvić-Bubić, V.Čikeš Keč, I. Lepen Pleić, I. Mladinuo, L. Grubišić, i P. Verley. 2017. "Spillover of the Atlantic bluefin tuna offspring from cages in the Adriatic Sea: A multidisciplinary approach and assessment." *PLoS ONE* 12 (11): e0188956. https://doi.org/10.1371/journal.pone.0188956.

Matić, F., Ž. Kovač, I. Vilibić, H. Mihanović, M. Morović, B. Grbec, N. Leder, i **T. Džoić**. 2017. "Oscillating Adriatic temperature and salinity regimes mapped using the Self-Organizing Maps method." *Continental Shelf Research* 132: 11–18. https://doi.org/10.1016/j.csr.2016.11.006.

Peharda, M., I. Vilibić, B. A. Black, K. Markulin, N. Dunić, **T. Džoić**, H. Mihanović, M. Gačić, S. Puljas, i R. Waldman. 2018. "Using bivalve chronologies for quantifying environmental drivers in a semi-enclosed temperate sea." *Scientific Reports* 8 (1). https://doi.org/10.1038/s41598-018-23773-w.

Vilibić, I., H. Mihanović, I. Janeković, C. Denamiel, P.-M. Poulain, M. Orlić, N. Dunić, V. Dadić, M. Pasarić, S. Muslim, R. Gerin, F. Matić, J. Šepić, E. Mauri, Z. Kokkini, M. Tudor, Ž. Kovač, **T. Džoić**. 2018. "Wintertime dynamics in the coastal northeastern Adriatic Sea: The NAdEx 2015 experiment." *Ocean Science* 14 (2): 237–58. https://doi.org/10.5194/os-14-237-2018.