# Ekološke karakteristike i uzgojni potencijal preostalih populacija vrste Gongolaria barbata (Stackhouse) Kuntze na istarskoj obali

**Bilajac, Andrea**

**Doctoral thesis / Doktorski rad**

**2024**

*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:217:840137

*Rights / Prava:* In copyright / Zaštićeno autorskim pravom.

*Download date / Datum preuzimanja:* **2025-10-10**

*Repository / Repozitorij:*

Repository of the Faculty of Science - University of Zagreb

Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet
Geološki odsjek

Andrea Bilajac

# Ekološke karakteristike i uzgojni potencijal preostalih populacija vrste *Gongolaria barbata* (Stackhouse) Kuntze na istarskoj obali

DOKTORSKI RAD

Zagreb, 2024

Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet
Geološki odsjek

Andrea Bilajac

# Ekološke karakteristike i uzgojni potencijal preostalih populacija vrste *Gongolaria barbata* (Stackhouse) Kuntze na istarskoj obali

DOKTORSKI RAD

Mentorica:
dr. sc. Ljiljana Iveša

Zagreb, 2024

University of Zagreb

Faculty of science
Department of geology

Andrea Bilajac

# Ecological features and cultivation potential of the remaining populations of *Gongolaria barbata* (Stackhouse) Kuntze on the Istrian coast

DOCTORAL DISSERTATION

Supervisor:
Ljiljana Iveša, PhD

Zagreb, 2024

Ovaj doktorski rad izrađen je u sklopu Sveučilišnog poslijediplomskog doktorskog studija Oceanologije pri Geološkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu pod vodstvom dr. sc. Ljiljane Iveša. Istraživanje je provedeno u sklopu projekta IP-2019-04-6984 "Odgovori smeđih algi roda *Cystoseira*, koje formiraju staništa, na lokalne i globalne stresore (HabCYS)" Hrvatske zaklade za znanost. Prikupljanje biološkog materijala se odvijalo u sjevernom Jadranu (zapadna i južna obala Istre). Obrada uzoraka, analiza podataka i pisanje doktorskog rada provedeni su u Centru za istraživanje mora Rovinj Instituta Ruđer Bošković.

Bilojac

ZAHVALA

*Za početak, jedno veliko hvala mojoj mentorici dr. sc. Ljiljani Iveša na prilici pružanoj za rad u znanosti i na svim iskustvima koja mi je prenijela u terenskim istraživanjima i znanstvenom radu, koja su na kraju doprinijela izradi ovog doktorskog rada.*

*Zahvaljujem se članovima povjerenstva prof. dr. sc. Petru Kružiću, prof. dr. sc. Zrinki Ljubešić i dr. sc. Tamari Đakovac na savjetima oko dorade doktorskog rada.*

*Zahvaljujem se kolegi Ediju Gljušćiću na velikoj pomoći kod terenskog uzorkovanja, obrade fotografija, postavljanja i praćenja laboratorijskih eksperimenata, te na konstruktivnim raspravama o ekologiji makroalgi. Hvala kolegici Shannen Smith na pomoći na terenu u hladnim zimskim mjesecima. Hvala kolegici Vittoria Ferrari na obradi dijela podataka koji su korišteni u ovom radu. Hvala dr. sc. Tamari Đakovac, Mariji Fornažar, Margareti Buterer i Jasni Jakovčević na pomoći pri kemijskoj analizi uzoraka morske vode. Hvala Denisu Škalicu na organizaciji abiotičkih podataka i Dariu Devescovi na pomoći oko ronjenja. I posebno hvala dr. sc. Mirjani Najdek na pomoći kod postavljanja eksperimenta i savjeta pri pisanju znanstvenih radova.*

*Zahvaljujem se svim kolegama s CIM-a koji su na bilo koji način doprinijeli izradi ovog doktorskog rada.*

*Hvala mojim prijateljima.*

*Posebno se zahvaljujem mojoj obitelji koja je uvijek bila zainteresirana za moj rad i koja mi je pružala bezuvjetnu podršku. Hvala vam!*

*Andrea Bilajac*

Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet

Geološki odsjek

Doktorski rad

**Ekološke karakteristike i uzgojni potencijal preostalih populacija vrste *Gongolaria barbata* (Stackhouse) Kuntze na istarskoj obali**

Andrea Bilajac

Centar za istraživanje mora, Institut Ruđer Bošković, G. Paliage 5, Rovinj

Vrsta *Gongolaria barbata* smeđa je makroalga koja je nekada bila ključni graditelj staništa na istarskoj obali, no danas je njezina rasprostranjenost ograničena na nekoliko staništa: plitki infralitoral, mediolitoralne lokvice i obalnu lagunu. U okviru ovog istraživanja kartirane su populacije *G. barbata* na zapadnoj obali Istre, te su na odabranim lokacijama analizirane morfometrijske karakteristike i biomasa s ciljem procjene stanja preostalih populacija. Recentni podaci su uspoređeni s povijesnim podacima kako bi se identificirale dugoročne promjene u populacijama te izradio opći model predikcije biomase temeljen na morfometrijskim karakteristikama. Populacija u laguni potencijalno predstavlja posljednu kontinuiranu šumu na istarskoj obali usprkos ekstremnim ljetnim temperaturama. Stoga je u *ex situ* eksperimentu termotolerancije ispitan utjecaj povišenih temperatura na odrasle jedinke iz lagune. Nadalje, istražen je *ex situ* uzgoj pod različitim intenzitetima svjetlosti, kao i *in situ* rast i razvoj juvenilnih jedinki tijekom godine dana uz praćenje abiotičkih čimbenika, s ciljem optimizacije metoda obnove populacija. Rezultati istraživanja ukazuju na značajnu varijabilnost jedinki *G. barbata* unutar i između lokacija uzorkovanja, a na nekoliko lokacija zabilježen je dugoročni trend degradacije populacija. Unotač tome što je izrada općeg modela predikcije biomase moguća, sezonska uzorkovanja potrebna su za preciznost modela. Odrasle jedinke pokazuju visoku otpornost i sposobnost regeneracije nakon produljenog izlaganja ekstremnim temperaturama. Za kraj, uzgoj vrste *G. barbata* je moguć, u kontroliranim *ex situ* uvjetima te pod povoljnim abiotičkim čimbenicima *in situ*, koji predstavljaju optimalne uvjete za rast i razvoj juvenilnih jedinki. Navedene spoznaje doprinose našem razumijevanju ekologije, potencijala za obnovu i očuvanja jedne od najvažnijih vrsta koje oblikuju staništa u Sredozemlju.

(170 stranica, 50 slika, 4 tablice, 218 literaturnih navoda, 34 priloga, jezik izvornika: hrvatski)
Ključne riječi: *Gongolaria barbata*, morfometrija, predikcija biomase, termotolerancija, uzgoj, obnova

| | |
|---|---|
| Mentorica: | dr. sc. Ljiljana Iveša, znanstvena savjetnica |
| Ocjenjivači: | prof. dr. sc. Petar Kružić |
| | prof. dr. sc. Zrinka Ljubešić |
| | dr. sc. Tamara Đakovac, znanstvena savjetnica |
| Zamjena: | dr. rer. nat. Martin Andreas Pfannkuchen, znanstveni savjetnik |

Rad prihvaćen: 10.09.2024.

University of Zagreb
Faculty of Science
Department of Geology

Doctoral thesis

**Ecological features and cultivation potential of the remaining populations of *Gongolaria barbata* (Stackhouse) Kuntze on the Istrian coast**

Andrea Bilajac

Center for Marine Research, Ruđer Bošković Institute, G. Paliaga 5, Rovinj

*Gongolaria barbata* is a brown macroalgae that was once a key habitat builder on the Istrian coast. Today, its distribution is limited to a few habitats: the shallow infralittoral zone, mediolittoral pools, and a coastal lagoon. This study mapped *G. barbata* populations on the western coast of Istria, analyzing morphometric characteristics and biomass at selected locations to assess the remaining populations. Recent data were compared with historical data to identify long-term changes and develop a general biomass prediction model based on morphometric traits. The lagoon population potentially represents the last continuous forest on the Istrian coast, despite extreme summer temperatures. To explore this, an *ex situ* thermotolerance experiment was conducted, testing the effect of elevated temperatures on adult individuals from the lagoon. *Ex situ* cultivation under different light intensities, as well as *in situ* growth and development of juvenile individuals over a year with abiotic factor monitoring, was investigated to optimize restoration methods. Results showed significant variability in *G. barbata* within and between locations, with some populations showing long-term degradation trends. While a general biomass prediction model is feasible, seasonal sampling is required for accuracy. Adult individuals demonstrated resilience and regeneration after prolonged exposure to extreme temperatures. Cultivation of *G. barbata* is possible under controlled *ex situ* conditions and in favorable *in situ* abiotic conditions, which support optimal growth of juveniles. These findings contribute to our understanding of the ecology, restoration potential, and conservation of one of the most important habitat-forming species in the Mediterranean.

(170 pages, 50 figures, 4 tables, 218 references, 34 appendices, original in Croatian)
Keywords: *Gongolaria barbata*, morphometry, biomass prediction, thermotolerance, cultivation, restoration

| | |
|---|---|
| Supervisor: | Ljiljana Iveša PhD, Senior scientist |
| Reviewers: | Petar Kružić PhD, Full Professor |
| | Zrinka Ljubešić PhD, Full Professor |
| | Tamara Đakovac PhD, Senior scientist |
| Substitute: | Martin Andreas Pfannkuchen PhD, Senior scientist |

Thesis accepted: 10th September 2024

# THESIS SUMMARY

In this thesis, we explore the ecological characteristics and restoration potential of *Gongolaria barbata*, a species of brown algae that once played a crucial role in the ecosystem of the Istrian coast (Iveša et al., 2016). This species, historically dominant as a habitat builder, has experienced significant decline due to various environmental stressors, both local and global (Verdura et al., 2023). This thesis investigates the current state of the remaining populations of *G. barbata*, assesses their ecological significance, and explores their potential for restoration and cultivation as a means of conserving the species and the ecosystems it supports.

The *Cystoseira sensu lato*, which includes the genus *Gongolaria*, is taxonomically diverse, with several species forming underwater belts and forests in the Mediterranean's rocky shores from the upper level of the sublittoral to the upper level of the circalittoral zone (Giaccone and Bruni, 1973). These species are highly sensitive to environmental changes, particularly eutrophication, pollution, and overgrazing by herbivorous fish and sea urchins (Iveša et al., 2021; Ling et al., 2015; Munda, 1982; Thibaut et al., 2014). Numerous studies have documented the decline of fucalean forests across the Mediterranean due to these stressors, resulting in the replacement of complex algal communities with less structurally diverse opportunistic species, a phenomenon known as “turfing” (Filbee-Dexter and Wernberg, 2018). This shift leads to a loss of biodiversity and ecosystem services, which are provided by the fucalean forests.

*Gongolaria barbata* belongs to the group of brown macroalgae, which are essential habitat-forming species in the Mediterranean, particularly in the shallow rocky shores. These algae form dense underwater forests that provide structural complexity, supporting high biodiversity and serving as nurseries and shelters for various marine organisms (Boudouresque and Lück, 1972; Molinier, 1960; Piazzi et al., 2018; Pinna et al., 2020; Thiriet et al., 2016; Vergés et al., 2009). However, over recent decades, the populations of *G. barbata* along the Istrian coast have become fragmented and are now limited to a few shallow infralittoral habitats, mediolittoral rockpools, and the coastal lagoon of Šćuza. Human activities such as coastal development, pollution, and overfishing, along with global stressors like rising sea temperatures and marine heatwaves (Verdura et al., 2021), have possibly contributed to this decline.

The research objectives of this thesis were fourfold: (1) to map the remaining populations of *G. barbata* along the western Istrian coast and assess their morphometric characteristics and biomass in order to compare the current populations with historical data, (2) to explore the possibility of developing a general model for predicting biomass based on morphometric data, (3) to examine the effects of extreme temperatures on the morphological and physiological responses of *G. barbata* populations, and (4) to test the potential for *ex situ* cultivation and the long-term survival of juvenile specimens under various environmental conditions. These objectives aimed to inform both the ecological status of the species and its potential for restoration efforts.

The fieldwork was conducted in several locations along the Istrian coast, including shallow infralittoral habitats, rockpool habitats and finally the Šćuza lagoon, which hosts one of the few remaining continuous populations of *G. barbata*. This site is particularly vulnerable due to its shallow depth, which makes it susceptible to extreme temperature fluctuations, especially during the summer months when marine heatwaves can occur. The study employed a combination of field surveys and laboratory experiments to gather comprehensive data on the algae's morphology, biomass, temperature tolerance, and growth potential under controlled conditions. The use of both historical data and recent observations allowed for a comparison of long-term trends in population dynamics.

One of the main components of the research involved mapping the current distribution of *G. barbata* along the Istrian coast. The study identified several locations where small, fragmented populations persist, primarily in shallow rockpools and the lagoon environment. These populations were then analyzed for their morphometric characteristics and biomass. Also, the data collected were compared with historical records to assess long-term changes in population size and structure. The results revealed significant variability in individual size and biomass between locations, with some sites showing clear signs of degradation over time. This degradation was linked to local stressors, such as increased sea urchin populations, which graze on the algae.

In addition to field surveys, the study included a detailed analysis of the morphometric data to develop a model for predicting biomass based on easily measurable traits. The goal was to create a non-destructive method for estimating the biomass of *G. barbata* populations, which could be used for monitoring efforts without the need to harvest entire specimens. While the development of a general biomass prediction model based on historical data was feasible, the recent data

indicated that seasonal variations in growth patterns need to be taken into account for more accurate predictions. Therefore, the model would require further refinement through year-round sampling to account for seasonal changes in algal growth.

The third component of the research focused on the species' response to temperature stress, which is particularly relevant given the increasing frequency of marine heatwaves in the Mediterranean. Laboratory experiments were conducted to test the thermotolerance of adult *G. barbata* specimens collected from the Šćuza lagoon. The algae were exposed to a range of temperatures, including those recorded during heatwaves, to assess their physiological responses and capacity for recovery. The results indicated that adult specimens of *G. barbata* are remarkably resilient to short-term exposure to high temperatures, showing significant regenerative capacity. However, the long-term impacts of repeated heatwaves, especially in combination with other stressors, remain a concern for the survival of these populations.

The final component of the study explored the potential for cultivating *G. barbata* as part of a population restoration strategy. Both *ex situ* and *in situ* cultivation experiments were conducted to assess the growth and survival of juvenile specimens under different environmental conditions. In the *ex situ* experiment, juvenile *G. barbata* were grown in controlled tanks under varying abiotic conditions, with an emphasis on light intensity. The results showed that specific abiotic factors, particularly light, had a significant impact on the growth rates of juvenile algae. The *in situ* experiments involved transplanting juvenile specimens into the lagoon environment to test their long-term survival and growth under natural conditions. These experiments demonstrated that it is possible to cultivate *G. barbata* successfully, although the growth of juveniles was influenced by the environmental conditions at the transplant site, particularly the variability in water temperature.

The findings of this thesis have important implications for the conservation and restoration of *G. barbata* populations along the Istrian coast. The development of non-destructive methods for estimating biomass also offers a valuable tool for monitoring the health of *G. barbata* populations over time, allowing for more effective management of these critical habitats. The species' resilience to temperature stress and its potential for cultivation provide promising avenues for restoration efforts. However, the success of such efforts will depend on careful selection of restoration sites, taking into account local environmental conditions and the presence of stressors such as herbivores and nutrient pollution.

In conclusion, the thesis provides a comprehensive assessment of the current state of *Gongolaria barbata* populations along the Istrian coast and offers valuable insights into the species' potential for restoration through cultivation. The research highlights the importance of long-term monitoring and the need to consider both local and global stressors in conservation planning. As climate change continues to alter marine environments, species like *G. barbata* that play a crucial role in ecosystem functioning will require targeted conservation efforts to ensure their survival. The cultivation and restoration techniques explored in this study offer a promising approach to mitigating the impacts of environmental change and preserving the biodiversity and ecosystem services provided by *G. barbata* forests. Through a combination of field surveys, laboratory experiments, and modeling, this thesis contributes significantly to our understanding of the ecology and restoration potential of one of the Mediterranean's most important habitat-forming species.

# Sadržaj

1. UVOD ..... 1

2. CILJEVI I HIPOTEZE ISTRAŽIVANJA ..... 5

3. PREGLED LITERATURE ..... 6

3.1. Vrste u Sredozemnom moru i u Jadranskom moru ..... 6

3.2. Istraživanje cistozira na zapadnoj obali Istre ..... 7

3.3. Stanje cistozira na zapadnoj obali Istre ..... 9

3.4. Vrsta *Gongolaria barbata* ..... 10

3.5. Morfometrija, biomasa i alometrija ..... 13

3.6. Utjecaj globalnog zagrijavanja i morskih toplinskih valova na cistozire ..... 16

3.7. Uzgoj cistozira i metode obnove populacija u Sredozemnom moru ..... 18

4. MATERIJALI I METODE ..... 20

4.1. Sjeverni Jadran ..... 20

4.2. Kartiranje vrste *Gongolaria barbata* duž zapadne i južne obale Istre ..... 20

4.3. Lokacije uzorkovanja ..... 22

4.3.1. Lanterna ..... 24

4.3.2. Funtana ..... 25

4.3.3. Bijela uvala ..... 26

4.3.4. Kamenjak ..... 27

4.3.5. Laguna Šćuza ..... 28

4.4. Morfometrija vrste *Gongolaria barbata* ..... 29

4.4.1. Morfometrijske karakteristike i biomasa ..... 29

4.4.2. Povijesni i recentni podaci morfometrijskih karakteristika ..... 31

4.4.3. Alometrija ..... 32

4.4.4. Analiza podataka ..... 33

4.4.4.1. Morfometrijske karakteristike i biomasa ..... 33
4.4.4.2. Povijesni i recentni podaci morfometrijskih karakteristika ..... 33
4.4.4.3. Alometrija ..... 34
4.5. Eksperiment termotolerancije ..... 36
4.5.1. Temperaturni uvjeti unutar i izvan lagune ..... 36
4.5.2. Eksperimentalni dizajn ..... 37
4.5.3. Analiza podataka ..... 40
4.6. Uzgoj ..... 41
4.6.1. Eksperimentalni dizajn ..... 41
4.6.2. Abiotički parametri ..... 43
4.6.3. Analiza podataka ..... 44
4.6.3.1. *Ex situ* rast ..... 44
4.6.3.2. *Ex situ* preživljavanje ..... 45
4.6.3.3. *In situ* rast ..... 45
4.6.3.4. Abiotički parametri ..... 46
5. REZULTATI ..... 47
5.1. Kartiranje cistozira ..... 47
5.2 Morfometrija vrste *Gongolaria barbata* ..... 50
5.1.1. Morfometrijske karakteristike i biomasa ..... 50
5.1.2. Povijesni i recentni podaci morfometrijskih karakteristika ..... 53
5.1.3. Alometrija vrste *Gongolaria barbata* ..... 57
5.1.3.1. Analiza prediktivnih modela mokre biomase na istraženim lokacijama ..... 57
5.1.3.2. Analiza općih prediktivnih modela mokre biomase ..... 66
5.1.3.3. Alometrija povijesnih podataka ..... 68
5.3. Termotolerancija ..... 70

5.3.1. Temperaturni uvjeti površinskog sloja u laguni Šćuza ..... 70
5.3.2. Eksperiment termotolerancije ..... 73
5.3.3. Vizualna opažanja ..... 74
5.4. Uzgoj ..... 76
5.4.1. Rezultati *ex situ* ranog uzgoja - rast ..... 76
5.4.2. Rezultati *ex situ* ranog uzgoja - preživljavanje ..... 76
5.4.3. Rezultati *in situ* rasta ..... 78
5.4.4. Abiotički parametri ..... 80
6. RASPRAVA ..... 84
6.1. Rasprostranjenost i morfometrija vrste *Gongolaria barbata* ..... 84
6.1.1. Morfometrijske karakteristike i biomasa ..... 85
6.1.2. Povijesni i recentni podaci morfometrijskih karakteristika ..... 89
6.1.3. Alometrija ..... 91
6.2. Termotolerancija ..... 96
6.3. Uzgoj ..... 99
7. ZAKLJUČCI ..... 105
8. LITERATURA ..... 109
9. PRILOZI ..... 136
10. POPIS KRATICA ..... 163
11. ŽIVOTOPIS ..... 165
12. INFORMACIJE O MENTORU ..... 168

# 1. UVOD

*Cystoseira sensu lato* (Fucales, Phaeophyceae), velike su smeđe alge koje predstavljaju dominantne graditelje staništa na kamenitom dnu Sredozemnog mora. Nedavna taksonomska analiza roda *Cystoseira* podjelila je vrste u rodove *Cystoseira* (*Cystoseira sensu stricto*) Agardh, *Ericaria* Stackhouse i *Gongolaria* Boehmer (Molinari-Novoa i Guiry, 2020). *Cystoseira sensu lato* vrste (dalje ih u tekstu nazivamo i cistozire) tvore guste pojaseve ili šume od zone mediolitorala pa sve do gornjeg cirkalitorala (Giaccone i Bruni, 1973), time povećavajući kompleksnost kamenitog dna. Igraju ključnu ulogu u pružanju skloništa i mrijestilišta, a također su i bogat izvor hrane mnogim morskim organizmima koji naposlijetku podržavaju brojne trofičke mreže, kao i visoku razinu bioraznolikosti (Boudouresque i Lück, 1972; Molinier, 1960; Piazzi i sur., 2018; Pinna i sur., 2020; Thiriet i sur., 2016; Vergés i sur., 2009). Zajednice cistozira su jedno od najproduktivnijih staništa Sredozemnog mora (Ballesteros, 1989), te najviši stadij kompleksnosti sredozemnih algi (Ballesteros, 1989, 1990; Clayton, 1990). Rasprostranjenost pojedinih vrsta ovisi prvenstveno o dubini i intenzitetu hidrodinamike (Ercegović, 1952). Razmnožavanje cistozira i širenje populacija često je ograničeno na usko geografsko područje (Riquet i sur., 2021) zbog velikih i teških propagula koje nakon ispuštanja, brzo tonu u neposrednoj blizini jedinke (Verdura i sur., 2018).

Brojna istraživanja zabilježila su regresiju u naseljima koje ove vrste tvore diljem Sredozemnog mora, kao rezultat djelovanja različitih negativnih čimbenika poput uništavanja staništa (Thibaut i sur., 2005), urbanog zagađenja (Munda, 1982, 1980; Perkol-Finkel i Airoldi, 2010; Pinedo i sur., 2015; Sales i sur., 2011; Soltan i sur., 2001; Thibaut i sur., 2014), brštenja od strane ježinaca i herbivornih riba (Gianguzza i sur., 2011; Guidetti i Dulčić, 2007; Hereu, 2006; Ling i sur., 2015; Sala i sur., 2012, 2011, 1998; Vergés i sur., 2014, 2009), te negativnog utjecaja oluja i globalnog zagrijavanja (Fabbrizzi i sur., 2020; Mineur i sur., 2015; Sala i sur., 2012; Smith i sur., 2023; Verdura i sur., 2021).

Iako su neki od stresora koji negativno utječu na cistozire poznati, često je razlog degradacije populacija uzajamno djelovanje raznih lokalnih i globalnih stresora. Neovisno o izvoru stresora, ishod utjecaja navedenih čimbenika ili njihove kombinacije je zamjena ekološki kompleksnih i produktivnih algi, manje kompleksnim, oportunističkim vrstama algi koje formiraju tzv. “turf”

(Filbee-Dexter i Wernberg, 2018; Perkol-Finkel i Airoldi, 2010). To je pojava globalnog karaktera (Filbee-Dexter i Wernberg, 2018), no u Sredozemnom moru je često povezana s eutrofikacijom, urbanim zagađenjem te je samim time geografski povezana s urbanim sredinama (Benedetti-Cecchi i sur., 2001). Pojava "turf"-a u nekim dijelovima Sredozemnog mora je također povezana s prekomjernim utjecajem brstioca (Franco i sur., 2015; Vergés i sur., 2014) koji "otvaraju" prostor za naseljavanje oportunističkih algi koje često učinkovitije i brže rastu od kompleksnih vrsta, poput onih koje tvore podmorske šume, te time formiraju alternativno stabilno stanje koje onemogućuje rekolonizaciju cistozira. Takve promjene, s njima povezana homogenizacija staništa, kao i gubitak usluga ekosustava (Cheminée i sur., 2013; Sala i sur., 2011) široko su zabilježeni i smatraju se pokazateljima degradacije (Orfanidis i sur., 2011).

Obzirom na važnu ulogu u ekosustavu i posebnu osjetljivost na prirodne i antropogene učinke, kao odgovor na njihovu degradaciju, cistozire su zaštićene raznim međunarodnim legislativnim alatima. Prvenstveno su zaštićene Bernskom konvencijom, koja uključuje različite vrste cistozira kao "strogo zaštićene" (Prilog I; Vijeće Europe, 1979), zatim Direktivom o staništima, gdje su zajednice vrsta cistozira smatrane "staništima od ključne važnosti" u EU (Direktiva 92/43/EEC; Prilog I, uključen u "Hridinaste grebene" – Vijeće Europe, 1992), Europskim crvenim popisom staništa, koji klasificira "ugrožene" fotofilne zajednice s algama koje formiraju šume u sredozemnom infralitoralnom i gornjem cirkalitoralnom kamenitom dnu (Dio 1, Prilog A; Europska unija, 2016), Barcelonskom konvencijom, koja uključuje većinu sredozemnih vrsta cistozira na "Popis ugroženih ili strogo ugroženih vrsta" (izmijenjeni Prilog II "Protokola o posebno zaštićenim područjima i biološkoj raznolikosti"; UNEP, 2019). Također, cistozire se koriste kao bioindikatori "dobrog ekološkog stanja" u europskim obalnim vodama prema Okvirnoj direktivi o vodama (2000/60/EC), te su uključene u različite ekološke indekse (Ballesteros i sur., 2007; Orfanidis i sur., 2011).

Jedan od glavnih odgovora znanstvene zajednice brzo rastućem trendu opadanja šuma makroalgi u Sredozemnom moru je povećanje napora pri istraživanju načina obnove degradiranih populacija cistozira (Cebrian i sur., 2021; Orlando-Bonaca i sur., 2022a, 2021), istraživanju negativnog utjecaja stresora (de Caralt i sur., 2020; Verdura i sur., 2023) te istraživanju metoda suzbijanja nekih od glavnih stresora (npr. utjecaj herbivora: Gianni i sur., 2020; Savonitto i sur., 2021).

*Gongolaria barbata* (Stackhouse) Kuntze vrsta je smeđe alge koja je nekoć bila dominantna vrsta u plitkim staništima zapadne obale Istre. Naime, već u prošlom stoljeću zabilježen je utjecaj brojnih negativnih faktora poput urbanog onečišćenja i herbivora, koji su tu vrstu doveli do funkcionalnog izumiranja (Hanel, 2002; Munda, 1980; 1993; 2000). Trenutno se na zapadnoj obali Istre pojedina, uglavnom točkasta ili fragmentirana naselja vrste *G. barbata,* pronalaze na tek nekoliko lokacija, pozicionirana u plitkom infralitoralu i u mediolitoralnim lokvicama te pod prijetnjom negativnog djelovanja herbivora. Uz „degradirana“ naselja, jedina kontinuirana i zdrava populacija nalazi se u plitkom infralitoralu lagune Šćuza (Iveša i sur., 2022).

U prvom djelu ovog doktorskog rada izvršeno je kartiranje plitkih staništa koje vrsta *G. barbata* nastanjuje uz zapadnu i južnu obalu Istre, te je procijenjena njezina rasprostranjenost i relativna brojnost. Nadalje, na odabranim lokacijama izmjerene su morfometrijske karakteristike i biomasa jedinki *G. barbata* u svrhu usporedbe i karakterizacije stanja preostalih populacija u pojedinim staništima (plitki infralitoral, lokvice i laguna). Dio recentnih podataka se zatim iskoristio za usporedbu s povijesnim podacima, u svrhu određivanja dugoročnih promjena populacija vrste *G. barbata*. Recentni i povijesni podaci su zatim iskorišteni za izradu općih modela predikcije biomase na temelju morfometrijskih karakteristika. Ovo istraživanje pruža uvid u stanje preostalih populacija vrste *G. barbata* u plitkim staništima te postavlja temelj za buduće praćenje stanja. Nadalje, nudi informacije o dugoročnim promjenama u morfometrijskim karakteristikama ovih populacija i procjenjuje potencijal razvoja općih prediktivnih modela za nedestruktivnu procjenu biomase.

U obalnoj laguni Šćuza nalazi se jedno od posljednjih utočišta vrste *G. barbata* u istarskom priobalju. Upravo zbog male dubine lagune, postoji direktna prijetnja populaciji *G. barbata* od negativnog utjecaja ekstremnih klimatskih događaja, tj. povišene ljetne temperature. U drugom djelu doktorskog rada, simulirali smo morske toplinske valove različitog intenziteta kako bismo definirali učinak ekstremnih temperatura na jedinke *G. barbata*, uz istraživanje otpornosti i potencijala za oporavak ove vrste. Pratili smo temperature u laguni Šćuza, i na temelju ljetnih ekstrema proveli *ex situ* eksperiment termotolerancije, koji se sastojao od faze stresa i faze oporavka. Istražili smo učestalost, trajanje i intenzitet morskih toplinskih valova (MTV) na južnoj obali Istre kako bismo postavili lagunarne uvjete u širi okolišni kontekst i uspostavili realne uvjete za testiranje termalnih performansi. Ovaj eksperiment proveden je kako bismo istražili: (1) imaju

li zabilježene ekstremne temperature u laguni Šćuza štetne učinke na morfološke i fiziološke karakteristike vrste *G. barbata*; i (2) jesu li talusi vrste *G. barbata* sposobni za regeneraciju nakon ponovnog izlaganja povoljnim temperaturnim uvjetima. Ove informacije će pridonijeti općem znanju o ekologiji vrste koja formira morsku šumu u izazovnim temperaturnim uvjetima, pružajući uvid u buduće akcije očuvanja i obnove ugroženih vrsta koje formiraju staništa u Jadranskom moru.

U trećem djelu doktorskog rada, implementirali smo metodu uzgoja, koja se sastojala od tri ključne faze: početne faze *ex situ* uzgoja, faze aklimatizacije prije presađivanja, te faze presađivanja na izvornu donorsku lokaciju. Glavni cilj bio nam je istražiti rani uzgoj vrste *G. barbata* i procijeniti utjecaj abiotičkih čimbenika, poput svjetlosti i temperature, na rast i preživljavanje u ranim stadijima razvoja mladih jedinki. Uz to, bavili smo se izazovima vezanim uz kratkoročno pohranjivanje rane kulture vrste *G. barbata* prije faze presađivanja. Presađivanje juvenilnih jedinki *in situ* strateški je provedeno tijekom najtoplijeg razdoblja godine, što je predstavljalo posebno izazovne temperaturne uvjete za mlade, osjetljive jedinke. Istražili smo učinke ovih ekstremnih uvjeta na rast ranih stadija vrste *G. barbata*, kao i utjecaj smanjenja temperature tijekom jesensko-zimskih mjeseci. Dodatno, usporedno s praćenjem rasta, pratili smo i stopu sedimentacije i dinamiku hranjivih tvari kako bismo dobili cjelovitu sliku o njihovom utjecaju na juvenilne jedinke. Ovo istraživanje prvenstveno naglašava važnost odabira odgovarajućih uvjeta rasta u ranoj fazi *ex situ* uzgoja, ali također ističe kako izbor specifičnih uvjeta dugoročno utječe na rast i razvoj makroalgi. Nadalje, ključno je praćenje više abiotičkih čimbenika na terenu radi utvrđivanja karakteristika potencijalnih odredišnih i/ili donorskih lokacija. Ovi podaci mogu poslužiti kao "markeri" za obnovu populacija, pomoći pri odabiru prikladnih lokacija za obnovu, te u konačnici, doprinijeti uspješnoj obnovi.

# 2. CILJEVI I HIPOTEZE ISTRAŽIVANJA

Ciljevi istraživanja:

1) Opisati morfometriju i biomasu vrste *Gongolaria barbata*, usporediti različite populacije plitkih staništa, lokvica i lagune te usporediti s povijesnim podacima.

2) Ustanoviti potencijal izrade modela predikcije biomase vrste *Gongolaria barbata* na temelju morfometrijskih podataka koristeći povijesne i recentno prikupljene podatke.

3) Ispitati utjecaj ekstremnih temperatura na populacije vrste *Gongolaria barbata.*

4) Ispitati potencijal *ex situ* uzgoja vrste *Gongolaria barbata.*

Glavne hipoteze istraživanja:

1) Nema razlike u morfometriji i biomasi recentno kao i povijesno prikupljenih podataka za populacije vrste *Gongolaria barbata* u plitkim staništima, lokvicama i laguni.

2) Moguća je izrada općeg modela predikcije biomase za vrstu *Gongolaria barbata* temeljem morfometrijskih podataka koristeći povijesne i recentno prikupljene podatke.

3) Ekstremne temperature u *ex situ* uvjetima ne utječu značajno na fiziologiju i morfometriju jedinki vrste *Gongolaria barbata.*

4) *Ex situ* uzgoj vrste *Gongolaria barbata* je moguć.

# 3. PREGLED LITERATURE

## 3.1. Vrste u Sredozemnom moru i u Jadranskom moru

Neki autori smatraju da je identifikacija vrsta iz roda *Cystoseira s.l.* samo na temelju morfoloških karakteristika nedovoljna zbog iznimne morfološke plastičnosti skupine (Orellana i sur., 2019). Draisma i sur. (2010) dokazali su polifiliju europskih vrsta roda *Cystoseira*, te na temelju toga zaključili da je potrebna podjela na tri roda. Nadalje, Orellana i sur. (2019) na temelju analize morfologije i DNK vrše podjelu na *Cystoseira* C. Agardh, 1820, *Carpodesmia* Greville, 1830 i *Treptacantha* Kützing, 1843. Zaključno, Molinari-Novoa i Guiry (2020) revidirali su rodove koje su predložili Orellana i sur. (2019), zaključujući da *Gongolaria* Boehmer, 1760 i *Ericaria* Stackhouse, 1809 imaju prioritet nad rodovima *Treptacantha* Kützing i *Carpodesmia* Greville. Prema tome, *Cystoseira*, *Gongolaria* i *Ericaria* ispravna su imena za tri klada (Molinari-Novoa i Guiry, 2020).

Unutar roda *Cystoseira* Agardh, taksonomski je trenutno prihvaćeno 20 imena vrsta, jedna podvrsta, dva varijeteta i devet formi. U sinonimiji, postoji 105 imena vrsta, 16 imena podvrsta, 36 imena varijeteta i 21 ime forme. Dodatno, uključeno je 15 imena s nejasnim statusom, kao i 62 imena koja do sada nisu provjerena. Što se tiče roda *Gongolaria* Boehmer, taksonomski je trenutno prihvaćeno 15 imena vrsta, dva varijeteta i pet formi. U sinonimiji, postoji šest imena vrsta. Kod roda *Ericaria* Stackhouse, taksonomski je trenutno prihvaćeno 14 imena vrsta i jedan varijetet. U sinonimiji, postoje dva imena vrsta i jedno ime forme. Ako se gleda ukupan broj vrsta smeđih algi iz skupine cistozira koje tvore guste šume na kamenitom dnu Sredozemnog mora, službeno je taksonomski prihvaćeno 49 vrsta (Guiry i Guiry, 2024).

Od 49 vrsta koje pronalazimo u Sredozemnom moru, njih deset se nalazi na zapadnoj obali Istre (Tablica 1, Iveša i sur., 2016). Nekoliko je nižih taksonomskih jedinica od navedenih vrsta koje također pronalazimo na zapadnoj obali Istre (Tablica 1).

Tablica 1. Taksoni cistozira na istarskoj obali.

| **Taksoni** |
|---|
| *Cystoseira compressa* (Esper) Gerloff & Nizamuddin |
| *Cystoseira compressa* subsp. *rosetta* (Ercegovic) Cormaci, Furnari, Giaccone, Scammacca & Serio |
| *Cystoseira compressa* f. *plana* (Ercegovic) Cormaci, Furnari, Giaccone, Scammanca & Serio* |
| *Cystoseira foeniculacea* (Linnaeus) Greville |
| *Cystoseira foeniculacea* f. *latiramosa* (Ercegovic) Gómez-Garreta, Barceló, Ribera & Lluch |
| *Cystoseira foeniculacea* f. *tenuiramosa* (Ercegović) Gómez Garreta, Barceló, Ribera & Lluch |
| *Cystoseira humilis* Schousboe *ex* Kützing |
| *Cystoseira pustulata* (Ercegovic) Neiva & Serrão |
| *Gongolaria montagnei* (J.Agardh) Kuntze |
| *Gongolaria barbata* (Stackhouse) Kuntze |
| *Ericaria corniculata* (Turner) Neiva & Serrão |
| *Ericaria crinita* (Duby) Molinari & Guiry |
| *Ericaria amentacea* (C.Agardh) Molinari & Guiry |
| *Ericaria dubia* (Valiante) Neiva & Serrão* |

*Rijetke vrste/taksoni

## 3.2. Istraživanje cistozira na zapadnoj obali Istre

Najznačajnije informacije vezane uz rasprostranjenost navedenih vrsta duž istarske obale iznijeli su sljedeći autori: Ercegović (1952), Munda (2000) te Iveša i sur. (2016). Bitno je spomenuti i rovinjskog „sakupljača i preparatora morskih organizama“ Antonija Zaratina, koji je krajem 19. stoljeća izradio desetak herbarija, tako doprinijevši poznavanju rasprostranjenosti pojedinih vrsta cistozira duž istarske obale. Ercegović (1952) u detalje opisuje ekologiju, morfologiju i vegetacijski ciklus pojedinih vrsta. Fokus njegovog istraživanja bile su cistozire na području čitavog Jadrana, zbog čega nije uspio detaljno obraditi cijelu istarsku obalu, već je cistozire uz Istru uzorkovao na svega nekoliko lokacija. Unatoč tome, njegovi podaci su vrlo značajni pri određivanju rasprostranjenosti algi u pedesetim godinama prošlog stoljeća, pogotovo u kontekstu cijelog Jadrana. Munda (2000) uspoređuje svoje podatke o prisutnosti/odsutnosti različitih vrsta crvenih, smeđih i zelenih algi iz rovinjskog priobalja (razdoblja 1967. - 1970. i 1978. - 1983.) s podacima iz dnevnika algologa Paula Kuckuck-a iz 19. stoljeća. U toj usporedbi su obuhvaćene i cistozire. Nadalje, Iveša i sur. (2016) su detaljno obradili rasprostranjenost i abundanciju cistozira duž zapadne obale Istre u razdoblju od 2001. do 2013. godine, uzevši u obzir i dubinsku raspodjelu vrsta, kao i utjecaj ježinaca i eutrofikacije na cistozire.

Prema Battelli i Alberti (2003), Antonio Zaratin je cistozire pronašao na nekoliko postaja duž istarske obale: “ispod topova”, “Molo Sanita” i Plava laguna (Molindrio) kod Poreča, Vrsar, Monte i otok Sveta Katarina kod Rovinja, Pula, te Rabac. U svojim herbarskim primjercima spominje vrste: *Cystoseira compressa, C. aectocarpa* (napomena: nisu pronađeni literaturni navodi za ovu vrstu, stoga bi bilo poželjno provjeriti herbarski primjerak), *Gongolaria barbata, Cystoseira corniculata, Ericaria amentacea* (napomena: *Cystoseira ericoides* (Linnaeus) Agardh, danas pod nazivom *Ericaria selaginoides* (Linnaeus) Molinari i Guiry, međutim poznato je da se navedena vrsta zasigurno ne nalazi u istarskom priobalju te se Zaratinijev primjerak odnosi na vrstu *E. amentacea*), *G. barbata, Cystoseira arbuscola* (napomena: ne postoje literaturni navodi, stoga bi bilo poželjno provjeriti herbarski primjerak) i *Gongolaria usneoides* (Linnaeus) Molinari i Guiry (napomena: niti jedan istraživač nakon njega ne spominje navedenu vrstu pronađenu u istarskom priobalju, stoga bi također bilo poželjno proučiti herbarski primjerak). Potrebno je napomenuti kako je Antonio Zaratin uglavnom sakupljao naplavljene primjerke i one dostupne s kopna. Stoga nije ciljano sakupljao vrste s veće dubine, ali su one mogle biti pronađene uz obalu kao naplavine.

Munda (2000) u svojoj usporedbi povijesnih podataka zaključuje kako kroz vrijeme dolazi do značajnog opadanja broja vrsta iz svih skupina makroalgi, Rhodophyta, Heterokontophyta i Chlorophyta. Napominje kako je krajem 19. stoljeća sveukupno zabilježeno 280 svojti, dok je u razdoblju 1967. - 1970. uočen pad na 213 svojti, te u razdoblju 1978. - 1983. pad na 128 svojti. Dakle u nešto manje od 100 godina, 152 svojte algi su „nestale“ ili nisu pronađene u rovinjskom priobalju. Navodi i kako Kuckuck za više postaja u rovinjskom priobalju bilježi sveukupno sedam vrsta cistozira: *G. barbata, C. compressa, C. foeniculacea, G. montagnei, E. corniculata, E. crinita* i *E. amentacea*.

Munda (2000) je u razdoblju 1967.-1970. pronašla sve vrste cistozira koje je zabilježio i Paul Kuckuck, a po prvi je puta zabilježila i vrstu *E. dubia* na nekoliko postaja u priobalju Rovinja. Od tada navedena vrsta nije pronađena u istarskom priobalju, no postoji pohranjeni primjerak u Centru za istraživanje mora u Rovinju. U drugom razdoblju istraživanja 1978.-1983., Munda u priobalju Rovinja nije pronašla sljedeće vrste: *G. barbata, C. foeniculacea, E. crinita* i *E. dubia*.

Polovicom prošlog stoljeća, s ciljem doprinosa istraživanju cistozira u čitavom Jadranu, Ercegović (1952) uzorkuje cistozire na nekoliko postaja u istarskom priobalju: Rt Opasna i otok Porer kod Premanture, otoci Sveti Ivan od Pelaga, Sveti Andrija kod Rovinja i Sveta Katarina kod Rovinja,

otočić Lunga i svjetionik Marmi kod Vrsara. Na Rtu Opasna zabilježio je sljedeće vrste: *E. corniculata*, *G. montagnei* i *C. foeniculacea*, a kod otoka Porer: *E. amentacea*, *E. crinita* i *C. foeniculacea*. Kod otoka Sveti Ivan od Pelaga zabilježio je vrste: *E. corniculata*, *E. amentacea* i *E. crinita*, Sveti Andrija: *E. amentacea*, *E. crinita* i *C. compressa* te kod otoka Sveta Katarina: *E. corniculata*, *E. amentacea*, *E. crinita*, *G. barbata* i *C. foeniculacea*. Kod otočića Lunga zabilježio je vrste: *E. amentacea*, *E. crinita* i *C. compressa*, dok kod svjetionika Marmi: *E. corniculata* i *C. foeniculacea*.

## 3.3. Stanje cistozira na zapadnoj obali Istre

Iveša i sur. (2016), Devescovi (2015), Iveša i Devescovi (2014) te Zavodnik i sur. (2002) donose najznačajnije i najdetaljnije informacije o cistozirama istarskog priobalja u razdoblju od 2000-ih do 2013. Njihova istraživanja pružaju informacije o dubinskoj i geografskoj distribuciji, biomasi, te kvalitativan kronološki pregled dinamike degradacije i obnove populacija cistozira u odnosu na povijesne razine eutrofikacije i prisutnost ježinaca. Opisuju prostornu i dubinsku rasprostranjenost pojedinih vrsta, ali i biomasu kao kvantitativnu karakteristiku koja omogućuje usporedbu količine i sastava pojedinih vrsta na različitim lokacijama. Istražene su cistozire u priobalju Umaga, Novigrada, Vrsara i Rovinja te su zabilježene sljedeće vrste: *Ericaria amentacea*, *Gongolaria barbata*, *Cystoseira compressa*, *Cystoseira humilis*, *Ericaria corniculata*, *Ericaria crinita*, *Cystoseira foeniculacea* i *Gongolaria montagnei*. Trenutno je poznato (neobjavljeni podaci) da se uz istarsko priobalje zasigurno nalaze sve svojte objavljene u radu Iveša i sur. (2016), uz svojte *C. foeniculacea* f. *latiramosa* i *C. compressa* f. *plana*, čiji su rijetki talusi bili zabilježeni 2009. godine, dok vrsta *Ericaria dubia* do današnjeg dana nije zabilježena u istarskom priobalju.

Pregledom i uzorkovanjem u infralitoralu, doneseni su dokazi i zaključci o postojanju gustih šuma cistozira u priobalju zapadne obale Istre (Iveša i sur., 2016). Ovisno o konfiguraciji morskog dna, veličina naselja varirala je od nekoliko stotina metara do jednog kilometra, te su uglavnom tvorila miješane šume s varijacijama koje su ovisile o prostornoj skali i dubinskom gradijentu (Devescovi, 2015). Pronađene su sve očekivane vrste u rasponima dubine 0,5 - 2 m, 5 - 7 m i 10 - 12 m (Iveša i sur., 2016; Iveša i Devescovi, 2014). U rasponu dubine od 0,5 do 2 m, najzastupljenije vrste su bile *G. barbata*, *C. compressa* i *E. crinita*, dok su *C. foeniculacea* i *C. c. pustulata* pokazivale niže vrijednosti abundancije i biomase. Vrste *E. amentacea* i *G. montagnei* nisu pronađene unutar tog dubinskog raspona. Sličan trend uočen je na svim lokacijama duž istarske obale za navedeni raspon

dubina. U rasponu dubine od 5 do 7 m, najzastupljenije vrste su bile *G. barbata*, *C. compressa*, *E. corniculata*, *C. foeniculacea* i *G. montagnei* ovisno o lokaciji uzorkovanja. U rasponu dubine od 10 do 12 m, dominirale su vrste *E. corniculata*, *C. foeniculacea* i *G. montagnei*, dok su vrste *G. barbata* i *C. c. pustulata* pokazivale niže vrijednosti biomase (bile su prateće vrste).

## 3.4. Vrsta *Gongolaria barbata*

Vrsta *Gongolaria barbata* je široko rasprostranjena diljem Sredozemnog mora, uključujući Jadransko more, Crno more i Azovsko more (Cormaci i sur., 2012; Ercegović, 1952; Fabbrizzi i sur., 2020; Gómez Garreta i sur., 2001; Munda, 2000; Ribera i sur., 1992; Sadogurska, 2021). Pad brojnosti vrste je snažno povezan s ljudskim utjecajem (Blanfuné i sur., 2019; Mariani i sur., 2019; Thibaut i sur., 2015, 2005). U sjevernom Jadranu vrsta *G. barbata* tvori guste šume na manjim dubinama od 0,5 do 3 m, naseljavajući staništa s umjerenim razinama sedimentacije (Iveša i sur., 2016; Iveša i Devescovi, 2014). Nadalje, ova vrsta bila je česta duž istarske obale, gdje danas obično naseljava zaštićena staništa poput uvala, lokvica i laguna (Ercegović, 1952; Munda, 2000).

Kod vrste *G. barbata* morfološki razlikujemo tri dijela: bazalnu pločicu, stabljiku i grane (Slika 1). Ostali dijelovi važni za morfološku diferencijaciju razvijaju se iz navedenih glavnih dijelova. Bazalna pločica je jednostavna i diskoidalna. Iz jednostavne pločice raste jedan uspravan kauloid, na čijem se gornjem kraju nalazi gladak vršak koji je najčešće izdignut iznad insercije primarnih grana (Ercegović, 1952). Maksimalna visina talusa je do 1 m, dok pojedini kauloidi dosežu visinu do 50 cm, a promjer kauloida 3-5 mm (Gómez Garreta i sur., 2001). Primarne grane u proljeće dosežu 40-70 cm u duljini i nose sekundarne grane koje mogu biti valjkasto-lističaste, s prisutnim aerocistama (do 5-6 u lancu). Tijekom kasnog ljeta, broj aerocista znatno je smanjen. Primarne grane često otpadaju, ostavljajući do 1 cm duge ožiljke iz kojih nerijetko izlaze manje adventivne grane. Receptakuli su terminalno smješteni i najčešće cilindrično kopljastog oblika, hrapavi ili glatki, a njihova veličina varira od 5 do 20 mm (Cormaci i sur., 2012). Prema Ercegoviću (1952) vegetativno razdoblje vrste započinje u drugoj polovici jeseni, obično početkom do sredine studenog. Ovo razdoblje obilježava pojava kratkih primarnih i sekundarnih grana, koje razvijaju kompaktne receptakule i aerociste. Primarne grane doživljavaju značajan rast tijekom zime i prvog dijela proljeća, dosežući maksimalnu duljinu i gustoću svih strukturnih komponenti tijekom travnja ili početkom svibnja. Alga se ponekad tijekom ljeta nalazi u stanju mirovanja (Marzocchi i sur., 2003). U zaklonjenim područjima (poput laguna i zatvorenih zaljeva), alga ne pokazuje intenzivan

rast, a od lipnja do kraja rujna stabla su gola i prekrivena epibiontima. Na izloženijim staništima alga ne prekida vegetacijsko razdoblje, ali je ono tijekom ljeta usporeno (Ercegović, 1952; Falace i sur., 2024).

Pet taksona je trenutno dobro opisano u literaturi: *Gongolaria barbata*, *Gongolaria barbata* f. *aurantia* (Kützing) Falace, Alongi i Kaleb, *Gongolaria barbata* f. *hoppei* (C.Agardh) Falace, Alongi i Kaleb, *Gongolaria barbata* f. *turneri* Falace, Alongi i Kaleb i *Gongolaria barbata* f. *repens* (A.D.Zinova i Kalugina) Sadogurska. Naime, uglavnom je *G. barbata* epilitska vrsta, međutim ovisno o okolišnim karakteristikama, pronalazi se i u pleustofitskom obliku (Battelli i Catra, 2021; Falace i sur., 2024; Ramdani i sur., 2021; Sadogurska, 2021), te u bento-pleustofitskom obliku (Iveša i sur., 2022; Lenzi i sur., 2024).

Vrsta *G. barbata* se smatra euritermnom vrstom koja podnosi temperature u rasponu od 8 do 23 °C, s optimalnim rastom i razvojem talusa na temperaturi između 8 i 16–17 °C (Ercegović, 1952), ali čini se da preživljava i podnosi temperature daleko iznad navedenog limita, od ispod nule do >30 °C, barem kratkoročno (Iveša i sur., 2022; Orfanidis, 1991). Pokazuje visoku morfološku varijabilnost, ciklički ovisnu o godišnjem dobu i geografski o izloženosti valovima i drugim okolišnim faktorima, poput intenziteta svjetla i temperature (Ercegović, 1952; Falace i Bressan, 2006; Sadogurska, 2021). Konkretno, veličina receptakula te oblik i veličina aerocista pokazuju najveću plastičnost (Sadogurska, 2021). Plodnost vrste primijećena je prvenstveno tijekom proljeća, od ožujka do lipnja, te rane jeseni (Cebrian i sur., 2021).

Na granama višeg stupnja nalaze se receptakuli (grane koje nose rasplodne strukture; Slika 2A, B). Na receptakulima se nalaze rasplodne komorice (konceptakuli; Slika 2C) unutar kojih se razvijaju anteridiji i oogoniji (cistozire su jednodomne vrste; Slika 2C, D) (Guern i Guern, 1962). Vrsta se razmnožava oogamijom, pomoću velike nepomične jajne stanice i biflagelatnih spermija (Ercegović, 1952). Mejoza se odvija tijekom formiranja gameta (n), dok se zigota (2n) razvija u jedinu diploidnu vegetativnu fazu životnog ciklusa (Gómez Garreta i sur., 2001). Oplodnja je vanjska, a tvori veliku zigotu (~70–130 μm) koja brzo tone na kamenito dno, gdje se pričvrsti tijekom prvih 12-72 sata (Falace i sur., 2018; Orfila, 2014; Verdura i sur., 2018).

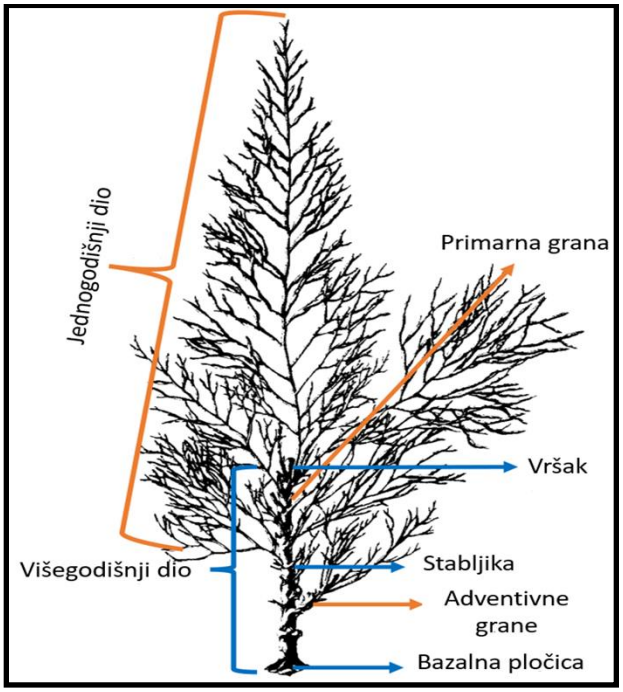


Slika 1. Građa talusa vrste *Gongolaria barbata*. Plavom bojom su označeni višegodišnji dijelovi alge, dok su narančastom bojom označeni jednogodišnji dijelovi alge. Shematski prikaz vrste *G. barbata* iz Ercegović (1952).

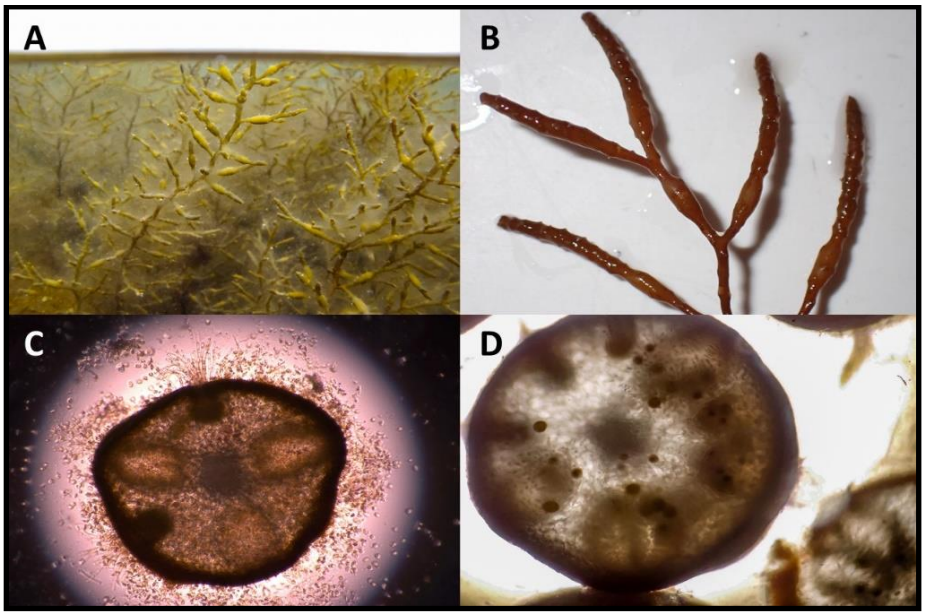


Slika 2. Primarne grane koje nose receptakule (A), pojedini receptakuli (B), nezreli konceptakuli (C) i zreli konceptakuli s anteridijima i oogonijima (D).

## 3.5. Morfometrija, biomasa i alometrija

Iako je potreba za detekcijom stresora koji uzrokuju regresiju populacija morskih šuma velika (Gann i sur., 2019), znanje o stanju populacija je ograničeno na svega nekoliko vrsta, te usku prostornu i vremensku skalu istraživanja (Krumhansl i sur., 2016). Studije koje uspješno obuhvaćaju dugoročne promjene u populacijama makroalgi u Sredozemnom moru su rijetke (Verdura i sur., 2023), a većina njih se temelji na usporedbi povijesnih podataka prikupljenih nestandardiziranim metodama, te su takvi podaci često kvalitativne prirode (npr. Munda, 2000; Tamburello i sur., 2022). Regresija morskih šuma u Sredozemnom moru, izaziva značajnu zabrinutost zbog mogućih negativnih utjecaja na bioraznolikost i funkcije ekosustava, naglašavajući hitnu potrebu za učinkovitim mjerama očuvanja i obnove populacija, te za razvojem učinkovitih i standardiziranih protokola za dugoročni monitoring populacija (Verdura i sur., 2023).

U mnogim istraživanjima koja se bave cistozirama, morfometrijska mjerenja (Verdura i sur., 2021) i mjerenja biomase (Iveša i sur., 2016) predstavljaju temelj za praćenje stanja populacija, i promjena koje se dešavaju uslijed djelovanja negativnih antropogenih i/ili prirodnih stresora. Osim što se morfometrijske karakteristike i biomasa koriste za procjenu stanja populacija cistozira na terenu, također predstavljaju ključne parametre u praćenju vrsta tijekom različitih eksperimentalnih tretmana u laboratoriju (Bilajac i sur., 2024; de Caralt i sur., 2020; Iveša i sur., 2021; Verdura i sur., 2021), kojima se često učinkovito detektiraju promjene uzrokovane različitim stresorima.

Osim procjene stanja populacija na određenom području, morfometrijske karakteristike i biomasa pružaju uvid i u: sezonalnu dinamiku populacije (Falace i Bressan, 2006), varijabilnost pojedinih parametara između populacija (što je uvjetovano različitim okolišnim uvjetima) na različitim geografskim skalama (Ercegović, 1952; Falace i sur., 2024; Orlando-Bonaca i sur., 2022a; Sadogurska, 2021), te intraspecijske varijacije (Falace i sur., 2024).

Procjena stanja cistozira na hridinastom morskom dnu, može se provesti korištenjem kvalitativnih i kvantitativnih metoda uzorkovanja (Bianchi i sur., 2004). Kvalitativne metode koriste se prvenstveno za procjenu stanja naselja, identifikaciju vrsta i opis strukture zajednice, bez potrebe za mjerenjem abundancije, morfometrijskih karakteristika ili procjene biomase. Manje su invazivne i koriste se u preliminarnim istraživanjima ili kada je potrebna brza procjena ekosustava. Kvantitativna procjena morskih šuma češće pruža detaljnije informacije o proučavanom organizmu; glavni parametri koji se proučavaju uključuju biomasu, biovolumen, brojnost jedinki,

gustoću, frekvenciju pojavljivanja, pokrovnost i morfometrijske karakteristike. Osim navedenih metoda, postoje i semi-kvantitativne metode koje su značajne za donošenje općih zaključaka o nekom naselju ili zajednici, što olakšava rad na terenu, osobito kada se istraživanje provodi na širem geografskom području (Braun-Blanquet, 1979).

Metode uzorkovanja cistozira se dijele na destruktivne i nedestruktivne (Bianchi i sur., 2004), a svaka od njih ima svoje prednosti i nedostatke. Međutim, kombinacija ovih dviju metoda može rezultirati značajnim i sveobuhvatnim rezultatima. Destruktivna metoda omogućava precizniju taksonomsku determinaciju i objektivnu procjenu pojedinih parametara, no njezini nedostaci uključuju produljeno vrijeme boravka na terenu, visoke troškove izvedbe, potrebu za profesionalcima, ograničenost na malu površinu uzorkovanja, kao i negativan utjecaj na ekosustav. S druge strane, nedestruktivna metoda obuhvaća pregled video zapisom i vizualni cenzus. Prednosti pregleda video zapisom uključuju objektivnu procjenu, ponovljivost metode, mogućnost automatizacije, kraći boravak pod vodom, istraživanje šireg područja i minimalan utjecaj na ekosustav. Nedostaci su niža preciznost i poteškoće u interpretaciji fotografije *a posteriori*. Prednosti vizualnog cenzusa su nizak trošak, trenutni rezultati, ponovljivost, i nizak utjecaj na ekosustav, ali nedostaci su rizik subjektivnosti i često produljeni boravak pod vodom.

Za prikupljanje detaljnih informacija o biomasi morskih algi, potrebno je destruktivno uzorkovati jedinke te navedene parametre precizno izmjeriti u laboratoriju. Alternativu predstavlja nedestruktivno uzorkovanje, pri kojem se parametri koji ne zahtijevaju fizičko prikupljanje uzoraka mjere direktno na jedinkama na terenu. U ekološkim istraživanjima, često se koristi parametar biomasa, dok su rijetka istraživanja koja uključuju nedestruktivne mjere (parametre), poput *in situ* mjerenja duljine jedinki (Mulas i sur., 2022a). Nadalje, metoda videozapisa predstavlja veliki potencijal za nedestruktivno mjerenje i procjenu određenih parametara na terenu (Overrein i sur., 2024).

U nekim slučajevima, biomasu cistozira je moguće procijeniti na temelju morfometrijskih karakteristika prikupljenih direktno na terenu, što zapravo predstavlja prednost nad destruktivnom metodom upravo iz razloga što jedinke ili populacija na morskom dnu ostaju netaknuti i neoštećeni, dok se istovremeno iz populacije dobivaju sve nužne informacije, potrebne za procjenu stanja (Orfanidis i sur., 2017).

U posljednje vrijeme, brojna istraživanja se odvijaju na polju biometrije i alometrijskih odnosa, u svrhu procjene biomase makroalgi (Aller-Rojas i sur., 2020; Gevaert i sur., 2008; Scrosati i sur., 2020; Stagnol i sur., 2016; Starko i Martone, 2016; Wickham i sur., 2019). Tako se npr. u istraživanjima koriste morfometrijske karakteristike za procjenu mokre biomase (Campbell i Starko, 2021), zatim za procjenu suhe biomase (Scrosati i sur., 2020) ili pak za procjenu sadržaja ugljika ili dušika u morskim makroalgama (Gevaert i sur., 2008, 2001). Također, radi se i na izradi odnosa mokre biomase i suhe biomase, kao i njihovog odnosa sa žarenom suhom biomasom (Mulas i sur., 2022b).

Istraživanje odnosa biomase i morfometrijskih karakteristika može rezultirati praktičnim metodama koje će se naposlijetku koristiti u svrhu nedestruktivne procjene biomase u kontekstu ekoloških istraživanja ili pak u kontekstu procjene prinosa u marikulturi (Campbell i Starko, 2021; Overrein i sur., 2024; Stagnol i sur., 2016). Navedeno značajno doprinosi smanjenju destruktivnosti i invazivnosti metoda na funkcije morskih ekosustava (Tait i Schiel, 2011) te predstavlja temelj za procjenu prinosa ekosustava, zaliha ugljika u kontekstu protokola za prilagodbu klimatskim promjenama (Nellemann i sur., 2009), kao i za kvantifikaciju usluga ekosustava.

U Jadranskom moru, očekuje se porast utjecaja raznih stresora na cistozire, poput gubitka staništa, promjene u kvaliteti mora, utjecaja nativnih i invazivnih herbivora, te sve veći utjecaj klimatskih promjena (Verdura i sur., 2023). Upravo iz tog razloga, kao i zbog regresije cistozira diljem Sredozemnog mora, poželjno bi bilo razviti nedestruktivnu ili manje destruktivnu metodu koja bi omogućila brzu i preciznu procjenu biomase algi, što je ključno za praćenje stanja specifičnih populacija (Iveša i sur., 2016) ili za određivanje potencijala za sekvestraciju ugljika. Naime, cistozire mogu predstavljati bitne donore ugljika susjednim sustavima, pri čemu se taj ugljik sekvestrira u sedimentima i dubokim vodama tijekom dugog vremenskog razdoblja (Moreda i sur., 2024).

Istraživanja alometrijskih odnosa biomase i morfometrijskih karakteristika cistozira su rijetka, sa svega nekoliko istraživanja koja obuhvaćaju tek nekolicinu vrsta na uskom geografskom području (Mulas i sur., 2022b; Orfanidis i sur., 2017).

## 3.6. Utjecaj globalnog zagrijavanja i morskih toplinskih valova na cistozire

Uz rastući trend zagrijavanja diljem globalnog priobalnog oceana (Johnson i Lyman, 2020; Lima i Wethey, 2012), učestalost i intenzitet morskih toplinskih valova (MTV) na uzlaznoj su putanji (Frölicher i sur., 2018; Oliver, 2019; Oliver i sur., 2021) kao posljedica antropogenih klimatskih promjena. Granice termotolerancije organizama sve se češće prekoračuju i to sa sve većim intenzitetom (Frölicher i sur., 2018; Oliver i sur., 2018; Sen Gupta i sur., 2020), pri čemu MTV-ovi imaju različite utjecaje na razmnožavanje vrsta, pomicanje areala i uspostavu stranih vrsta (Smith i sur., 2023). Štoviše, povećana učestalost MTV-ova povezana je s naglim porastom masovnih pojava smrtnosti organizama diljem svijeta (Hanley i sur., 2023), pri čemu je posebno pogođen ekosustav Sredozemnog mora tijekom posljednja dva desetljeća (Estaque i sur., 2023; Garrabou i sur., 2022). Najdramatičnije pojave u kontekstu geografskog opsega i broja pogođenih vrsta dogodili su se 1999. i 2003. godine duž sjeverozapadnog dijela Sredozemnog mora (Cerrano i sur., 2000; Garrabou i sur., 2009; Perez i sur., 2000). Ove dvije pojave utjecale su na više od 40 vrsta iz raznih taksonomskih skupina duž tisuće kilometara obale. Nadalje, tijekom razdoblja od 2015. do 2019. godine, ovaj bazen je doživio dodatne masovne pojave smrtnosti koje su zahvatile tisuće kilometara obale od površine do 45 m dubine i obuhvatile 50 taksona iz osam koljena (Garrabou i sur., 2022).

Klimatski ekstremi i promjene u globalnom vodenom ciklusu od ključne su važnosti za najsjeverniji, najplići i najproduktivniji dio Sredozemnog mora, sjeverni Jadran (Bianchi i Morri, 2000). Temperature trenutno padaju ispod 11 °C zimi (Bianchi, 2007) i približavaju se 30 °C ljeti. Zbog složene cirkulacije (Vilibić i sur., 2023), sjeverni Jadran prolazi kroz razdoblja eutrofikacije (Degobbis i sur., 2000; Đakovac i sur., 2012), pojave proizvodnje sluzavih nakupina poznatih pod nazivom „mucilagine“ (Giani i sur., 2005), pojave hipoksije i anoksije (Đakovac i sur., 2015) te štetnih cvjetanja algi (Facca i sur., 2014). Uz ove stresore, invazije alohtonih vrsta (Iveša i sur., 2015; Shiganova i Malej, 2009) i „eksplozije“ ježinaca (Iveša i sur., 2016) predstavljaju poremećaje koji potencijalno ugrožavaju bioraznolikost, uključujući ekološki važne šume makroalgi (Gljušćić i sur., 2023; Iveša i sur., 2022, 2021, 2016). Sredozemno more se općenito smatra relevantnim modelom za procjenu ekološkog učinka klimatskih promjena na bioraznolikost u moru, kao i za ispitivanje mogućih strategija prilagodbe i ublažavanja negativnih utjecaja. Ove strategije imaju potencijal za širu primjenu u drugim regijama (Cramer i sur., 2018). Sukladno rečenom,

specifičnosti sjevernog Jadrana, čine ga savršenim prirodnim laboratorijem za proučavanje ugroženih populacija, njihovu obnovu i najbolju praksu očuvanja i zaštite (Gljušćić i sur., 2023; Lokovšek i sur., 2023; Orlando-Bonaca i sur., 2022a, 2021).

Cistozire igraju važnu ulogu kao graditelji staništa (Blanfuné i sur., 2019; Gianni i sur., 2013) i pružatelji usluga ekosustava, jer njihova trodimenzionalna struktura pruža stanište i zaklon za manje alge, beskralježnjake i ribe na stjenovitom dnu (Bonaca i Lipej, 2005; Cheminée i sur., 2013; Orlando-Bonaca i sur., 2022b; Pitacco i sur., 2014; Vergés i sur., 2009). U posljednjim desetljećima zabilježena je regresija u sastavu zajednica dominantnih smeđih algi iz reda Fucales u različitim regijama Sredozemnog mora, što je rezultat uništavanja staništa (urbanizacija i ekstremni olujni događaji), zagađenja, prekomjernog brštenja (ježinci i herbivorne ribe) i globalnog zagrijavanja (Darmaraki i sur., 2019; Fabbrizzi i sur., 2020; Gianni i sur., 2013; Mineur i sur., 2015; Verdura i sur., 2021).

U našoj studiji fokusirali smo se na termotoleranciju i otpornost makroalge *Gongolaria barbata* koja formira šume i nastanjuje stjenovito dno sjevernog Jadrana. Ova vrsta pripada skupini termofilnih mediteransko-atlantskih algi i geografski je široko rasprostranjena (Orfanidis, 1991). Duž obale koja je obuhvaćena ovim istraživanjem, povijesni podaci pokazuju da populacije vrste *G. barbata*, kao i populacije drugih vrsta cistozira, prolaze kroz razdoblja regresije i oporavka, što je vjerojatno povezano s eutrofikacijom te pojavom i brojnošću ježinaca (Iveša i sur., 2016). Od 2016. godine, terenska opažanja dovela su nas do hipoteze da je vrsta *G. barbata* ponovno u fazi regresije, pri čemu je njezina rasprostranjenost ograničena na svega nekoliko plitkih lokacija. Jedna od najvećih i moguće posljednjih dobro razvijenih šuma nalazi se u plitkoj obalnoj laguni Šćuza (Pomerski zaljev) na južnoj obali Istre (Iveša i sur., 2022).

Biološki odgovori na MTV-ove događaju se na individualnoj, populacijskoj i na razini zajednice, intenziviraju se prema toplim rubnim područjima rasprostranjenosti vrsta, dok središnja područja raspona i populacije na hladnim rubovima rasprostranjenosti ostaju uglavnom pod minimalnim utjecajem (Hanley i sur., 2023; Smith i sur., 2023). U posljednjih nekoliko godina, posebno se istražuju marginalne/ekstremne populacije, s ciljem razumijevanja kako će populacije u povoljnijim staništima reagirati na buduće klimatske scenarije (Kolzenburg, 2022), jer one već sada doživljavaju ekstremne uvjete koji se očekuju u budućnosti. Istraživanje tih populacija može dovesti do spoznaja o fiziološkim granicama tolerancije i ekološkim čimbenicima koji utječu na

brojnost organizama, rasprostranjenost vrsta i evolucijske procese (Bridle i Vines, 2007; Brown i sur., 1995). Plitke populacije nastanjuju područja čiji uvjeti predstavljaju gornju granicu termotolerancije (Gómez-Gras i sur., 2022; Verdura i sur., 2021), stoga su izrazito ugrožene MTV-ovima (Gómez-Gras i sur., 2022).

Na cistozirama je općenito vršen mali broj istraživanja koji govori o utjecaju povišenih temperatura na juvenilne i odrasle jedinke. Većina istraživanja je vršena u *ex situ* uvjetima (de Caralt i sur., 2023; Fabbrizzi i sur., 2023; Lokovšek i sur., 2024), dok je manji broj studija obuhvaćao kombinaciju *ex situ* i *in situ* eksperimenata za istraživanje razine utjecaja ekstremnih temperatura na cistozire (Mulas i sur., 2022a; Verdura i sur., 2021).

## 3.7. Uzgoj cistozira i metode obnove populacija u Sredozemnom moru

Makroalge iz skupine cistozira ključne su u oblikovanju hridinastog morskog dna, čime igraju značajnu ulogu u očuvanju stabilnosti i integriteta morskih ekosustava u Sredozemnom moru. Međutim, tijekom posljednjih nekoliko desetljeća, ove vrste doživjele su značajan pad brojnosti uslijed kombinacije prirodnih i antropogenih faktora. Kao odgovor na kontinuirani gubitak i fragmentaciju šuma makroalgi diljem obala Sredozemlja, znanstvena zajednica sve više usmjerava pažnju na aktivnu obnovu vrsta koje formiraju morske šume, s naglaskom na usavršavanje tehnika za obnovu njihovih populacija (Cebrian i sur., 2021).

Neki od ključnih preduvjeta za uspješnu obnovu populacija uključuju selekciju odgovarajućih prihvatnih i donorskih postaja, odabir ciljnih vrsta, te shodno tome i selekciju metoda obnove (Cebrian i sur., 2021). Nadalje, poznavanje reproduktivne fenologije kao i životnog ciklusa ciljnih vrsta također je od presudne važnosti i treba biti temeljito proučeno prije samog pokušaja obnove populacija (Rindi i sur., 2023; Savonitto i sur., 2019).

Najproučavanija metoda obnove uključuje prikupljanje reproduktivnog materijala s donorskih lokacija/populacija, poticanje oplodnje, uzgoj u strogo kontroliranim *ex situ* uvjetima, te konačno presađivanje materijala na odredišnu lokaciju (De La Fuente i sur., 2019; Orlando-Bonaca i sur., 2021; Tamburello i sur., 2019; Verdura i sur., 2018). Ostale metode uključuju *in situ* presađivanje odraslih jedinki (Susini i sur., 2007) ili premještanje plodnih grana s ciljem širenja propagula (Verdura i sur., 2018).

Uspješni pokušaji obnove zahtijevaju duboko razumijevanje ekologije i biologije vrsta, kao i svojstava i karakteristika donorskih i odredišnih lokacija, s ciljem povećanja učinkovitosti obnove. Mnoštvo abiotičkih i biotičkih čimbenika, uključujući temperaturu (Verdura i sur., 2021), svjetlost, sedimentaciju (Irving i sur., 2009) i hranjive tvari (Lenzi i sur., 2024) igraju ključnu ulogu u rastu i razvoju mladih i odraslih jedinki, imajući utjecaj na ukupni uspjeh obnove populacija.

Postoje mnoge prijetnje koje potencijalno sprječavaju uspješnu obnovu populacija. Neke od prijetnji su primjerice utjecaj stohastičkih događaja poput nevremena na konstrukcije koje sadržavaju pričvršćene mlade jedinke (Orlando-Bonaca i sur., 2021), negativni utjecaj eutrofikacije (Iveša i sur., 2021), kao i utjecaj herbivora u ranim fazama obnove (Monserrat i sur., 2023). Sukladno tome, pronalaze se i razna riješenja za neke od navedenih prijetnji. Primjerice, sve je više istraživanja o načinu suzbijanja brstioca u ranim fazama obnove (Gianni i sur., 2020; Savonitto i sur., 2021), kao i načinu tretiranja morske vode u ranoj fazi *ex situ* uzgoja u svrhu sprječavanja kontaminacije (Lokovšek i sur., 2023).

Velike smeđe alge razvile su specifične morfološke i fiziološke prilagodbe kako bi optimizirale svoje performanse u postojećim okolišnim uvjetima. Svako odstupanje od optimalnog raspona uvjeta može potaknuti reakcije na staničnoj, individualnoj ili populacijskoj razini, često s negativnim posljedicama (Smith i sur., 2023). S obzirom na prisutnost nekoliko desetaka vrsta cistozira u Sredozemnom moru i njihovu ekološku važnost (Guiry i Guiry, 2024), postoji hitna potreba za istraživanjima kako bi se utvrdili optimalni rasponi abiotičkih i biotičkih čimbenika za svaku vrstu, osobito u kontekstu rane faze uzgoja i obnove, uzimajući u obzir prijetnje njihovom opstanku. Također, ključno je u obzir uzeti zahtjeve pojedinih vrsta u različitim životnim fazama (de Caralt i sur., 2023).

U posljednja dva desetljeća, eksperimenti obnove populacija ili uzgoja provedeni su samo na nekoliko vrsta cistozira, uglavnom na ograničenoj prostornoj skali. Najproučavanije vrste u tom kontekstu su *Gongolaria barbata*, *Cystoseira compressa* i *Ericaria amentacea*.

# 4. MATERIJALI I METODE

## 4.1. Sjeverni Jadran

Sjeverni Jadran je najsjeverniji biogeografski sektor Sredozemnog mora (Bianchi i Morri, 2000) i uključuje 20 000 $km^2$ površine Jadranskog mora. Režimi otjecanja sjevernih talijanskih rijeka, koje ispuštaju svoje vode približno 100 km od zapadne istarske obale, igraju ključnu ulogu u kratkoročnim i dugoročnim varijacijama eutrofikacije sjevernog Jadrana (Degobbis i sur., 2000; Đakovac i sur., 2015, 2012). Na svojoj zapadnoj i sjevernoj strani, sjeverno jadranski biogeografski sektor obuhvaća pretežno pješčanu talijansku obalu od Ancone do Trsta, a zapadna obala istarskog poluotoka predstavlja njegovu istočnu granicu. Uz ovu obalu, morsko dno je uglavnom stjenovito do dubine od približno 12 m, što ga čini posebno pogodnim za formiranje šuma velikih smeđih algi (Iveša i sur., 2016).

Produktivnost sjevernog Jadrana ograničena je dostupnošću nutrijenata, posebno fosfora (Chiaudani i Vighi, 1982). Promjene u sastavu nutrijenata u priobalnom dijelu sjevernog Jadrana su brze, a koncentracije opadaju prema jugu, u smjeru otvorenog mora (Campanelli i sur., 2011). U usporedbi s drugim dijelovima Jadrana, sjeverni Jadran se smatra eutrofnim područjem (Matek i Ljubešić, 2024), što je posebno izraženo zbog utjecaja rijeke Po koja donosi visoke količine fosfora i dušika (Degobbis i sur., 1986; Granéli i sur., 1999). Tijekom procesa eutrofikacije (od 1911. do 1982. godine) dolazi do smanjenja prozirnosti, primarne produkcije bentosa i koncentracije kisika u sjevernom Jadranu (Justić, 1988). Međutim, recentna istraživanja ukazuju na smanjenje protoka rijeke Po zbog učestalijih razdoblja suše uzrokovanih klimatskim promjenama (Grilli i sur., 2020). Ova promjena dovodi do smanjenog unosa nutrijenata, što pogoduje razvoju oligotrofnih uvjeta (Cozzi i sur., 2018). Novija istraživanja doista pokazuju desetljetni trend značajnog smanjenja eutrofikacije u sjevernom Jadranu (Brush i sur., 2020).

## 4.2. Kartiranje vrste *Gongolaria barbata* duž zapadne i južne obale Istre

Godine 2021., u sklopu projekta Hrvatske zaklade za znanost IP-2019-04-6984 “Odgovori smeđih algi roda *Cystoseira*, koje formiraju staništa, na lokalne i globalne stresore (HabCYS)”, izvršeno je kartiranje vrsta iz rodova *Cystoseira*, *Ericaria* i *Gongolaria* na zapadnoj obali Istre u zoni gornjeg infralitorala te u zoni plime i oseke, što obuhvaća i mediolitoralne lokvice. Detaljno je pregledana obala do dubine od 1 metra od Savudrije do Rovinja, uključujući priobalje općine Bale

(San Polo) i cijelu obalu Kamenjaka. Za procjenu brojnosti i pokrovnosti korišten je semikvantitativni indeks Braun-Blanquet (Braun-Blanquet, 1979). Metoda se temelji na vizualnoj procjeni brojnosti ili pokrovnosti određenih organizama na specifičnom području. Površina prekrivena određenom vrstom reda Fucales ocjenjuje se prema skali koja se kreće od -/+ do 5. Oznaka minus (-) predstavlja odsustvo vrste, oznaka plus (+) predstavlja prisustvo vrste u maloj brojnosti (pokrovnost < 1%). Ostale kategorije postepeno predstavljaju veća naselja (1 = 1-5%, 2 = 6-25%, 3 = 26-50%, 4 = 51-75%, 5 = 76-100%).

Vrsta *Gongolaria barbata* u laguni Šćuza potencijalno formira jednu od posljednjih zdravih populacija na obali Istre. Iz tog razloga, vizualno je procijenjena rasprostranjenost vrste *G. barbata* ronjenjem te hodanjem kroz lagunu tijekom zime, proljeća i ljeta 2021. godine. Uz procjenu rasprostranjenosti vrste *G. barbata*, također je procijenjena rasprostranjenost morske cvjetnice *Cymodocea nodosa* (Ucria) Ascherson, koja je dominantni makrofit u laguni.

## 4.3. Lokacije uzorkovanja

Tijekom kartiranja 2021.-2023. vrsta *G. barbata* je bila najbrojnija na lokacijama Lanterna, Funtana, Bijela uvala, laguna Šćuza i Kamenjak. Shodno tome, uzorkovanje jedinki u svrhu usporedbe morfometrijskih karakteristika i biomase preostalih populacija, te za izradu predikcijskih modela biomase na temelju morfometrijskih karakteristika vršeno je na navedenim lokacijama koje će biti detaljnije opisane u sljedećim poglavljima (Slika 3).

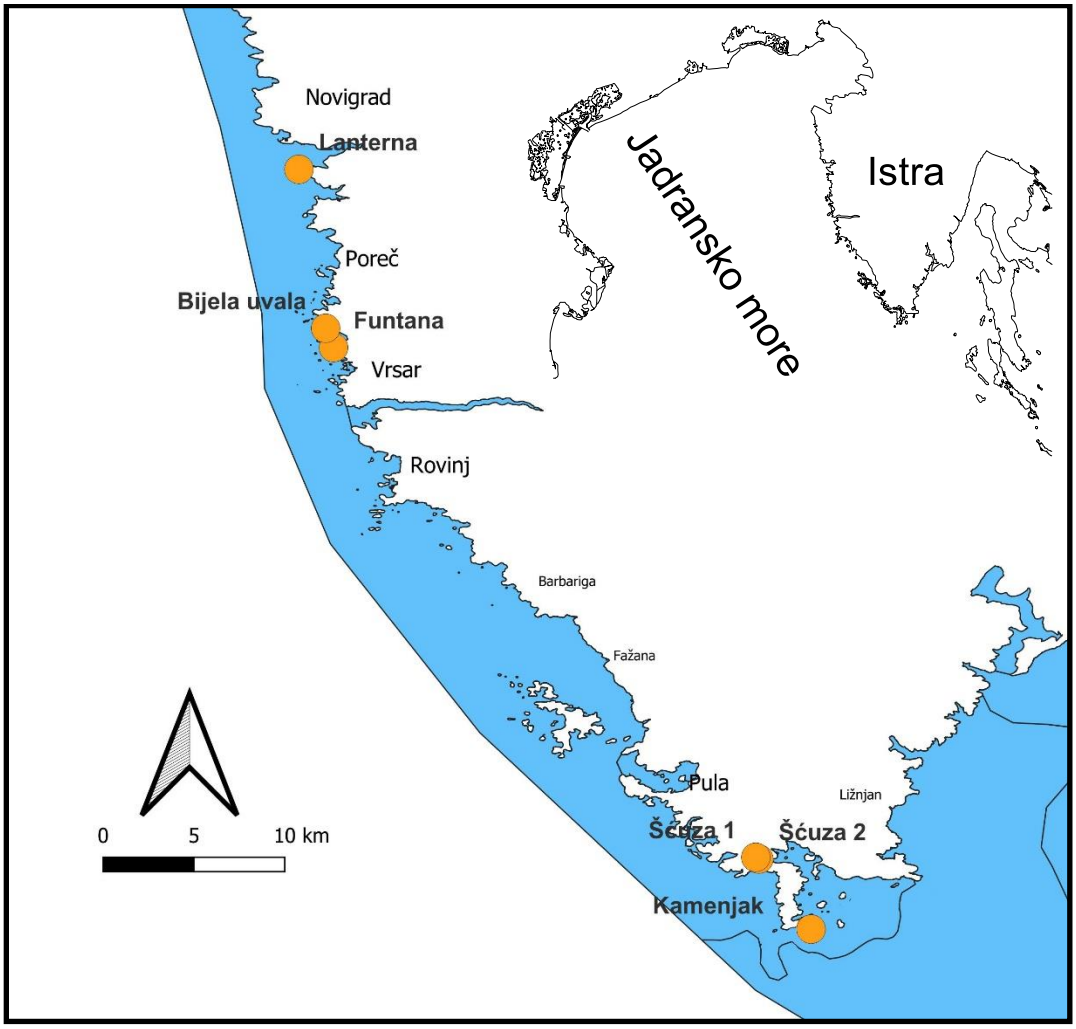


Slika 3. Lokacije uzorkovanja jedinki vrste *Gongolaria barbata* za analizu morfometrijskih karakteristika na zapadnoj i južnoj obali Istre: Lanterna, Funtana, Bijela uvala, Kamenjak, Šćuza 1 i Šćuza 2.

Nadalje, u svrhu usporedbe morfometrijskih karakteristika između recentno uzorkovanih i povijesno uzorkovanih jedinki *G. barbata* na zapadnoj obali Istre, istražene su sve plitke lokacije (0,5-2 m) opisane u radu Iveša i sur. (2016). Dakle istražene su lokacije u blizini Umaga (Bašanija, Katoro i Lovrečica), Novigrada (Novigrad sjever, Lanterna i Červar), Vrsara (Funtana sjever, Funtana jug i Petalon) i Rovinja (Škaraba, Guštinja i Kolone). Na lokacijama gdje su pronađene populacije *G. barbata*, vršeno je uzorkovanje. Od navedenih lokacija, vrsta *G. barbata* je recentno pronađena samo u Lanterni i Funtani jug, stoga se usporedba morfometrije odnosila prvenstveno na dvije navedene lokacije za koje su morfometrijski podaci prikupljeni 2009. i 2023. godine (Slika 4).

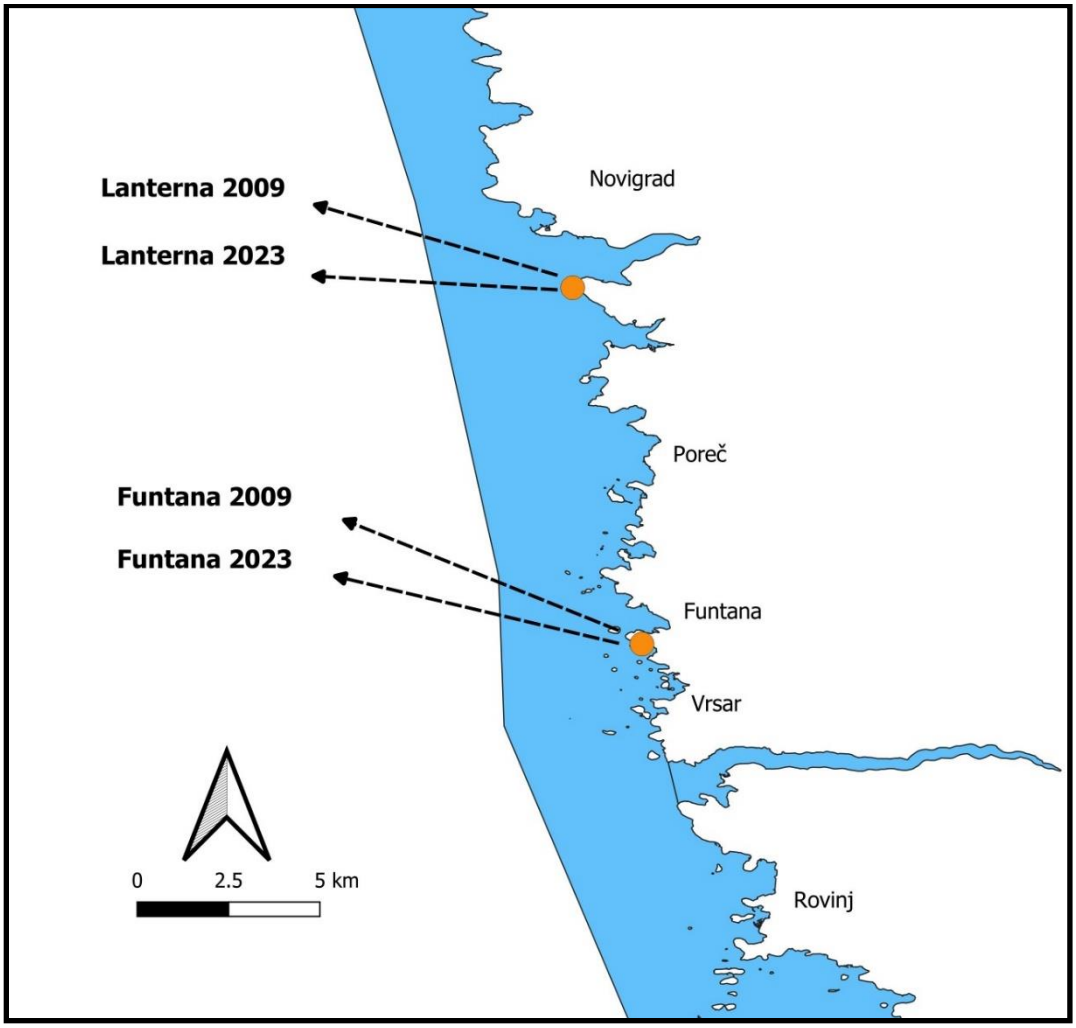


Slika 4. Lokacije uzorkovanja vrste *Gongolaria barbata* na lokacijama Lanterna i Funtana za usporedbu morfometrijskih karakteristika plitkih staništa tijekom 2009. i 2023. godine.

### 4.3.1. Lanterna

Lanterna je lokacija na sjevernom dijelu zapadne obale Istre (područje grada Novigrada), u neposrednoj blizini turističkog naselja. Brojnost i rasprostranjenost pojedinih vrsta cistozira su na lokaciji Lanterna detaljno istraženi 2009. godine na dubinama od 0,5 do 12 m (Iveša i sur., 2016). Na plitkom kamenitom dnu vrsta *Gongolaria barbata* je pokazivala vrlo visoke vrijednosti biomase po jedinici površine, te je time bila dominantna vrsta u dubinskom rasponu od 0,5-2 m. Tvorila je uglavnom miješane šume u kombinaciji s vrstom *Ericaria crinita*. Vrsta *G. barbata* je bila brojna i tvorila je miješane šume s različitim vrstama cistozira i na dubini od 5-7 m, međutim s nižom brojnošću u odnosu na dubine od 0,5 do 2m.

Slika 5. Vrsta *Gongolaria barbata* u plitkom infralitoralu lokacije Lanterna. Veća slika predstavlja taluse vrste *G. barbata* pod obraštajem, dok manja slika predstavlja taluse koji su degradirani uslijed utjecaja ježinaca.

Dakle za navedenu lokaciju postoje povijesni podaci o morfometriji i biomasi vrste *G. barbata* koji će se u ovome radu koristiti za usporedbu morfometrijskih karakteristika (INTERREG projekt "Implementation of the Water Quality Monitoring in the Western Istria Coastal Sea - Northern

Adriatic", WICOS), te za testiranje izrade modela predikcije biomase za populacije *G. barbata* u plitkim staništima. Također, kao dodatno opažanje, poznato je da je plitko kamenito dno trenutno bogato ježincima, s vrlo visokom brojnosti po jedinici površine (37 jedinki/$m^2$; osobna opažanja; Slika 5).

### 4.3.2. Funtana

Funtana je lokacija u središnjem dijelu zapadne obale Istre (područje Vrsara), također u neposrednoj blizini turističkog naselja. Slično kao za Lanternu, lokacija Funtana je dobro istražena 2009. godine (Iveša i sur., 2016). Kamenito dno na dubinama od 0,5 do 2 m bilo je nastanjeno miješanim šumama različitih vrsta cistozira: *Gongolaria barbata*, *Cystoseira compressa*, *Ericaria crinita*, *Cystoseira foeniculacea* i *Cystoseira humilis* (Slika 6).

Slika 6. Miješano naselje cistozira u plitkom infralitoralu lokacije Funtana u kojem se nalazi i vrsta *Gongolaria barbata*.

Pojedine su se vrste pojavljivale i na većim dubinama (u rasponu od 5 do 12 m), međutim s nižim vrijednostima biomase, osim za vrstu *Cystoseira corniculata*, koja inače u većoj brojnosti

nastanjuje samo dublje kamenito dno. Za navedenu lokaciju također postoje povijesni podaci o morfometriji i biomasi vrste *G. barbata* koji će se u ovome radu koristiti za usporedbu morfometrijskih karakteristika, te za testiranje izrade modela predikcije biomase za populacije *G. barbata* u plitkim staništima.

### 4.3.3. Bijela uvala

Lokacija Bijela uvala nalazi se na obalnom području Poreča, na zapadnoj obali Istre. To je poluzatvorena uvala smještena u blizini turističkog naselja, s blagim nagibom obale i pretežno kamenitim podmorjem. Jedna od najvećih i najgušćih šuma vrste *Ericaria crinita* na zapadnoj istarskoj obali nalazi se u ovoj uvali u zoni infralitorala (osobna opažanja), s nešto manjom brojnosti ostalih vrsta cistozira, pretežito vrsta *Cystoseira compressa*, *Gongolaria barbata* i *Cystoseira foeniculacea*. Također, tu se nalaze i mediolitoralne lokvice koje su naseljene brojnim jedinkama četiriju vrsta cistozira: *G. barbata*, *C. compressa*, *C. foeniculacea* i *E. crinita*.

Slika 7. Miješano naselje cistozira s dominacijom vrste *Gongolaria barbata* u mediolitoralnoj lokvici lokacije Bijela uvala.

Uz vrste iz reda Fucales, mnoge druge vrste makroalgi su bile prisutne prilikom ljetnog uzorkovanja: *Laurencia obtusa* (Hudson) J.V.Lamouroux, *Gelidium* sp. J.V.Lamouroux, *Padina*

*pavonica* (Linnaeus) Thivy, *Halimeda tuna* (J.Ellis & Solander) J.V.Lamouroux, *Ulva lactuca* Linnaeus, *Polysiphonia* sp. Greville, *Dictyopteris polypodioides* (De Candolle) J.V.Lamouroux i *Caulerpa cylindracea* Sonder. Mediolitoralne lokvice na lokaciji Bijela uvala su pod stalnim režimom plime i oseke, pod kojim stalno dolazi do izmjene volumena morske vode, uglavnom češće nego u lokvicama na Kamenjaku. *Gongolaria barbata* je na navedenoj lokaciji uzorkovana u 7 takvih, manjih lokvica (Slika 7).

### 4.3.4. Kamenjak

Na jugu Istre u zaštićenom području Kamenjak nalazi se više mediolitoranih lokvica koje nastanjuju smeđe alge reda Fucales (Slika 8). Upravo u dvjema takvim lokvicama je provedeno uzorkovanje vrste *Gongolaria barbata*. One prema svojoj poziciji spadaju pod visoke mediolitoralne lokvice u kojima je izmjena morske vode ograničena.

Slika 8. Miješano naselje cistozira u mediolitoralnoj lokvici lokacije Kamenjak gdje pronalazimo i vrstu *Gongolaria barbata*.

U uskom pojasu mediolitorala, od vrsta koje tvore šume, nalaze se vrste *Ericaria amentacea* i *Ericaria crinita*. Gusta naselja vrste *Ericaria crinita* se mogu pronaći i u infralitoralu, međutim u plitkom infralitoralu je prisutan veliki pritisak hridinastog ježinca *Paracentrotus lividus* Lamarck, 1816 koji uvelike ograničava rast te vrste i sužava njenu rasprostranjenost u uskom pojasu

mediolitorala. Uz vrste *G. barbata*, *E. crinita*, *Cystoseira compressa* i *Cystoseira foeniculacea*, u ljetnom razdoblju u mediolitoralnim lokvicama bili su prisutni i sljedeći taksoni algi: *Acetabularia acetabulum* (Linnaeus) P.C.Silva, *Alsidium* sp. C.Agardh, *Cladophora* sp. Kützing, 1843, *Dictyota dichotoma* (Hudson) J.V.Lamouroux, *Flabellia petiolata* (Turra) Nizamuddin, *Gelidium* sp., *Halimeda tuna*, *Halopteris scoparia* (Linnaeus) Sauvageau, *Jania rubens* (Linnaeus) J.V.Lamouroux, *Laurencia obtusa*, *Padina pavonica*, *Peyssonnelia heteromorpha* (Zanardini) Athanasiadis, *Rytiphlaea tinctoria* (Clemente) C.Agardh, *Sphacelaria cirrosa* (Roth) C.Agardh, *Ulva* sp. Linnaeus i *Valonia utricularis* (Roth) C.Agardh.

### 4.3.5. Laguna Šćuza

Laguna Šćuza, poznata i kao Pomerski zaljev ili Ribnjak, nalazi se u južnoj Istri, u sjevernom Jadranu (44°49′13,3572″N, 13°53′22,7400″E). To je plitka obalna laguna površine 68,6 ha, duboka do 1,5 m, s kamenitim, muljevitim i pjeskovitim tipovima dna. Umjetni nasip razdvaja lagunu od ostatka Medulinskog zaljeva, što rezultira intenzivnim varijacijama temperature, saliniteta i hidrodinamike, kao i snažnom sedimentacijom, erozijom i antropogenim pritiscima.

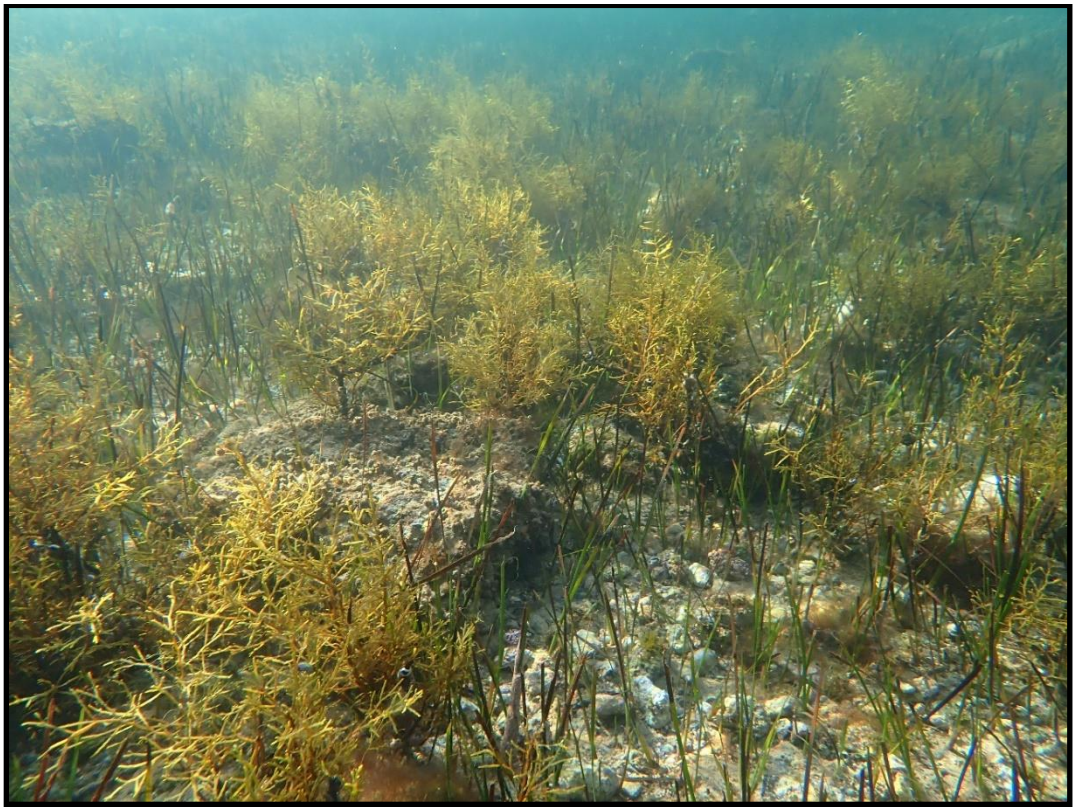

Slika 9. Populacija vrste *Gongolaria barbata* s dominantnom morskom cvjetnicom *Cymodocea nodosa* u laguni Šćuza.

Centralni, najveći dio pokriven je muljevitim pijeskom, gdje dominira velika livada morske cvjetnice *Cymodocea nodosa*. Sjeverni rub prekriven je muljem i erodiranom crvenicom, dok male pješčane sprudove nalazimo na sjeverozapadu i jugoistoku. Zapadni, južni i jugoistočni dijelovi lagune, plitki do 0,7 m, imaju kamenito dno, pogodno za naseljavanje vrste smeđe alge *Gongolaria barbata* (Slika 9), s velikim, erodiranim dijelovima prekrivenim šljunkom, pijeskom, muljem i erodiranim i odbačenim kamenitim materijalom.

Sezonski temperaturni trendovi u laguni Šćuza uglavnom prate one sjevernog Jadrana; međutim, u gornjim i donjim granicama termalnog raspona postoje ekstremne fluktuacije koje nisu zabilježene izvan lagune. Temperature se kreću od ispod 0 °C zimi do iznad 34 °C ljeti (Iveša i sur., 2022), što ovu lagunu čini jedinstvenom termalnom anomalijom na istarskoj obali i korisnim prirodnim laboratorijem za proučavanje učinaka ekstremnih temperatura na vrstu *G. barbata*.

U prošlosti je laguna Šćuza povremeno korištena kao prostrani pasivni bazen za marikulturu komercijalnih vrsta riba i školjkaša, budući da predstavlja utočište i mjesto razmnožavanja mnogih morskih organizama. Unatoč uključivanju lagune u mrežu Natura 2000 i očitoj važnosti lagune za lokalnu biološku raznolikost, kao i za komercijalni ribolov (uzgoj i refugij), provedeno je vrlo malo istraživanja ili procjena kako bi se bolje upravljalo ovim zaštićenim područjem.

## 4.4. Morfometrija vrste *Gongolaria barbata*

### 4.4.1. Morfometrijske karakteristike i biomasa

Recentno uzorkovanje jedinki vrste *Gongolaria barbata* u svrhu određivanje biomase i morfometrijskih karakteristika provedeno je u sljedećim lokacijama: Lanterna, Funtana, Bijela uvala, Kamenjak i Šćuza (Slika 3). Naime, Lanterna i Funtana predstavljaju stanište plitkog infralitorala, Bijela uvala i Kamenjak predstavljaju stanište mediolitoralnih lokvica, te dvije lokacije unutar lagune Šćuza predstavljaju stanište obalne lagune.

Uzorkovanje jedinki vrste *G. barbata* u laguni Šćuza i Bijeloj uvali provedeno je u ljeto 2021. godine, a u Funtani, Lanterni i na Kamenjaku u ljeto 2023. godine. Iz vizualnih opažanja populacija *G. barbata* na istarskoj obali u posljednjih nekoliko godina, moguće je zaključiti da prevladava faza regresije rasprostranjenosti i brojnosti ove vrste. Upravo iz tog razloga, u svrhu opisa morfometrijskih karakteristika i biomase, uzorkovana je ograničena količina jedinki. Primjerice, naselja u Lanterni su bila visoke brojnosti, međutim vidno degradirana. Lokvice inače imaju manju

površinu od infralitoralnih staništa, ali predstavljaju vrijedna „utočišta“ za vrste cistozira zbog odsustva herbivora, stoga je u njima uzorkovan ograničen broj jedinki. Jedina populacija gdje se mogao uzorkovati veći broj jedinki je bila laguna Šćuza, zbog iznimne brojnosti vrste *G. barbata* i otpornosti populacije. Naime, zbog smanjenog broja jedinki u nekim staništima, reprezentativan uzorak mogao se dobiti i bez uzorkovanja unutar kvadrata, posebno u staništima gdje bi daljnje uzorkovanje moglo negativno utjecati na opstanak populacije. Stoga je uzorkovanje provedeno nasumično unutar područja rasprostranjenja populacije *G. barbata*, pri čemu je uzorkovan manji broj jedinki.

Alge su pažljivo uzorkovane čekićem i dlijetom, pohranjene u plastične vrećice i prenesene u plastične bazene u kontrolirane uvjete u Centar za istraživanje mora, gdje su odmah sljedeći dan analizirane. Na većini jedinki izmjereni su sljedeći parametri: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), broj kauloida (N_k), duljina talusa (L_t), promjer glavnog kauloida (Fi_k), promjer bazalne pločice (Fi_bas) i mokra biomasa (W_w; Slika 10). Biomasa je mjerena vagom s preciznosti mjerenja od dvije decimale, dok su ostali parametri mjereni kaliperom ili ravnalom.

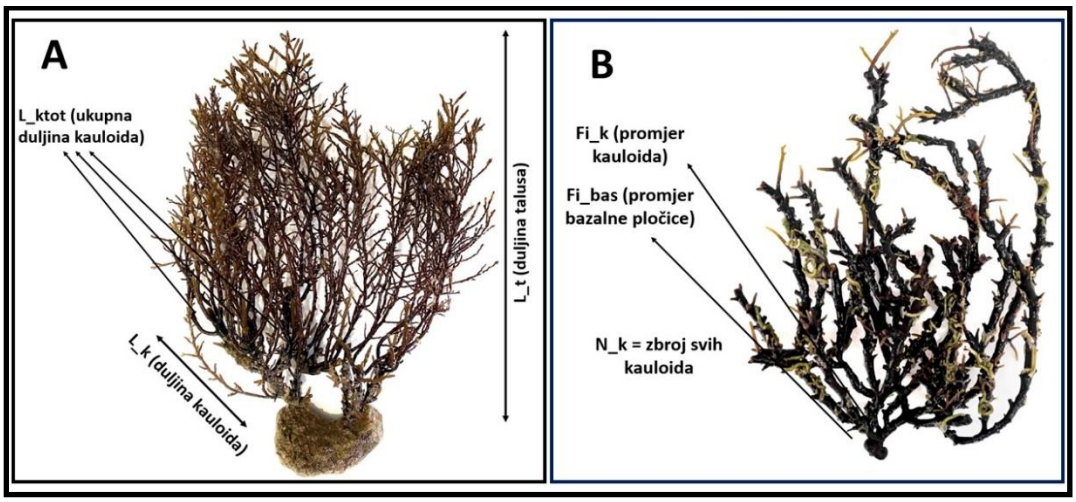


Slika 10. Izmjerene morfometrijske karakteristike ukupna duljina kauloida, duljina kauloida i duljina talusa (A) te broj kauloida, promjer kauloida i promjer bazalne pločice (B).

U Tablici 2. prikazan je broj jedinki vrste *Gongolaria barbata* korištenih za analizu morfometrijskih karakteristika i biomase na istraženim lokacijama u plitkom infralitoralu, mediolitoralnim lokvicama i obalnoj laguni. Na 8 jedinki od 35 s lokacije Funtana, nisu izmjerene karakteristike L_ktot i L_k, te na 19 od 37 jedinki s lokacije Šćuza 2 nije izmjerena karakteristika

Fi_bas (zbog degradiranosti ili nepostojanja bazalne pločice). Dakle, dalje u tekstu i na grafičkim prikazima jedinke iz Lanterne poprimaju naziv „LA“, jedinke iz Funtane naziv „FU“, jedinke iz Bijele uvale „BU“, jedinke iz Kamenjaka „KA“, epilitske jedinke iz lagune „ŠĆ1“, te bento-pleustofitske jedinke (dalje u tekstu nazivamo ih pleustofitske jedinke) iz lagune „ŠĆ2“.

Tablica 2. Broj jedinki vrste *Gongolaria barbata* korištenih za analizu morfometrijskih karakteristika i biomase, te izradu alometrijskih modela na istraženim lokacijama: laguna Šćuza i Bijela uvala (istraživanje provedeno tijekom ljeta 2021. godine) te Funtana, Lanterna i Kamenjak (istraživanje provedeno tijekom ljeta 2023. godine). Za alometrijske modele nisu korištene karakteristike promjer kauloida i promjer bazalne pločice.

| Karakteristika | Lanterna | Funtana | Bijela uvala | Kamenjak | Šćuza1 | Šćuza2 |
|---|---|---|---|---|---|---|
| **Ukupna duljina kauloida** | 29 | 27 | 31 | 11 | 72 | 37 |
| **Duljina kauloida** | 29 | 27 | 31 | 11 | 72 | 37 |
| **Broj kauloida** | 29 | 35 | 31 | 11 | 72 | 37 |
| **Duljina talusa** | 29 | 35 | 31 | 11 | 72 | 37 |
| **Promjer kauloida** | 29 | 35 | 31 | 11 | 72 | 37 |
| **Promjer bazalne pločice** | 29 | 35 | 31 | 11 | 72 | 19 |
| **Mokra biomasa** | 29 | 35 | 31 | 11 | 72 | 37 |

### 4.4.2. Povijesni i recentni podaci morfometrijskih karakteristika

U travnju 2009. uzorci vrste *Gongolaria barbata* prikupljeni su u plitkom infralitoralu (0,5 - 2 m) na lokacijama Lanterna i Funtana (Slika 4). Unutar tri „plohe“, veličine približno 10 × 10 m, udaljene nekoliko desetaka metara jedna od druge, nasumično je postavljeno po tri kvadrata veličine 50 × 50 cm. Unutar kvadrata su pomoću čekića i dlijeta prikupljene sve prisutne vrste cistozira. Nakon prikupljanja, uzorci su transportirani u laboratorij u plastičnim vrećama, a vrste su identificirane prema Ercegoviću (1952) i Gómez-Garreta i sur. (2001). Izmjereni parametri uključuju ukupnu duljinu kauloida, duljinu kauloida, duljinu talusa, broj kauloida te promjer kauloida. Za usporedbu morfometrijskih karakteristika vrste *G. barbata* s dvije lokacije (Funtana i Lanterna) i u dva vremenska razdoblja (2009. i 2023. godina), analizirane su sljedeće morfometrijske karakteristike: duljina kauloida (L_k), duljina talusa (L_t), ukupna duljina kauloida

(L_ktot), promjer glavnog kauloida (Fi_k) i broj kauloida (N_k). Prikupljanje i obrada uzoraka za Funtanu 2023. i Lanternu 2023. opisani su u prethodnom poglavlju, a broj prikupljenih jedinki za analizu prikazan je u Tablici 3.

Tablica 3. Broj jedinki vrste *Gongolaria barbata* korištenih za analizu morfometrijskih karakteristika na dvjema lokacijama tijekom 2009. i 2023. godine.

| Karakteristika | Lanterna 2009 | Funtana 2009 | Lanterna 2023 | Funtana 2023 |
|---|---|---|---|---|
| **Ukupna duljina kauloida** | 146 | 97 | 29 | 27 |
| **Duljina kauloida** | 146 | 97 | 29 | 27 |
| **Broj kauloida** | 146 | 97 | 29 | 27 |
| **Duljina talusa** | 146 | 96 | 29 | 27 |
| **Promjer kauloida** | 146 | 96 | 29 | 27 |

### 4.4.3. Alometrija

Za izradu modela predikcije biomase na temelju glavnih morfometrijskih karakteristika koristili smo iste podatke koji su korišteni za usporedbu morfometrijskih karakteristika između različitih lokacija (Tablica 2). Dakle, podaci su prikupljeni od jedinki uzorkovanih na sljedećim lokacijama: Lanterna, Funtana, Bijela uvala, Kamenjak i Šćuza. Za izradu modela predikcije korištene su sljedeće karakteristike: mokra biomasa (W_w), ukupna duljina kauloida (L_ktot), broj kauloida (N_k), duljina glavnog kauloida (L_k) i duljina talusa (L_t).

Nadalje, osim uzorkovanja provedenog tijekom 2021. i 2023. godine, za izradu modela korišteni su i povijesni podaci morfometrijskih karakteristika jedinki vrste *Gongolaria barbata* prikupljeni u sklopu projekta WICOS tijekom 2009. godine. U tu svrhu, korišten je uzorak od 39 kvadrata. U Tablici 4. prikazan je broj kvadrata unutar kojih je uzorkovana vrsta *Gongolaria barbata* na pet različitih lokacija tijekom 2009. godine i koji su korišteni za izradu alometrijskih modela predikcije biomase na temelju povijesnih podataka.

Za svaki kvadrat pojedinačno, sumirane su sljedeće karakteristike: mokra biomasa (Tot_WW), ukupna duljina kauloida (L_ktot), broj kauloida (N_k), duljina kauloida (L_k), duljina talusa (L_t), biomasa grana (Grane) i broj jedinki (N_axes).

Tablica 4. Broj uzoraka kvadrata unutar kojih je uzorkovana vrsta *Gongolaria barbata* za pojedine morfometrijske karaktersitike i biomasu na pet lokacija tijekom 2009. godine. Navedeni podaci su korišteni za izradu alometrijskih modela na razini kvadrata iz povijesnih podataka.

| Karakteristika | Lovrečica | Lanterna | Červar | Funtana | Petalon |
|---|---|---|---|---|---|
| **Ukupna duljina kauloida** | 3 | 8 | 7 | 17 | 4 |
| **Duljina kauloida** | 3 | 8 | 7 | 17 | 4 |
| **Duljina talusa** | 3 | 8 | 7 | 17 | 4 |
| **Broj jedinki** | 3 | 8 | 7 | 17 | 4 |
| **Biomasa grana** | 3 | 8 | 7 | 17 | 4 |
| **Mokra biomasa** | 3 | 8 | 7 | 17 | 4 |

### 4.4.4. Analiza podataka

#### 4.4.4.1. Morfometrijske karakteristike i biomasa

Za analizu podataka morfometrije iz 2021. i 2023. godine, korištena je kanonička analiza glavnih koordinata (eng. *Canonical Analysis of Principal Coordinates*, CAP). Sve analize provedene su koristeći softver Primer v7 s dodatkom PERMANOVA+. Podaci su prikupljeni s ukupno 215 uzoraka iz različitih lokacija označenih kao LA, FU, BU, KA, ŠĆ1 i ŠĆ2. Svi podaci su transformirani korištenjem D1 euklidske udaljenosti. Analiza je provedena kako bi se istražile razlike između grupa uzoraka temeljenih na faktoru Lokacija. Permutacijski test proveden je s 9999 permutacija za procjenu značajnosti rezultata. Grafički prikaz rezultata analize CAP prikazan je na slici koja prikazuje raspodjelu uzoraka prema kanoničkim koordinatama CAP1 i CAP2, s označenim grupama prema lokacijama.

#### 4.4.4.2. Povijesni i recentni podaci morfometrijskih karakteristika

Za usporednu analizu morfometrijskih podataka (na lokacijama Funtana i Lanterna tijekom 2009. i 2023. godine) također je korištena metoda analize CAP. Podaci su prikupljeni s ukupno 299 uzoraka iz različitih lokacija i godina označenih kao FU23, LA23, FU09 i LA09. Svi podaci su transformirani korištenjem D1 euklidske udaljenosti. Analiza je provedena kako bi se istražile razlike između različitih grupa uzoraka temeljenih na njihovoj lokaciji i vremenskim razdobljima. Permutacijski test proveden je s 9999 permutacija za procjenu značajnosti rezultata. Grafički prikaz

rezultata analize CAP prikazan je na slici koja prikazuje raspodjelu uzoraka prema kanoničkim koordinatama CAP1 i CAP2, s označenim grupama prema lokacijama i godinama.

#### 4.4.4.3. Alometrija

Primarno su izrađeni linearni i nelinearni univarijatni modeli na neobrađenim podacima, gdje je potvrđeno da su linearni modeli bolji po predikciji biomase. Nadalje, kako bismo opisali odnos između mokre biomase (W_w) i različitih morfometrijskih karakteristika poput ukupne duljine kauloida (L_ktot), broja kauloida (N_k), duljine kauloida (L_k) i duljine talusa (L_t), transformirane su sve varijable (log10) i prilagođeni univarijatni i multivarijatni linearni modeli koristeći pojedinačne prediktorske varijable i različite kombinacije varijabli. Navedeno je rezultiralo s ukupno 15 generiranih linearnih modela za svaku lokaciju istraživanja.

Dobiveni modeli za recentni set podataka su zatim uspoređeni odvojeno za svaku lokaciju koristeći AICc, a najbolji modeli su odabrani na temelju uvjeta $\Delta AICc < 2$. Odgovarajuće $R^2$ vrijednosti su korištene ovisno o tome jesu li modeli univarijatni ("višestruki $R^2$") ili multivarijatni ("prilagođeni $R^2$"). Općenito, niža vrijednost kriterija znači da je model bolji. Ako su vrijednosti generiranih modela unutar uvjeta $\Delta AICc < 2$, modeli se smatraju jednakima po kvaliteti predikcije, te u tom slučaju nema razloga za odabir jednog modela nad drugim. Za svaki model su generirani grafički prikazi aktualnih naspram predviđenih vrijednosti. Grafički su prikazani svi univarijantni modeli i dva multivarijatna modela s najboljim karakteristikama.

Također, u zasebnoj analizi, generirani su modeli s interakcijama između morfometrijskih mjera i faktora Lokacija (razine: LA, FU, BA, KA, ŠĆ1, ŠĆ2), kako bi se omogućili varijabilni nagibi i presjeci po lokaciji. Generirano je sveukupno 45 modela. Izrađeni su univarijatni i multivarijatni modeli za predikciju mokre biomase (W_w) koristeći različite kombinacije prediktorskih varijabli. Modeli su uključivali i interakcijske termine s faktorom Lokacija kako bi se istražilo može li se izgraditi opći model predikcije. Za izradu modela, korištene su sve moguće kombinacije prediktorskih varijabli. Za generiranje svih kombinacija prediktora korištena je funkcija koja je generirala modele s jednostavnim prediktorima, kao i modele s kombinacijama dvaju, triju i četiriju prediktora. Na taj način osigurana je sveobuhvatna analiza svih mogućih scenarija predviđanja. Modeli su evaluirani koristeći kriterij AICc i koeficijent determinacije $R^2$ kako bi se utvrdila njihova preciznost i učinkovitost.

Kako bi saznali je li moguća izrada modela predikcije biomase na razini kvadrata iz povijesnih uzorkovanja 2009. godine, generirani su univarijatni i multivarijatni modeli za predikciju mokre biomase (Tot_WW) koristeći različite kombinacije prediktorskih varijabli. Prediktorske varijable su: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), mokra biomasa grana (Grane), duljina talusa (L_t), broj kauloida (N_k) i broj jedinki (N_axes). Podaci su log10-transformirani, te su definirane različite kombinacije modela kako bi se identificirali najbolji prediktori za mokru biomasu. Ukupno je izrađen 31 model. Modeli su uspoređeni i rangirani na temelju njihovih vrijednosti AICc i $R^2$ kako bi se identificirali najprecizniji i najpraktičniji modeli za terensku primjenu.

Za procjenu utjecaja veličine uzorka na koeficijente nagiba i presjeka, proveli smo eksperiment ponovnog uzorkovanja s vraćanjem (eng. „*bootstrap*“), koristeći podatke Tot_WW i Grane (koeficijenti linearne jednadžbe koja proizlazi iz modela Tot_WW~Grane) iz povijesnog skupa podataka (n = 39). Podaci su log10-transformirani, generiran je linearni model, zatim su koeficijenti nagiba i presjeka izvučeni iz modela i korišteni kao referentne vrijednosti za kasniju usporedbu s novim generiranim modelima i izvučenim koeficijentima povezanima s različitim veličinama uzorka. Zatim smo proveli eksperiment ponovnog uzorkovanja koji se sastoji od 1000 iteracija, počevši s veličinom uzorka od n = 3, i povećavajući veličinu uzorka za 3 jedinice, sve do veličine n = 39, čime se dobiva 1000 koeficijenata nagiba i 1000 koeficijenata presijeka za svaku veličinu uzorka. Referentne vrijednosti koeficijenata nagiba i presijeka iz originalnog linearnog modela su zatim oduzete od novih generiranih vrijednosti koeficijenata nagiba i presjeka iz različitih veličina uzoraka, zatim je apsolutna vrijednost izračunata iz dobivenih razlika koeficijenata nagiba i presjeka. Dobivene apsolutne vrijednosti razlika nagiba i presjeka su zatim grafički prikazane, svaka vrijednost prikazana je na y-osi, dok je porast veličine uzorka prikazan na x-osi.

Metode generiranja i odabira najboljih modela, kao i odabir minimalne veličine uzorka, korištene su na identičan način za predviđanje mokre biomase smeđe alge *Saccharina latissima* (Laminariales, Phaeophyceae) u južnoj Britanskoj Kolumbiji (Campbell i Starko, 2021). Izrada i testiranje svih modela vršeno je u softveru R koristeći pakete: *MuMIn*, za izračunavanje AICc-a; *broom*, za rezimiranje modela; *officer* i *flextable*, za izradu tablica u Word dokumentu; *tidyverse*,

skup paketa za operacije s podacima; *lmtest*, za testiranje linearnih modela; *car*, za dijagnostiku linearnih regresijskih modela; *ggplot2* i *cowplot*; za vizualizaciju podataka i modela.

## 4.5. Eksperiment termotolerancije

### 4.5.1. Temperaturni uvjeti unutar i izvan lagune

Temperatura mora u laguni na mjestu uzorkovanja neprekidno je praćena u razdoblju od 01.01.2020. do 31.12.2022. korištenjem HOBO Pendant® Temperature/Light 64K Data Loggera, smještenog 0,5 m ispod morske površine, s bilježenjem temperature svakih 30 minuta. Za analizu podataka, dnevne maksimalne vrijednosti temperature izdvojene su iz cijelog skupa podataka. Te su vrijednosti zatim podvrgnute funkciji „*exceedence*“, dostupnoj u paketu *heatwaveR* (Schlegel i Smit, 2018). U funkciji su određene granice od 28, 30, 32 i 34 °C kako bi se identificirali slučajevi kada temperatura prelazi pojedine ekstremne temperature. U funkciji „*exceedence*“, postavljeno je minimalno trajanje od 5 uzastopnih dana za granice od 28, 30 i 32 °C, a minimalno trajanje od jednog dana uzeto je u obzir za granicu od 34 °C. Ovaj pristup omogućio je vizualnu identifikaciju razdoblja u kojim su zabilježene ekstremne temperature. Podaci su grupirani prema godini i temperaturi, te je generiran sažetak koji prikazuje ukupan broj dana koji prelaze svaku temperaturnu granicu za svaku pojedinu godinu. Ovaj sažetak omogućio je kasniju vizualizaciju trajanja određenih događaja, pružajući uvid u učestalost i intenzitet fluktuacija temperature tijekom promatranih godina. Nadalje, najtoplija razdoblja zabilježena u laguni u 2022. godini vizualizirana su korištenjem dijagrama pravokutnika kako bi se pobliže objasnio dnevni raspon temperature i fluktuacije (Prilog Slika P8). Radi opisa temperaturnih uvjeta izvan lagune, podaci o temperaturi površine mora (SST) dobiveni iz satelita (OISST v.2) preuzeti su s ERDDAP poslužitelja podataka (Simons i Chris, 2023). Korištena je srednja vrijednost temperature za piksele duž južne obale Istre (geografske širine od 44°22′30″ do 44°52′30″N i geografske dužine od 13°30′0″ do 14°7′30″E) za svaku vremensku točku (dnevne prosječne vrijednosti temperature) u razdoblju od 1983. do kraja 2022. godine. *In situ* podaci i dnevne prosječne SST vrijednosti temperatura preklopljeni su za razdoblje od 2020. do kraja 2022. godine kako bi se vizualizirali različiti uvjeti unutar i izvan lagune, te time temperatura lagune postavila u širi okolišni kontekst.

Nadalje, radi istraživanja dugoročnog trenda (intenziteta i trajanja) ekstremnih morskih toplinskih valova izvan lagune, podaci o SST-u podvrgnuti su funkcijama „*ts2clm*“, „*detect_event*“ i „*lolliplot*“ iz paketa *heatwaveR* (Schlegel i Smit, 2018). Funkcija „*ts2clm*“ omogućila je

određivanje sezonske klimatologije i praga 90. percentila za izračunavanje morskih toplinskih valova kao što je definirano u Hobday i sur. (2016, 2018). Funkcija „*detect_event*“ omogućila je otkrivanje trajanja i intenziteta morskih toplinskih valova, dok je funkcija „*lolliplot*“ omogućila vizualizaciju trajanja i intenziteta morskih toplinskih valova u razdoblju od početka 1983. do kraja 2022. godine.

### 4.5.2. Eksperimentalni dizajn

Dana 07.03.2023. godine, 45 jedinki je nasumično uzorkovano iz plitke obalne lagune Šćuza (Slika 11) i pažljivo smješteno u kamene bazene koji su sadržavali prirodnu morsku vodu (14 °C), gdje su zadržane do 09.03.2023. godine.

Jedinke su pričvršćene na pločice od vapnenca (10 cm × 10 cm × 2 cm) elastičnim trakicama te raspoređene u staklene akvarije od 24 L koji su sadržavali filtriranu morsku vodu i održavani na konstantnoj temperaturi od 18 °C. Zatim su simulirana četiri različita scenarija morskih toplinskih valova. Kontrolna temperatura od 18 °C odabrana je jer se ta temperatura podudara s razdobljem vrhunca vegetacije ove vrste unutar lagune.

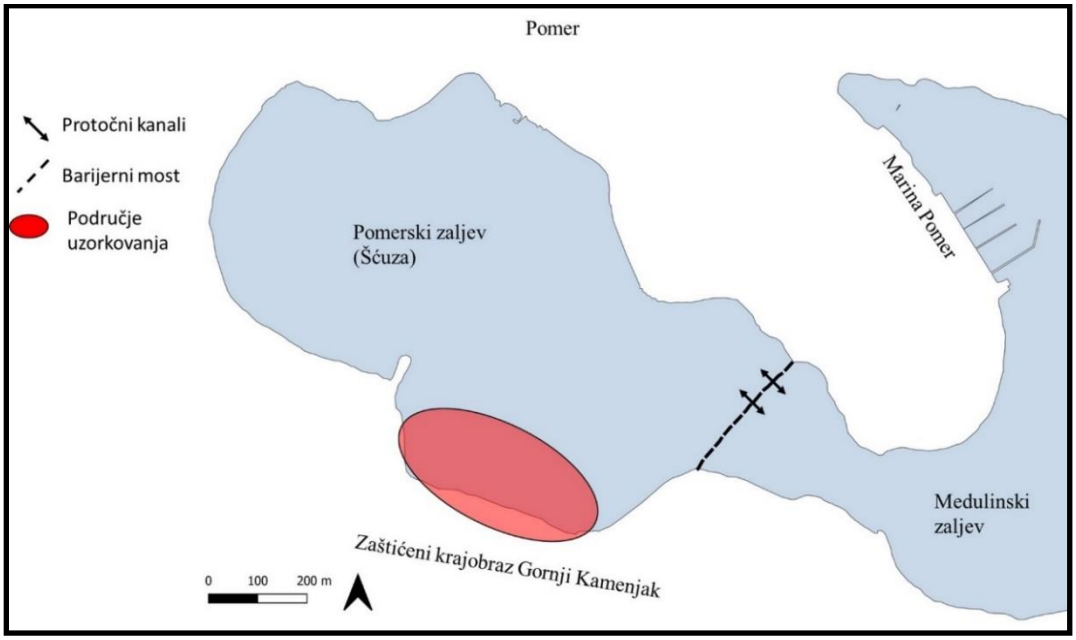


Slika 11. Karta južne istarske obale koja prikazuje lagunu Šćuza, mjesto uzorkovanja jedinki *Gongolaria barbata* (crvena elipsa), most (isprekidana linija) i kanale izmjene vode (strelice). Pozicija lagune na istarskoj obali prikazana je na Slici 3.

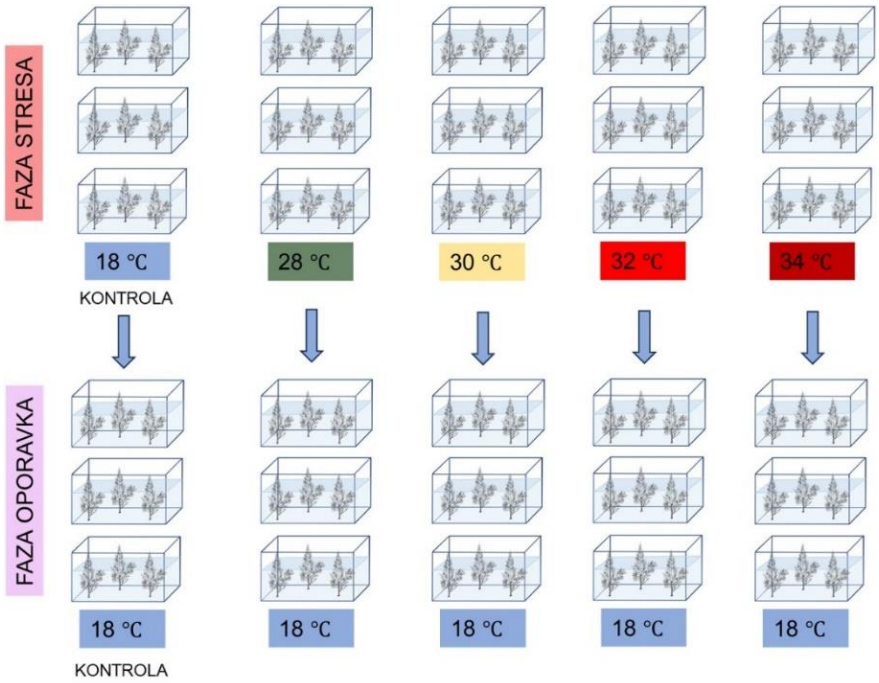


Slika 12. Shema eksperimentalnog dizajna eksperimenta termotolerancije.

Maksimalne temperature (28, 30, 32 i 34 °C) odabrane su na temelju promatranja ljetnih uvjeta u laguni, tijekom kojih ova vrsta estivira. Eksperimentalni dizajn sastojalo se od tri odvojena spremnika za svaki tretman, s po tri jedinke smještene unutar svakog spremnika (Slika 12).

Tijekom sljedećih dana, temperatura je održavana na 18 °C u kontrolnim akvarijima, dok je u ostalim tretmanima povećana na 21 °C 10.03.2023., na 23 °C 11.03.2023. i na 25 °C 13.03.2023. Dana 14.03.2023., temperatura četiri ekstremna tretmana povećana je na 28, 30, 32 ili 34 °C (Slika 13). Zatim su provedena početna mjerenja biomase, morfometrije i fiziologije. Eksperiment je trajao 38 dana, što je uključivalo fazu stresa (tretman) i fazu oporavka. Faza stresa trajala je 17 dana, tijekom kojih su uzorci izloženi određenim uvjetima stresa. Faza oporavka karakterizirana je postupnim smanjenjem temperature na kontrolne uvjete, počevši od 18. dana i trajala je 10 dana (1 °C dan$^{-1}$, tretman 28 °C; 1,2 °C dan$^{-1}$, tretman 30 °C; 1,4 °C dan$^{-1}$, tretman 32 °C; i 1,6 °C dan$^{-1}$, tretman 34 °C), nakon čega su uzorci održavani na 18 °C preostalih 10 dana (Slika 13). Mjerenje biomase i duljine talusa provodilo se isključivo tijekom faze stresa (dani 0, 3, 6, 10, 14 i 17), dok je mjerenje efektivnog kvantnog prinosa (*YII*; „effective quantum yield“) i maksimalnog kvantnog prinosa (*Fv/Fm*; „maximum quantum yield“) dobiveno tijekom obje faze, stresa i oporavka (dani

stresa 0, 3, 6, 10, 14, 17 i dani oporavka 28, 31, 35 i 38). Tijekom svake točke mjerenja, uzorci su pažljivo uklonjeni iz spremnika i nježno osušeni pomoću papirnatih maramica kako bi se uklonio višak vode. Zatim su jedinke fotografirane korištenjem digitalnih kamera visoke razlučivosti kako bi eventualna strukturalna oštećenja bila zabilježena. Izmjerena je mokra biomasa i duljina talusa, nakon čega je provedeno mjerenje *YII*. U slučaju *Fv/Fm*, uzorci su bili podvrgnuti razdoblju adaptacije u tami od 15 minuta, nakon čega su izvršena pojedinačna mjerenja u tamnim uvjetima. Oba mjerenja kvantnog prinosa izvršena su korištenjem MINI-PAM-II (Heinz Walz GmbH), mjerenjem fluorescencije na granama.

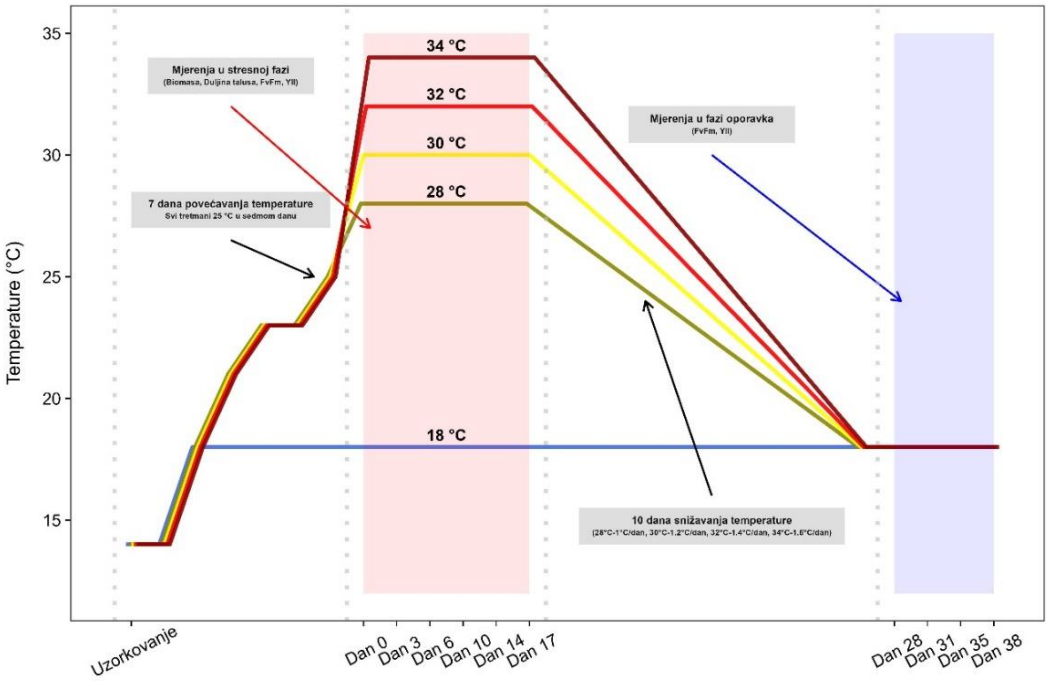


Slika 13. Shema tretmana: kontrolni uvjeti na 18 °C i ekstremni uvjeti na 28, 30, 32 i 34 °C. Tijekom prvih 7 dana nakon uzorkovanja, temperatura je postupno povećana na 25 °C, a osmog je dana u različitim tretmanima dosegnuta specifična temperaturna granica. Fazi stresa slijedilo je 10 dana postupnog smanjenja temperature, nakon čega je uslijedila faza oporavka.

Biomasa i duljina talusa procijenjeni su kao postotci uspoređujući mjerenja svake jedinke u određenoj točki vremena s njihovim početnim vrijednostima. Te promjene prikazane su tako da se mjerenje na dan 0 postavlja kao 100% za biomasu i duljinu talusa, dok su naknadne točke vremena pokazatelji postotka biomase i duljine talusa koji su preostali u odnosu na početna mjerenja. Temperatura od 18 °C održavana je korištenjem temperaturnog kontrolera morske vode (Teco

TK500) i klima uređaja. Više temperature regulirane su s 100 W grijačima za akvarij. Za održavanje kvalitete vode, 50% morske vode u svakom spremniku mijenjano je na tjednoj razini. Prirodna morska voda namijenjena za izmjenu volumena u eksperimentu, zagrijavana je na 25 °C i pohranjena u odvojenom akvariju. Kao izvor svjetla korištene su fluorescentne cijevi (Phillips Master TL-D 36 W/865, 6000 K), pružajući približno osvjetljenje od 50 µmol fotona $m^{-2}$ $s^{-1}$, dok je fotoperiod slijedio ciklus od 12 h svjetla i 12 h tame.

Prije glavnog eksperimenta 2023. godine, proveden je i preliminarni eksperiment koji je obuhvaćao duže vremensko razdoblje izlaganja jedinki povišenim temperaturama. Preliminarni eksperiment termotolerancije proveden je 2022. godine. Jedinke su izložene različitim temperaturnim tretmanima (28, 30, 32 i 34 °C), te su fotoaparatom bilježene vizualne promjene u izgledu talusa tijekom različitih mjernih intervala. Stresna faza trajala je 62 dana, dok je cijeli eksperiment trajao 166 dana. Fotografije jedinki preliminarnog eksperimenta prikazane su u Prilozima na Slici P9.

### 4.5.3. Analiza podataka

Za istraživanje utjecaja temperature na biomasu korišten je linearni mješoviti model (eng. *Linear Mixed effects Model*, LMM), dok je za analizu utjecaja temperature na duljinu talusa, *Fv/Fm* i *YII* korišten generalizirani linearni mješoviti model (eng. *Generalized Linear Mixed effects Model*, GLMM) s Poissonovom distribucijom pogreške i "logit link" funkcijom. Temperatura je bila uključena kao fiksni faktor, a vrijeme je uključeno kao "*crossed-random*" faktor. Dodatno, uključen je drugi nasumični faktor, jedinke ugniježđene unutar akvarija. Za istraživanje utjecaja fiksnog faktora primijenjen je test tipa II Wald $\chi 2$ na svaki prilagođeni model. Nadalje, provedeni su Tukey post-hoc testovi kako bi se utvrdile specifične razlike između temperaturnih tretmana. Sve analize izvedene su koristeći program R (R Core Team, 2023), pri čemu su modeli prilagođeni korištenjem paketa *lme4* (Bates i sur., 2015) i *MASS* (Ripley i sur., 2023). p-vrijednosti su dobivene putem testa Wald $\chi 2$ koristeći funkciju „*Anova*" iz paketa *car* (Fox i Weisberg, 2019), a p-vrijednost <0,05 korištena je za zaključivanje o statističkoj značajnosti. Za Tukeyev post-hoc test korištena je funkcija „*glht*" iz paketa *multcomp* (Hothorn i sur., 2008).

## 4.6. Uzgoj

### 4.6.1. Eksperimentalni dizajn

Dana 18.04.2023. godine, plodni receptakuli prikupljeni su iz lagune Šćuza (Slika 1, 2). Receptakuli su očišćeni od nečistoća i epibionata, zatim omotani aluminijskom folijom i pohranjeni na 4 °C tijekom 24 sata kako bi se potaknulo oslobađanje gameta.

Glinene pločice promjera 5,5 cm s centralnom rupom od 0,5 cm korištene su kao podloga za prihvat propagula. Ukupno osam akvarija, svaki s po osam glinenih pločica i nekoliko manjih pločica za mjerenje *ex situ* (po 4 manje pločice raspoređene u dva akvarija na svakoj svjetlosnoj razini), postavljeno je u inkubator. Tijekom *ex situ* faze, praćene su po dvije označene manje pločice iz dva akvarija po svjetlosnom tretmanu, dok su preostale pločice bile namijenjene za naknadno praćenje na terenu.

Receptakuli su nasumično postavljeni iznad pločica u akvarijima u svrhu oslobađanja gameta. Razina filtrirane morske vode (filtrirane kroz filter od 0,22 µm) iz lagune bila je podešena tako da prekrije pločice i receptakule. Zatim su akvariji prebačeni u inkubator (Memmert Compressor Cooling Inkubator ICP260), gdje je temperatura održavana na 18 °C, a intenzitet svjetla postavljen je na 15 i 70 µmol fotona $m^{-2}$ $s^{-1}$. Dana 19.04.2023. četiri akvarija je podvrgnuto nižem intenzitetu svjetla, dok je drugih četiri podvrgnuto višem intenzitetu svjetla. Razina od 15 µmol fotona $m^{-2}$ $s^{-1}$ je blizu onoj koja se inače bilježi u šumama ili ispod šuma *Gongolaria barbata* (Irving i sur., 2009), dok je za usporedbu u ovom eksperimentu korištena i znatno viša svjetlosna razina.

Prva mjerenja preživljavanja i visine izvršena su 21.04.2023. godine. Dana 22.04.2023. godine, receptakuli su uklonjeni iz akvarija. Naknadno, u svaki akvarij dodano je po 100 mL filtrirane morske vode. Prva izmjena vode provedena je 24.04.2023., a od tog trenutka nadalje, volumen u svakom akvariju prilagođen je na 500 mL filtrirane morske vode obogaćene Von Stosch medijem. Ukupni volumen filtrirane morske vode u akvariju zamijenjen je u sljedećim datumima: 24.04.2023., 28.04.2023., 02.05.2023., 05.05.2023. i 10.05.2023.

Za pripremu Von Stoch otopine, potrebno je otopiti 8,5 g natrijeva nitrata ($NaNO_3$) u 200 mL destilirane vode, zatim dodati 2,15 g natrijeva hidrogen fosfata dodekahidrata ($Na_2HPO_4 \cdot 12H_2O$), 55,6 mg željezo (II) sulfata heptahidrata ($FeSO_4 \cdot 7H_2O$), 3,9 mg manganova (II) klorida tetrahidrata ($MnCl_2 \cdot 4H_2O$) i 0,74 g dinatrij EDTA ($Na_2EDTA \cdot 2H_2O$), svaki u 200 mL destilirane vode. Zadnja

otopina sastoji se od 10 mL otopine biotina (10 mg biotina u 500 mL destilirane vode) i 0,2 mL otopine vitamina B12 (10 mg B12 u 10 mL destilirane vode), kojima se dodaje 40 mg tiamina. Na kraju se dodaje destilirana voda kako bi se dobio ukupni volumen od 200 mL. Navedene otopine se čuvaju na 5°C. Za pripremu konačnog medija za uzgoj juvenilnih algi, 1 mL svake od šest pripremljenih otopina dodaje se u jednu litru filtrirane morske vode.

Dana 12.05.2023., nakon redovitih mjerenja, pločice su premještene u sustav otvorenog protoka s nefiltriranom morskom vodom pod intenzitetom svjetla od 50 µmol $m^{-2}$ $s^{-1}$. U ovom sustavu, HOBO TidbiT v2 Water Temperature Data Logger bilježio je temperaturu. Pločice su ostale u sustavu otvorenog protoka do 07.06.2023., kada je ukupno 40 glinenih pločica bilo pričvršćeno plastičnim vezicama u dva kaveza s „mrežastim“ poklopcem (Slika 14). Svaki kavez predstavlja jedan od tretmana različitog intenziteta svjetlosti. Mrežasti kavezi postavljeni su nekoliko metara jedan od drugog u obalnoj laguni Šćuza (Slika 14), blizu izvornog mjesta prikupljanja plodnog materijala, na dubini od približno 0,5 metara.

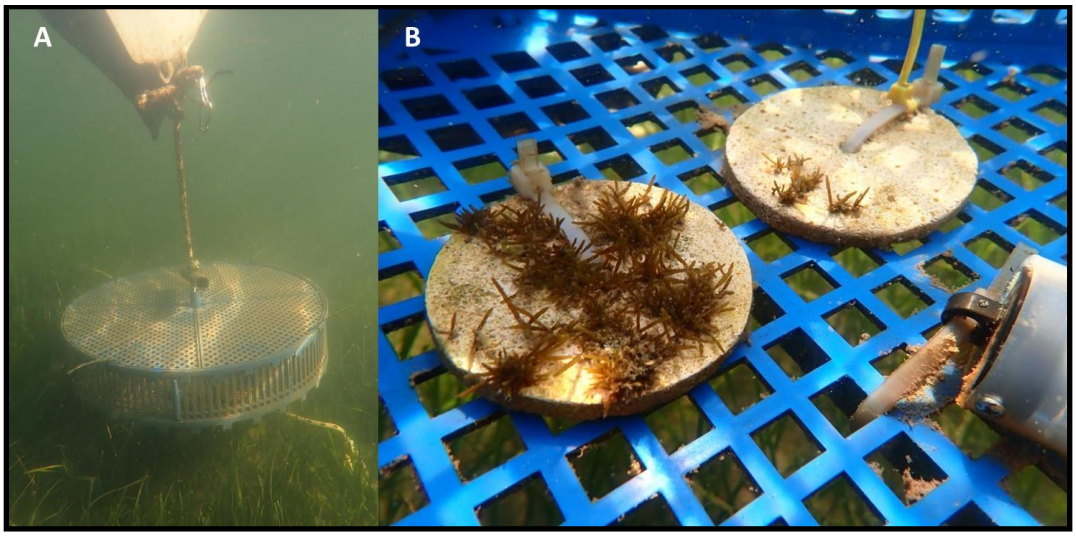


Slika 14. Mrežasti kavez za uzgoj pričvršćen u laguni Šćuza (A) te glinene pločice s juvenilnim jedinkama i uređaj za mjerenje temperature pričvršćeni unutar kaveza (B).

Mjerenje visine i preživljavanje u *ex situ* fazi izvršeno je na četiri glinene pločice (manje pločice) na obje razine svjetlosti, dok su preostale pločice bile namijenjene za kasniju transplantaciju i praćenje rasta i razvoja jedinki u *in situ* uvjetima. Uzorci su pregledani pomoću stereolupe (Olympus SZX 12) i fotografirani pomoću Zeiss-Axiocam 105 color kamere. Visina je mjerena

pomoću ZEN Blue softvera, dok je preživljavanje mjereno pomoću softvera FIJI (Image J). Na svakoj glinenoj pločici, olovkom je označena površina od 0,6 x 0,7 cm (četiri točke) zbog jednostavnijeg mjerenja preživljavanja i visine juvenilnih jedinki. Preživljavanje je praćeno na povećanju od 8,4 × 1,2, dok su mjerenja visine provedena na povećanju od 48 × 1,2. Navedeni parametri praćeni su: 21.04.2023., 24.04.2023., 26.04.2023., 28.04.2023., 02.05.2023., 05.05.2023. i 12.05.2023. u *ex situ* laboratorijskim uvjetima (Slika 15).

Za *in situ* mjerenja na terenu, svaki uzgojni kavez u laguni sadržavao je po 20 glinenih pločica s juvenilnim uzorcima. Iz svakog kaveza je uzeto po četiri glinene pločice na kojima su izvedena mjerenja. Početna mjerenja visine za jedinke na terenu provedena su 11.07.2023. Naknadna mjerenja izvedena su 27.07.2023., 18.08.2023., 01.09.2023., 15.09.2023., 17.10.2023., 14.11.2023., 14.12.2023., 24.01.2024., 24.02.2024. i 21.03.2024. (Slika 15). Ciljane pločice bile su odvojene iz kaveza i pažljivo prenesene do obale gdje su provedena mjerenja. Za određivanje visine, pločice s mladicama algi su fotografirane horizontalno. Pored svake glinene pločice postavljeno je ravnalo kako bi bilo moguće izmjeriti visinu jedinki. Fotografije su pohranjene i kasnije analizirane u FIJI (Image J) softveru. Nakon posljednjeg *in situ* mjerenja, sve pločice su prenesene u kontrolirane *ex situ* uvjete u laboratorij Centra za istraživanje mora, Rovinj, na daljnje praćenje.

### 4.6.2. Abiotički parametri

Za određivanje temperature i svjetlosnih uvjeta na terenu, HOBO Pendant® Temperature/Light 64K Data Logger-i su fiksirani u jednom od kaveza, na istoj razini kao i glinene pločice s juvenilnim jedinkama. Salinitet je mjeren točkasto s YSI ProSOLO sondom. Za praćenje stope sedimentacije, kao i količine organskih i anorganskih frakcija u sedimentu, 10.07.2023. postavljene su dvije menzure (promjera 2,5 cm) u svaki uzgojni kavez, u blizini glinenih pločica. Navedeni parametri analizirani su 27.07.2023., 23.08.2023., 01.09.2023., 15.09.2023., 02.10.2023., 17.10.2023., 14.11.2023., 14.12.2023., 24.01.2024., 24.02.2024., 21.03.2024. i 06.06.2024 (Slika 15).

U laboratoriju, sadržaj svake menzure filtriran je na prethodno vaganom i označenom GF/F filtru. Nakon filtracije, filteri su sušeni (100 °C, 24 sata), izvagani, žareni u mufolnoj peći (450 °C, 5 sati), te ponovno izvagani.

Ukupni protok, izražen u mg/cm$^2$/dan, izračunava se oduzimanjem mase praznog filtra od mase filtra nakon sušenja, a zatim dijeljenjem te vrijednosti s površinom menzure (površina kruga, krug = $r^2\pi$, u našem slučaju: 1,252 x 3,141592654 = 4,909 cm$^2$) i brojem dana koliko su menzure stajale na terenu. Postotak anorganske frakcije (%) dobiven je dijeljenjem sedimentnog protoka (ukupni protok – organski udio dobiven kao gubitak žarenjem) s ukupnim protokom i množenjem s 100.

Uzorci morske vode za određivanje hranjivih soli (nitrat - $NO_3^-$, nitrit - $NO_2^-$, fosfat - $PO_4^{3-}$, amonijev ion - $NH_4^+$ i silikat - $SiO_4^{4-}$) i klorofila a (Chl *a*) prikupljeni su u blizini šume *G. barbata* u laguni Šćuza. Uzorci su filtrirani na prethodno žarenom Whatman GF/F filteru i pohranjeni na −18 °C. Analiza hranjivih soli je provedena korištenjem spektrofotometrijske metode prema Strickland i Parsons (1972). Granice detekcije i reprodukcije za hranjive soli bile su sljedeće: nitrat 0,05 i 0,025 µmol L$^{-1}$; nitrit 0,01 i 0,01 µmol L$^{-1}$; amonijev ion 0,1 i 0,098 µmol L$^{-1}$; silicij 0,1 i 0,06 µmol L$^{-1}$; i fosfat 0,03 i 0,03 µmol L$^{-1}$. Otopljeni anorganski dušik (TIN) izračunat je kao zbroj $NO_3^-$, $NO_2^-$ i $NH_4^+$.

Analiza Chl *a* provedena je fluorometrijski unutar nekoliko dana nakon ekstrakcije u 90% acetona, prema Holm-Hansen i sur. (1965). S obzirom na volumen filtrirane vode (500 mL), granica detekcije za Chl *a* bila je 0,01 µg L$^{-1}$.

Navedeni parametri analizirani su za uzorke morske vode prikupljene na sljedećim datumima: 07.06.2023., 03.07.2023., 01.09.2023., 15.09.0203., 02.10.2023., 14.11.2023., 14.12.2023., 24.01.2024., 26.02.2024., 21.03.2024 (Slika 15).

### 4.6.3. Analiza podataka

#### 4.6.3.1. *Ex situ* rast

Podaci *ex situ* rasta su analizirani korištenjem linearnog mješovitog modela (LMM) kako bi se procijenili učinci svjetlosti i vremena na logaritam visine algi. Model je uključivao fiksne faktore svjetlost, vrijeme i njihove interakcije, dok je glinena pločica tretirana kao nasumični faktor kako bi se kontrolirala varijabilnost između različitih glinenih pločica. Značajnost fiksnih faktora testirana je korištenjem Type II Wald hi-kvadrat testa.

Kako bi se detaljnije istražila interakcija između svjetlosti i vremena, izračunati su procijenjeni marginalni prosjeci (EMMs). Ovi prosjeci uspoređivani su kroz različite vremenske točke kako bi

se identificirale značajne razlike između uvjeta svjetlosti. Usporedbe između uvjeta svjetlosti u svakoj vremenskoj točki provedene su korištenjem Tukey (HSD) testa.

Sve statističke analize provedene su korištenjem programa R, pri čemu su glavni paketi bili *lme4* za postavljanje linearnog mješovitog modela, *car* za provođenje Type II Wald hi-kvadrat testa, *emmeans* za procjenu marginalnih prosjeka i provođenje post-hoc usporedbi. Značajnost je određena na razini od 0,05.

#### 4.6.3.2. *Ex situ* preživljavanje

Podaci o preživljavanju analizirani su korištenjem generaliziranog linearnog mješovitog modela (GLMM) s binomnom raspodjelom i “logit link” funkcijom kako bi se procijenio utjecaj svjetlosti i vremena na preživljavanje algi. Model je uključivao fiksne faktore svjetlost, vrijeme i njihove interakcije, dok je glinena pločica tretirana kao nasumični faktor kako bi se uzela u obzir varijacija između pločica. Za optimizaciju modela korišten je "bobyqa" optimizator. Značajnost fiksnih faktora testirana je korištenjem Type II Wald hi-kvadrat testa.

Kako bi se dodatno istražila interakcija između svjetlosti i vremena, izračunati su procijenjeni marginalni prosjeci (EMMs). Ovi prosjeci uspoređivani su kroz različite vremenske točke kako bi se identificirale značajne razlike u preživljavanju između uvjeta svjetlosti. Usporedbe između uvjeta svjetlosti u svakoj vremenskoj točki provedene su korištenjem Tukey (HSD) testa.

Glavni korišteni paketi bili su *lme4* za postavljanje generaliziranog linearnog mješovitog modela, *car* za provođenje Type II Wald hi-kvadrat testa, *emmeans* za procjenu marginalnih prosjeka i provođenje post-hoc usporedbi. Značajnost je određena na razini od 0,05.

#### 4.6.3.3. *In situ* rast

Podaci o visini analizirani su korištenjem linearnog mješovitog modela (LMM) kako bi se procijenili utjecaji svjetlosti i vremena na logaritam visine algi. Model je uključivao fiksne faktore svjetlost, vrijeme i njihove interakcije, dok je pločica tretirana kao nasumični faktor kako bi se uzela u obzir varijacija između različitih pločica. Značajnost fiksnih faktora testirana je korištenjem Type II Wald hi-kvadrat testa.

Kako bi se dodatno istražila interakcija između svjetlosti i vremena, izračunati su procijenjeni marginalni prosjeci (EMMs). Ovi prosjeci uspoređivani su kroz različite vremenske točke kako bi

se identificirale značajne razlike u visini između različitih uvjeta svjetlosti. Usporedbe između uvjeta svjetlosti u svakoj vremenskoj točki provedene su korištenjem Tukey (HSD) testa.

Glavni paketi uključivali su *lme4* za postavljanje linearnog mješovitog modela, *car* za provođenje Type II Wald hi-kvadrat testa te *emmeans* za procjenu marginalnih prosjeka i provođenje post-hoc usporedbi. Značajnost je određena na razini od 0,05.

#### 4.6.3.4. Abiotički parametri

U svrhu koreliranja rasta uzgojenih juvenilnih jedinki u laguni Šćuza s abiotičkim parametrima, izvršena je PCA analiza. Sljedeći abiotički parametri su bili uključeni u analizu: ukupni protok sedimenta (ukupni protok), temperatura (Temp), svjetlost (Svj), salinitet (Sal), klorofil a (Chl *a*), ukupni anorganski dušik (TIN), fosfat ($PO_4^{3-}$) i silikat ($SiO_4^{4-}$). Uz navedene abiotičke parametre, kao varijabla s dvije razine korištena je i promjena u rastu (kavez 1 - C1 Δrast i kavez 2 - C2 Δrast; rast u pojedinim točkama mjerenja u odnosu na primarno mjerenje rasta). Prije provođenja analize, podaci su normalizirani. U analizi su korišteni biotički i abiotički podaci po mjesecima, od lipnja 2023. do ožujka 2024. (Slika 15). Analiza je izvršena u programu Primer v7 s PERMANOVA+ dodatkom.

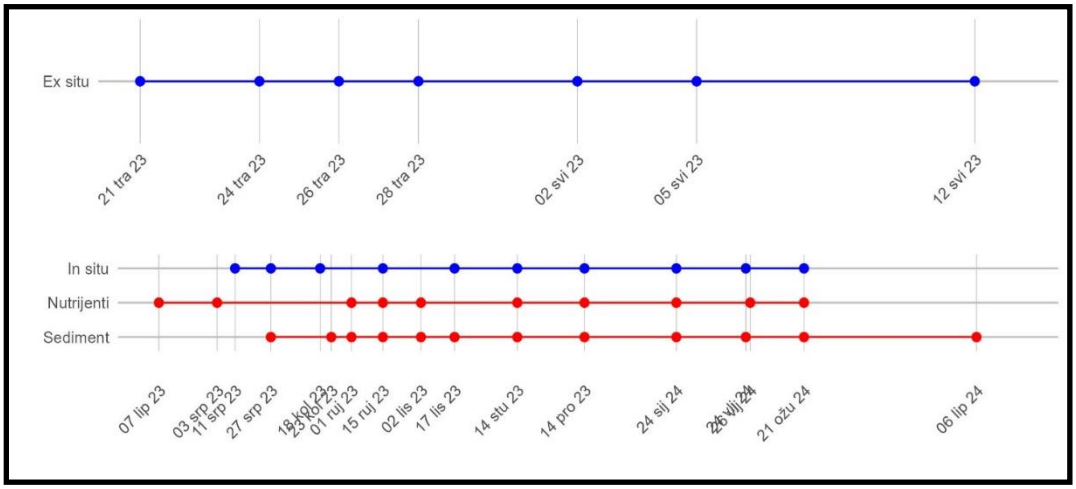


Slika 15. Vremenski prikaz biotičkih i abiotičkih mjerenja provedenih *ex situ* i *in situ*. Točke predstavljaju datume uzorkovanja. Plava boja označava biotička uzorkovanja, dok crvena boja označava abiotička uzorkovanja.

# 5. REZULTATI

## 5.1. Kartiranje cistozira

Tijekom proljeća 2021. godine mapiran je veći dio zapadne obale Istre, a najveća naselja vrsta reda Fucales su pronađena u okolici Poreča, Funtane i Vrsara, gdje se nalazilo mnoštvo točkastih naselja, ali i gustih kontinuiranih naselja cistozira. U obalnom dijelu sjeverno od Poreča, pronađena su točkasta „naselja“ cistozira, ali njihova brojnost i površina doseže vrlo niske razine. U rovinjskom priobalju, gdje su nekad cistozire bile brojne, pronađeno je vrlo malo lokacija u kojima je zabilježeno nekoliko primjeraka vrsta *Cystoseira compressa, Gongolaria barbata* i *Ericaria crinita*. Na jugu Istre, pregledana je cijela obala Kamenjaka, gdje su pronađene sljedeće vrste u mediolitoralu i gornjem infralitoralu: *C. compressa, G. barbata, E. crinita, Ericaria amentacea, Cystoseira foeniculacea*. Najzanimljivija naselja cistozira pronađena su u mediolitoralnim lokvicama na krajnjem jugu Kamenjaka. Navedena naselja su karakterizirana kao miješana naselja, s relativno visokom brojnosti pojedinih vrsta. Također, za razliku od centralnog dijela priobalja Istre, na jugu su pronađeni relativno široki i kontinuirani pojasevi vrste *E. amentacea* u zoni mediolitorala. Nadalje, na jugu Istre, u laguni Šćuza, u gornjem infralitoralu, pronađeno je najveće poznato naselje vrste *G. barbata* u priobalju Istre, a možda i šire.

Na temelju zabilježene pojavnosti vrste *G. barbata* duž zapadne obale Istre prema Braun-Blanquetovoj metodi, utvrđeno je da se ova vrsta na tom području rijetko pojavljuje (Slika 16). U kategoriji jedan (s pokrovnošću od 1-5%) vrsta *G. barbata* zabilježena je 49 puta u pregledanom priobalnom području (40 puta u infralitoralu, 9 puta u lokvicama). U kategoriji dva (6-25%) zabilježena je 22 puta (15 puta u infralitoralu, 7 puta u lokvicama). U kategoriji tri (26-50%) zabilježena je 8 puta (3 puta u infralitoralu, 5 puta u lokvicama). U kategoriji četiri (51-75%) zabilježena je 5 puta (1 put u infralitoralu i 4 puta u lokvicama). U najvišoj kategoriji pet (76-100%) zabilježena je samo 2 puta, oba puta u infralitoralu (Slika 16).

Kartiranje dominantnih vrsta makrofita u laguni Šćuza, pokazalo je da se dominantna zajednica u laguni Šćuza sastoji od livade morske cvjetnice *Cymodocea nodosa* s makroalgama *Cladophora prolifera* (Roth) Kützing, *Valonia aegagropila* C.Agardh i *Rytiphlaea tinctoria* (pronađenih u epilitskom i bento-pleustofitskom obliku), povremeno okružene malim naseljima cvjetnice *Zostera noltii* Hornemann na plitkim rubovima (Slika 17). Na južnoj i jugozapadnoj obali lagune, vrsta *G.*

*barbata* zajedno s makroalgama *Laurencia* sp. J.V.Lamouroux, *V. aegagropila* C.Agardh i *R. tinctoria* tvori kontinuirana naselja u infralitoralnoj zoni, protežući se dalje prema plitkoj mediolitoralnoj zoni. Mnogi talusi vrste *G. barbata* također rastu na pokretnim stijenama, šljunku te čak i na otpadu (hrđavim metalnim predmetima i cestovnim gumama).

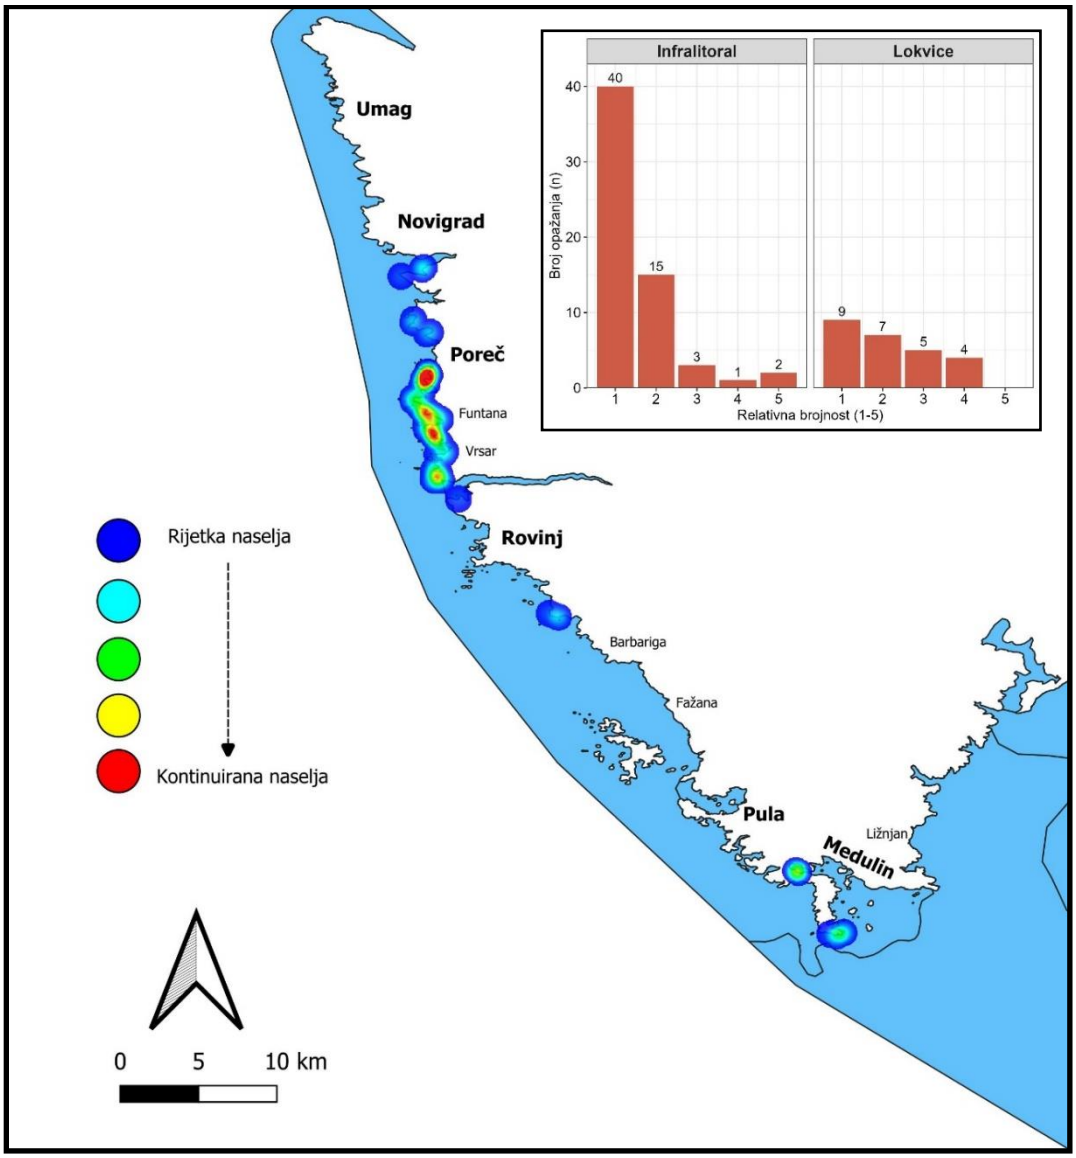


Slika 16. Toplinska karta i stupičasti grafikon relativne brojnosti vrste *Gongolaria barbata* u plitkim staništima zapadne i južne istarske obale. Na stupičastom grafikonu vidljiva je frekvencija pojavljivanja pojedine Braun-Blanquet kategorije (1-5) u plitkom infralitoralu i u lokvicama.

Tijekom vizualnih promatranja u laguni, pronađene su dvije različite morfološke varijante vrste *G. barbata*. Jedna forma ima pričvršćene, epilitske taluse (Prilog Slika P1A). Druga forma ima

odvojene, slobodno-živuće (pleustofitske) taluse koji žive na dnu odvojeni od podloge (Prilog Slika P1B, C). Brojni odvojeni talusi vrste *G. barbata* locirani su raspršeno na području od približno 200 × 300 m (Slika 17). Neki od odvojenih talusa još uvijek zadržavaju svoje bazalne pločice, koje su povremeno deformirane, dok se drugi sastoje u potpunosti od snažno razgranatih kauloida, s nedostatkom bazalne pločice. Na temelju naših opažanja, takvi primjerci mogu nastaviti živjeti i razvijati se poput epilitskih, ali pritom gube svoj karakteristični "stablasti" oblik i "visoku" strukturu tipičnu za vrstu *G. barbata*. Umjesto toga, talus se transformira u strukturu sastavljenu od gusto isprepletenih kauloida (Prilog Slika P1). Koliko nam je poznato, ovo je prva takva pojava primijećena u sjevernom Jadranu. Krajem proljeća i ljeti, talusi su snažno prekriveni serpulidima, spužvama, kolonijalnim plaštenjacima, mahovnjacima i drugim algama, što značajno povećava njihovu ukupnu biomasu. Posljedično, takvi talusi postaju osjetljiviji na odvajanje od tvrde podloge uslijed hidrodinamičkih procesa u laguni.

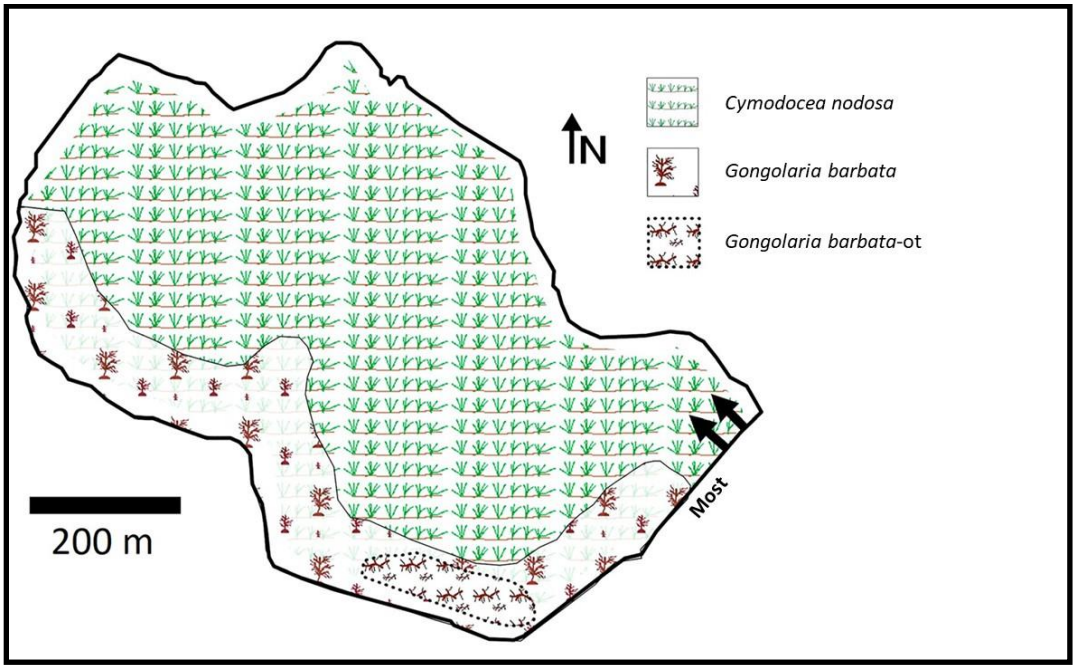


Slika 17. Rasprostranjenost dominantnih makrofita u laguni Šćuza. Kontinuirana naselja vrste *Gongolaria barbata* naseljavaju južnu i jugozapadnu obalu lagune. U legendi, *Gongolaria barbata* predstavlja epilitske primjerke, dok *Gongolaria barbata*-ot predstavlja pleustofitske primjerke.

U sveobuhvatnom istraživanju cistozira gdje je uzorkovanje vršeno u razdoblju 2009. u zoni infralitorala, na lokacijama na području Novigrada (Novigrad sjever, Lanterna i Červar) i Vrsara

(Funtana sjever, Funtana jug i Petalon) zabilježena je prisutnost vrste *G. barbata* (Iveša i sur., 2016) na gotovo svim dubinama uzorkovanja. U razdoblju od 2021. do 2023. ponovno su kartirane sve navedene lokacije te su jedinke vrste *G. barbata* pronađene samo na lokaciji Lanterna te na lokaciji Funtana jug. Na lokacijama na području Rovinja vrsta *G. barbata* nije pronađena niti 2009., niti u razdoblju 2021.-2023. Nadalje, na lokaciji Lovrečica (područje kod Umaga), vrsta *G. barbata* također nije pronađena u recentnom uzorkovanju.

## 5.2 Morfometrija vrste *Gongolaria barbata*

### 5.1.1. Morfometrijske karakteristike i biomasa

Morfometrijske karakteristike i biomasa, uspoređeni su za jedinke prikupljene u razdoblju 2021.-2023. na lokacijama Lanterna, Funtana, Bijela uvala, Kamenjak i Šćuza. Usporedba omogućuje uvid u recentno stanje preostalih populacija vrste *Gongolaria barbata* na istarskoj obali, te vrijedne temelje za dugoročno praćenje promjena u populacijama.

Različite morfometrijske karakteristike i biomasa vrste *Gongolaria barbata* prikazani su za ispitane lokacije, s jasnim razlikama između lokacija (Prilog Tablica P1). Ukupna duljina kauloida (L_ktot) ukazuje na to da uzorci s lokacija Šćuza 1 i Šćuza 2 imaju značajno veće vrijednosti u usporedbi s ostalim lokacijama, uz veću varijabilnost između uzoraka (Slika 18A). Šćuza 2 pokazuje najviše vrijednosti duljine kauloida (L_k). Iako je broj uzoraka mali (n = 11), lokacija Kamenjak ima slične prosječne i maksimalne vrijednosti. Vrijednosti na Šćuza 1 su usporedive s lokacijama Lanterna i Bijela uvala, dok jedinke na lokaciji Funtana imaju najniže vrijednosti ovog parametra (Slika 18B). Što se tiče ukupnog broja kauloida/razgranjenja (N_k), mjerenja na lokaciji Šćuza 2 poprimaju najveće vrijednosti, što sugerira intenzivnije razgranjenje i potencijalno stariju dob. Također je zanimljiva razlika u navedenoj varijabli između Šćuza 1 i Šćuza 2 unatoč uzorkovanju u „istoj populaciji“ (lagunarnoj) (Slika 18C). Duljina talusa (L_t) je najveća na lokalitetima Šćuza 2 i Kamenjak, pri čemu je varijabilnost najizraženija za skupinu Šćuza 2, dok ih po vrijednostima prate mjerenja na lokacijama Šćuza 1 i Bijela uvala (Slika 18D). Promjer glavnog kauloida (Fi_k) pokazuje značajne razlike između lokacija. Vidljivo je kako nasuprot jedinkama s lokacija Lanterna, Bijela uvala i Kamenjak, jedinke s lokacija Funtana, kao i epilitske i pleustofitske jedinke s lokacije Šćuza pokazuju vidno niže vrijednosti promjera kauloida i promjera bazalne pločice (Slika 18E, F). Navedena razlika je pogotovo očita na uzorcima iz lagune,

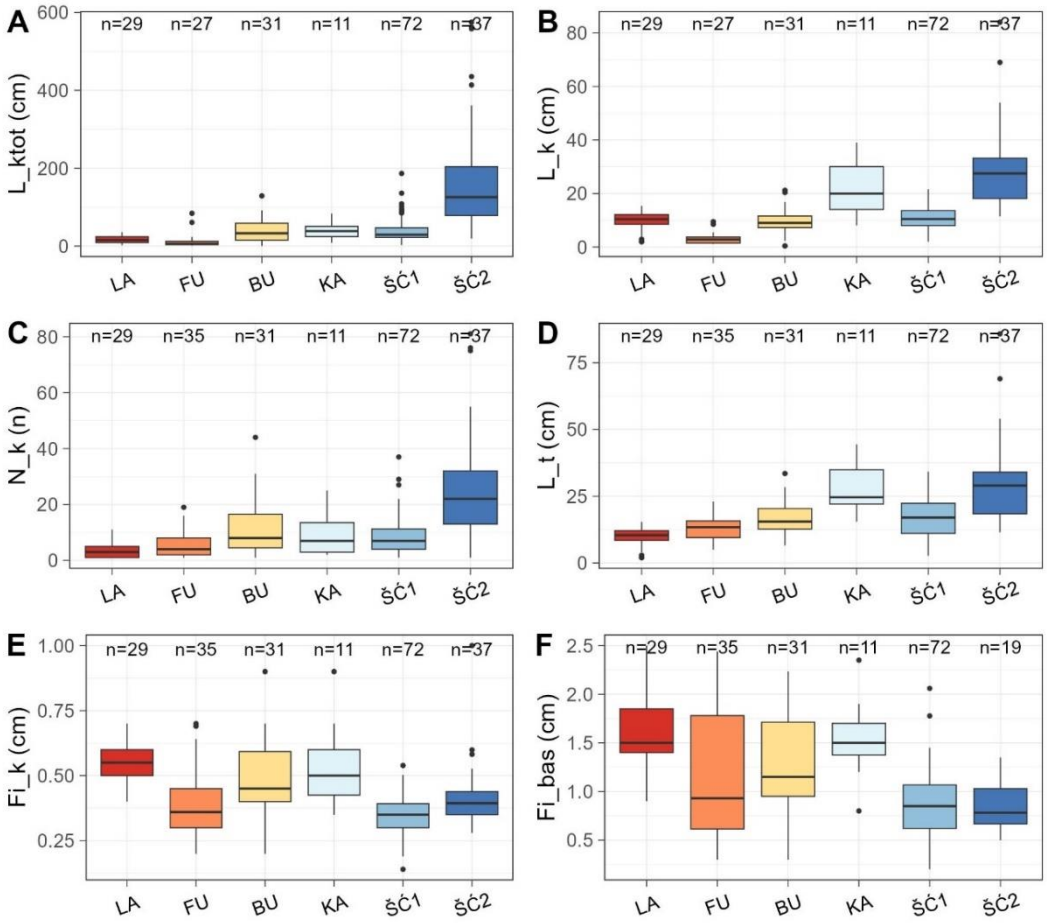


Slika 18. Usporedba pojedinih morfometrijskih karakteristika vrste *Gongolaria barbata* sa šest lokacija (uzorci prikupljeni 2021. i 2023. godine): ukupna duljina kauloida (A), duljina kauloida (B), broj kauloida (C), duljina talusa (D), promjer kauloida (E) i promjer bazalne pločice (F). Lokacije: LA – Lanterna, FU – Funtana, BU – Bijela uvala, KA – Kamenjak, ŠĆ1 – Šćuza 1 i ŠĆ2 – Šćuza 2.

gdje su epilitske jedinke pokazivale najniže vrijednosti navedenih karakteristika. Iako su jedinke iz Bijele uvale i Kamenjaka uzorkovane u istom staništu, mediolitoralnim lokvicama, tek se mala frakcija grupe Kamenjak preklapa s grupom Bijela uvala. Navedene razlike očite su kod karakteristika poput duljine kauloida, duljine talusa, promjera kauloida, ali i promjera bazalne pločice. Slično tome, suprotno očekivanom (uzorkovanje u plitkom infralitoralu), jedinke s Lanterne se razlikuju po karakteristikama bazalne pločice i promjera kauloida od jedinki s lokacije Funtana (Slika 18E, F). Što se tiče biomase, najviše vrijednosti pokazuju pleustofitske jedinke s

lokacije Šćuza 2, dok ih po vrijednostima prate one s Kamenjaka i Bijele uvale, te nešto niže vrijednosti pokazuju one iz Lanterne, Funtane i epilitske jedinke s lokacije Šćuza 1 (Slika 19).

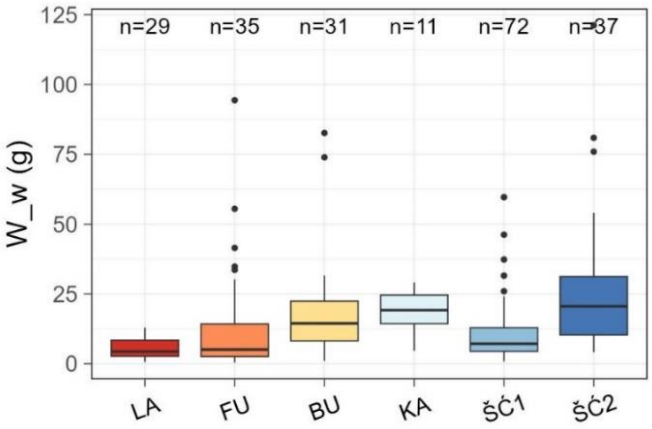


Slika 19. Usporedba biomase vrste *Gongolaria barbata* sa šest lokacija uzorkovanja (uzorci prikupljeni 2021. i 2023. godine). Lokacije: LA – Lanterna, FU – Funtana, BU – Bijela uvala, KA – Kamenjak, ŠĆ1 – Šćuza 1 i ŠĆ2 – Šćuza 2.

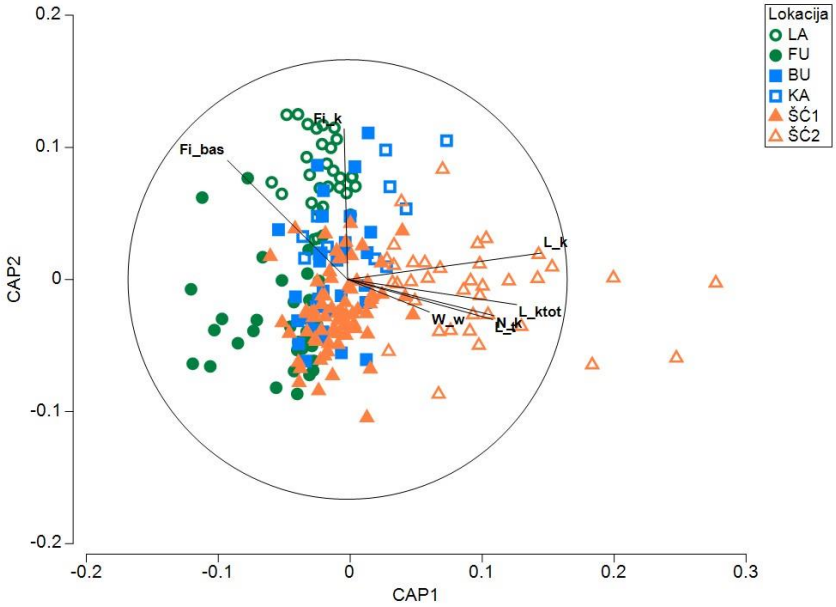


Slika 20. Kanonička analiza glavnih koordinata (CAP) za morfometrijske karakteristike (ukupna duljina kauloida - L_ktot; duljina talusa - L_t; duljina kauloida - L_k; promjer kauloida - Fi_k; promjer bazalne pločice – Fi_bas; broj kauloida - N_k) i biomasu (W_w) jedinki *Gongolaria barbata* na različitim lokacijama (LA - Lanterna, FU - Funtana, BU - Bijela uvala, KA - Kamenjak, ŠĆ1 - Šćuza 1, ŠĆ2 - Šćuza 2). Uzorci su prikupljeni tijekom 2021. i 2023. godine.

CAP graf prikazuje distribuciju jedinki s različitih lokacija na temelju njihovih morfometrijskih karakteristika i biomase. Prva kanonička os (CAP1) objašnjava najveći dio varijacije između uzoraka (67,38%), dok druga os (CAP2) obuhvaća dodatnih 53,39% varijacije. Ovi rezultati ukazuju na značajnu varijabilnost morfometrijskih karakteristika vrste *G. barbata* između različitih lokacija, pri čemu se posebno ističe lokacija Šćuza 2 s višim vrijednostima u većini izmjerenih parametara (Slika 20). Statistička značajnost tih razlika potvrđena je permutacijskim testom ($p < 0,0001$).

### 5.1.2. Povijesni i recentni podaci morfometrijskih karakteristika

Promjene u morfometrijskim karakteristikama vrste *Gongolaria barbata* na dugoročnoj vremenskoj skali analizirane su usporedbom morfometrijskih podataka prikupljenih na lokacijama Lanterna i Funtana tijekom 2009. i 2023. godine. Ova analiza omogućuje uvid u promjene koje su se dogodile tijekom 14-godišnjeg razdoblja, pružajući vrijedne informacije o dugoročnim trendovima u morfometrijskim karakteristikama ove vrste na navedenim lokacijama.

Prikaz usporedbe pojedinih varijabli (ukupna duljina kauloida, duljina kauloida, duljina talusa, broj kauloida, promjer kauloida) pruža nam uvid u detaljne razlike pojedinih lokacija po godinama uzorkovanja. Iako je broj uzoraka za lokaciju Lanterna bio znatno manji 2023. u usporedbi s 2009. godinom (vidi Materijali i metode), jasno je vidljivo da recentno uzorkovanje nije obuhvatilo sljedeće veličinske klase ukupne duljine kauloida: 40-50 cm, 50-60 cm, 60-70 cm, 80-90 cm i klasu iznad 100 cm (Slika 21A). Većina jedinki uzorkovanih 2009. godine spadala je pod veličinske klase od 0-10 cm i 10-20 cm, što se također podudara s uzorkovanjem iz 2023. gdje većina jedinki spada u klase od 0 do 20 cm. Sličan trend uočen je i kod jedinki u Funtani. Nedostaju klase ukupne duljine kauloida od 30 do 60 cm, 70-80 cm i klase iznad 100 cm (Slika 22A). Većina jedinki u obje istraživane godine, 2009. i 2023. godine, pripada klasama od 0 do 20 cm, dok su rijetke jedinke zabilježene u većim veličinskim klasama 2023., što nije bio slučaj s jedinkama uzorkovanim 2009. godine (Slika 21A i Slika 22A).

Što se tiče veličinskih klasa duljine kauloida na lokacijama Lanterna i Funtana u 2009. godini, većina jedinki pripadala je veličinskim klasama unutar raspona od 0 do 15 cm. Jedinke uzorkovane 2023. godine na lokaciji Lanterna također su spadale u navedene klase, međutim, uočena je gotovo zanemariva zastupljenost klase 15-20 cm te potpuna odsutnost klase 20-25 cm (Slika 21B). U Funtani, jedinke zabilježene 2009. godine se pojavljuju čak i u veličinskim klasama od 25 do 35

cm. Međutim, recentno uzorkovanje iz 2023. godine pokazuje potpunu odsutnost jedinki koje bi pripadale klasama većim od 10 cm (Slika 22B).

Većina jedinki na lokaciji Lanterna u 2009. spadala je u veličinske klase talusa od 10 do 40 cm, uz značajnu frakciju jedinki unutar klase do 50 cm. Nasuprot tome, jedinke uzorkovane 2023. godine na istoj lokaciji pojavljuju se isključivo u rasponu od 0 do 20 cm (Slika 21C). Sličan trend uočen je i na lokaciji Funtana, gdje su pojedine jedinke 2009. godine dosezale veličinske frakcije od 50 do 60 cm, dok su gotovo sve recentno prikupljene jedinke iz 2023. godine bile ograničene na veličinsku klasu od 0 do 20 cm (Slika 22C).

Što se tiče broja kauloida, većina jedinki uzorkovanih na obje lokacije i u obje godine, pokazuje sličan trend i spada u skupinu od 1 do 4 kauloida (Slika 21D i Slika 22D). Pojedine jedinke bile su zabilježene u frakcijama od 4 do 8 kauloida ili od 8 do 12 kauloida. U 2009. godini jedinke na lokaciji Lanterna rijetko su se pojavljivale u frakcijama do 36 kauloida (Slika 21D), dok su jedinke u Funtani dosezale frakciju do 24 kauloida (Slika 22D). Nasuprot tome, jedinke uzorkovane 2023. godine na lokaciji Lanterna pokazuju potpunu odsutnost klase iznad 8 kauloida, dok jedinke u Funtani iste godine pokazuju potpunu odsutnost frakcije iznad 16 kauloida (Slika 21D i Slika 22D).

Zanimljivo je da se kod promjera kauloida na lokaciji Lanterna 2023. godine odsutne najmanje veličinske frakcije, dok su se pojavile pojedine jedinke u klasi od 0,6 do 0,7 cm, koja je bila potpuno odsutna 2009. godine (Slika 21E). U slučaju lokacije Funtana, gotovo da nije bilo razlike u promjeru kauloida između 2009. i 2023. godine (Slika 22E).

CAP analiza i grafički prikaz odvajaju pojedine lokacije i godine u zasebne grupe. Prva kanonička os (CAP1) obuhvaća najveći dio varijacije između uzoraka (59,05%), dok druga os (CAP2) dodatno objašnjava 27,91% varijacije. Vidljivo je značajno preklapanje velikog dijela uzoraka jedinki prikupljenih godine 2009. na lokacijama Lanterna i Funtana, ali se za iste lokacije također ističe zasebno grupiranje jedinki prikupljenih 2023. na lokaciji Lanterna, i jedinki prikupljenih za isto razdoblje na lokaciji Funtana (Slika 23). Jedinke prikupljene na lokaciji Funtana 2023. djelomično se preklapaju s jedinkama u 2009. na lokacijama Lanterna i Funtana, međutim u svom većem dijelu formiraju zasebnu grupu. Jedinke prikupljene na lokaciji Lanterna 2023. godine pak tvore zasebnu grupu, gotovo bez preklapanja s tri ostale grupe (LA09, FU09 i FU23). Statistička značajnost tih razlika potvrđena je permutacijskim testom ($p < 0,0001$).

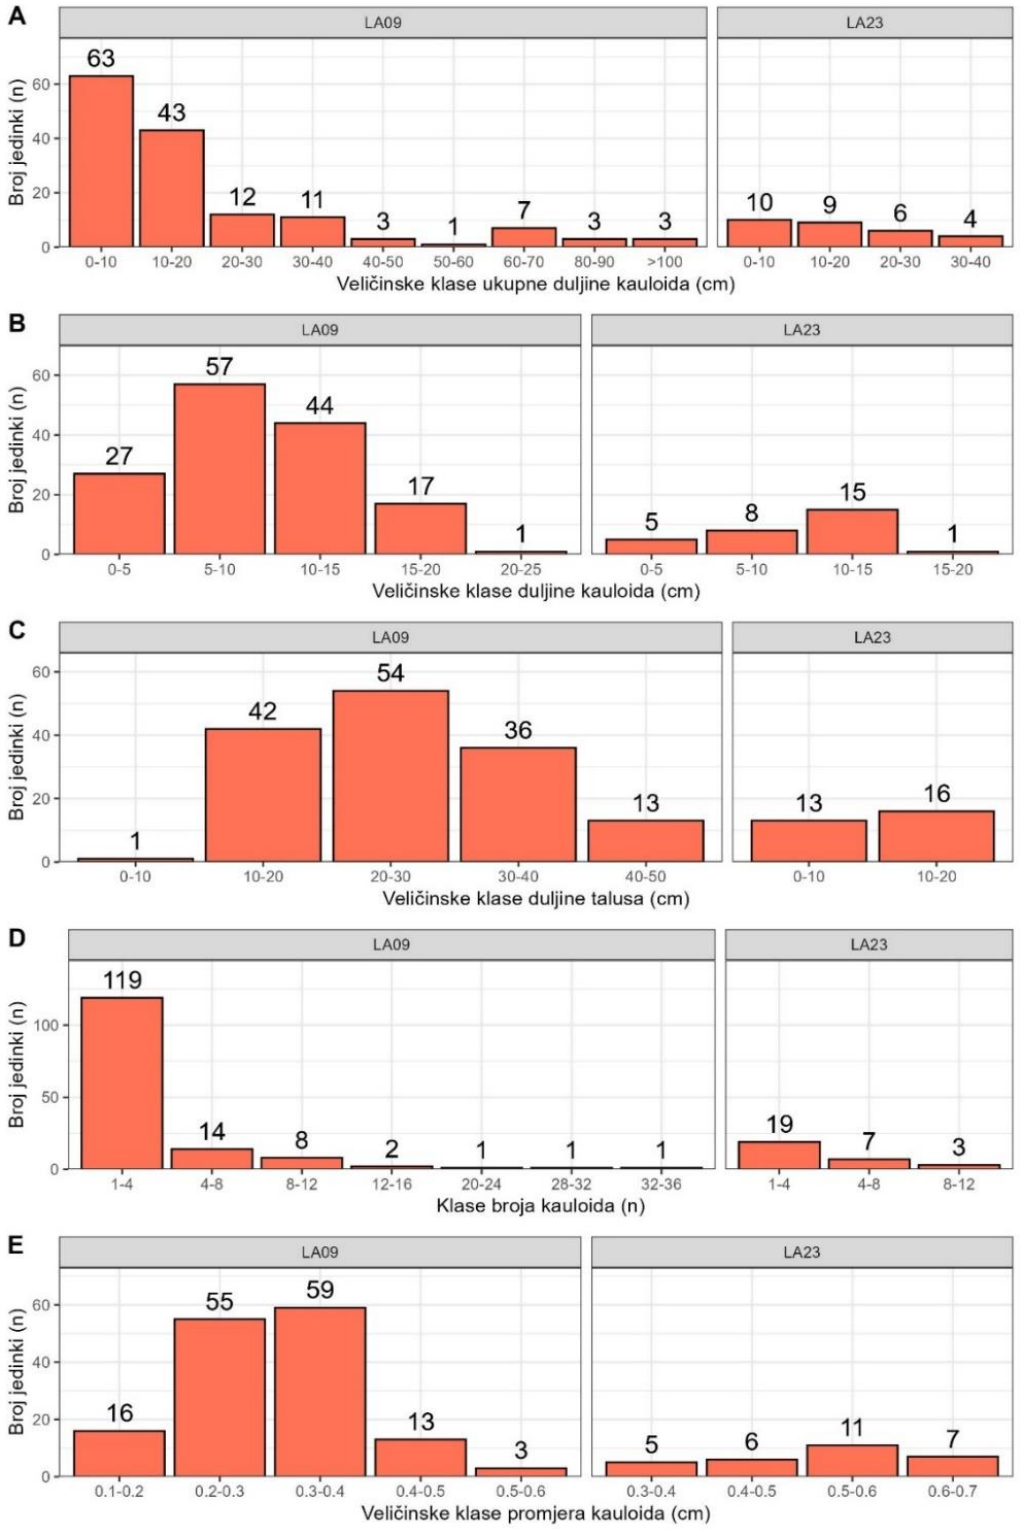


Slika 21. Usporedba klasa pojedinih morfometrijskih karakteristika jedinki *Gongolaria barbata* za lokaciju Lanterna (2009. i 2023. godine). Karakteristike: ukupna duljina kauloida (A), duljina kauloida (B), duljina talusa (C), broj kauloida (D) i promjer kauloida (E). Lokacija i godina: LA09 – Lanterna 2009., LA23 – Lanterna 2023.

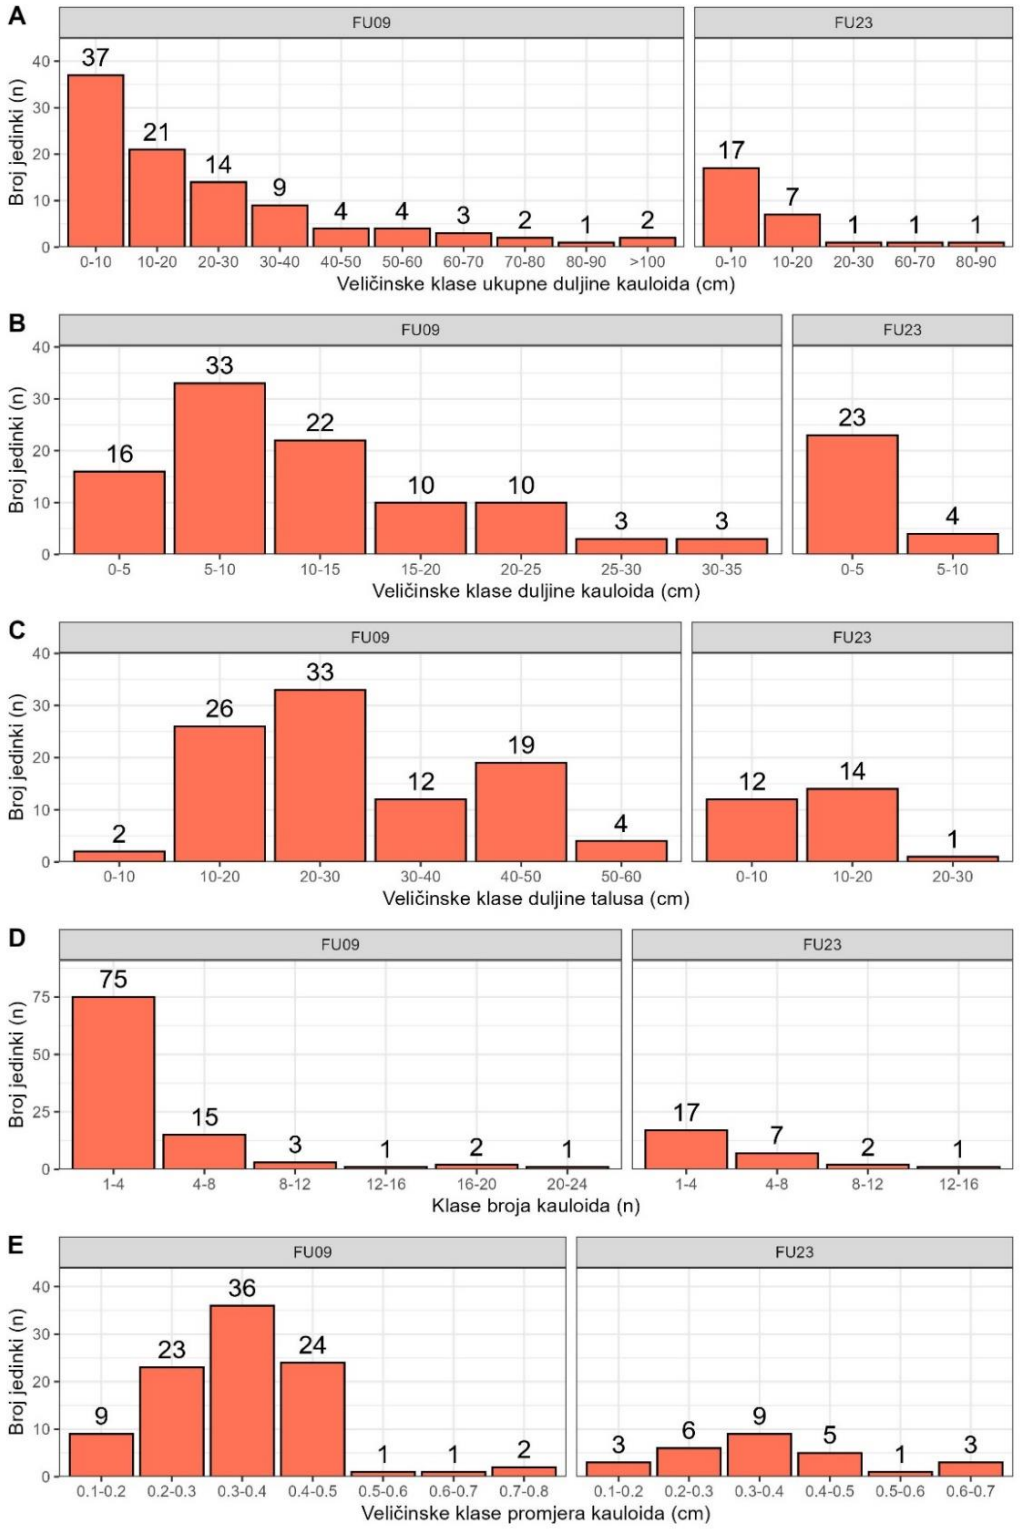


Slika 22. Usporedba klasa pojedinih morfometrijskih karakteristika jedinki *Gongolaria barbata* za lokaciju Funtana (2009. i 2023. godine). Karakteristike: ukupna duljina kauloida (A), duljina kauloida (B), duljina talusa (C), broj kauloida (D) i promjer kauloida (E). Lokacija i godina: FU09 – Funtana 2009., FU23 – Funtana 2023.

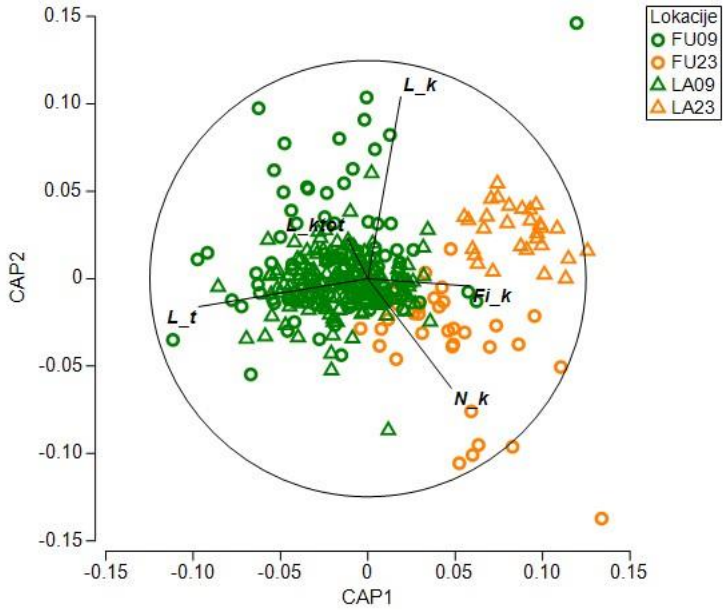


Slika 23. Kanonička analiza glavnih koordinata (CAP) za morfometrijske karakteristike (ukupna duljina kauloida - L_ktot, duljina talusa - L_t, duljina kauloida - L_k, promjer kauloida - Fi_k i broj kauloida - N_k) jedinki *Gongolaria barbata* s dvije lokacije, Lanterna (LA) i Funtana (FU), u dva vremenska razdoblja: 2009. (LA09, FU09) i 2023. godine (LA23, FU23).

### 5.1.3. Alometrija vrste *Gongolaria barbata*

#### 5.1.3.1. Analiza prediktivnih modela mokre biomase na istraženim lokacijama

Kako bi se procijenila mogućnost izrade modela za predikciju mokre biomase (W_w) vrste *Gongolaria barbata* koji su specifični za pojedinu lokaciju, analizirani su univarijatni i multivarijatni modeli koji uključuju različite kombinacije morfometrijskih karakteristika. Podaci se temelje na mjerenjima izvršenim u razdoblju od 2021. do 2023. na jedinkama s lokacija Lanterna, Funtana, Bijela uvala, Kamenjak i Šćuza.

Modeli predikcije specifični za lokacije Šćuza 1 i Šćuza 2 u 11 od 15 modela objašnjavaju preko 80% varijacije mokre biomase (W_w) (Prilog Tablica P2; Tablica P3). Za obje lokacije, najbolji univarijatni model bio je onaj koji uključuje varijablu „ukupna duljina kauloida“ (L_ktot) (Slika 24A i slika 26A) i koja objašnjava gotovo 90% varijacije mokre biomase (Prilog Tablica P2; Tablica P3). Ostali univarijantni modeli za lokaciju Šćuza 1 pokazali su jako niske vrijednosti $R^2$ ($R^2$ (N_k) = 68%, $R^2$ (L_k) = 45%, $R^2$ (L_t) = 41%) (Slika 24B, C, D). Univarijantni modeli za

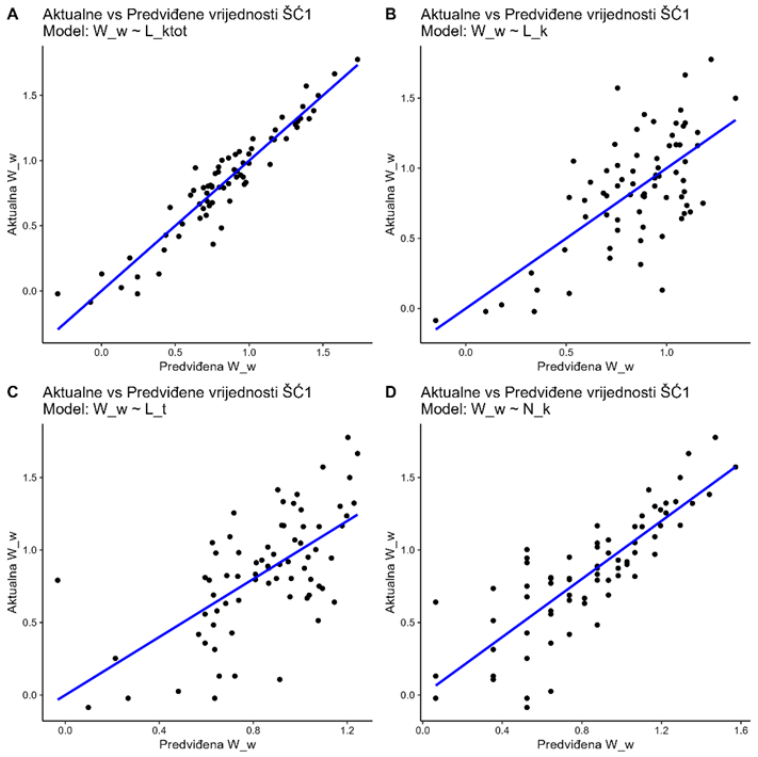


Slika 24. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za univarijatne modele predikcije za lokaciju Šćuza 1: model koji uključuje ukupnu duljinu kauloida – L_ktot (A), model koji uključuje duljinu kauloida – L_k (B), model koji uključuje duljinu talusa – L_t (C) i model koji uključuje broj kauloida – N_k (D).

lokaciju Šćuza 2 su također pokazali niske $R^2$ vrijednosti i generalno su pri dnu učinkovitosti modela ($R^2$ (N_k) = 77%, R2 (L_k) = 46%, $R^2$ (L_t) = 43%) (Slika 26B, C, D). Za lokaciju Šćuza 1, najbolji modeli prema kriteriju AICc i koeficijentu determinacije ($R^2$) su: W_w ~ L_ktot + L_t + N_k ΔAICc: -98,792997 $R^2$: 0,9189226; W_w ~ L_ktot + L_k + L_t ΔAICc: -98,785661 $R^2$: 0,9189144; W_w ~ L_ktot + L_t ΔAICc: -98.084468 $R^2$: 0,9167529 (Prilog Tablica P2; Slika 25A, B). Za oblik Šćuza 2, najbolji modeli su: W_w ~ L_ktot + L_k ΔAICc: -57,393904 $R^2$: 0,9118692; W_w ~ L_ktot + L_t ΔAICc: -57,162501 $R^2$: 0,9113163; W_w ~ L_ktot ΔAICc: -56,569097 $R^2$: 0,9092483 (Prilog Tablica P3; Slika 27A, B). Ovi modeli također pokazuju visoku moć predikcije, međutim iz navedenog je vidljivo da ukupna duljina kauloida (L_ktot) igra ključnu ulogu u objašnjavanju mokre biomase, budući da univarijatni model koji uključuje varijablu L_ktot objašnjava samo 1-2% manje varijacije u biomasi nego najbolji multivarijatni modeli za lokaciju

Šćuza 1, dok za lokaciju Šćuza 2 gotovo da i nema razlike između najboljeg multivarijatnog modela i univarijatnog modela koji uključuje varijablu L_ktot.

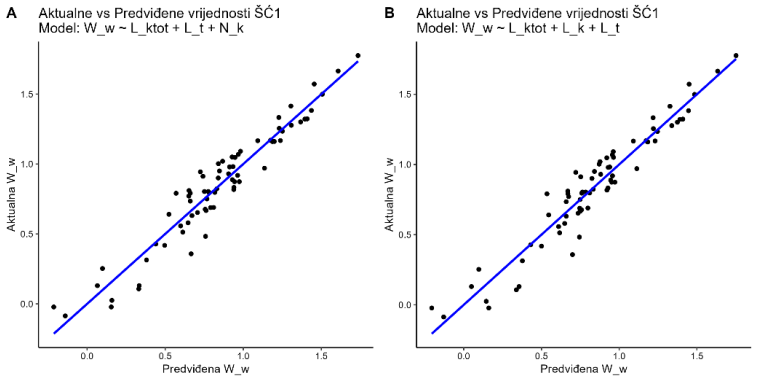


Slika 25. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za dva visokorangirana multivarijatna modela predikcije za lokaciju Šćuza 1: model koji uključuje ukupnu duljinu kauloida – L_ktot, duljinu talusa – L_t i broj kauloida – N_k (A) i model koji uključuje ukupnu duljinu kauloida – L_ktot, duljinu kauloida – L_k i duljinu talusa – L_t (B).

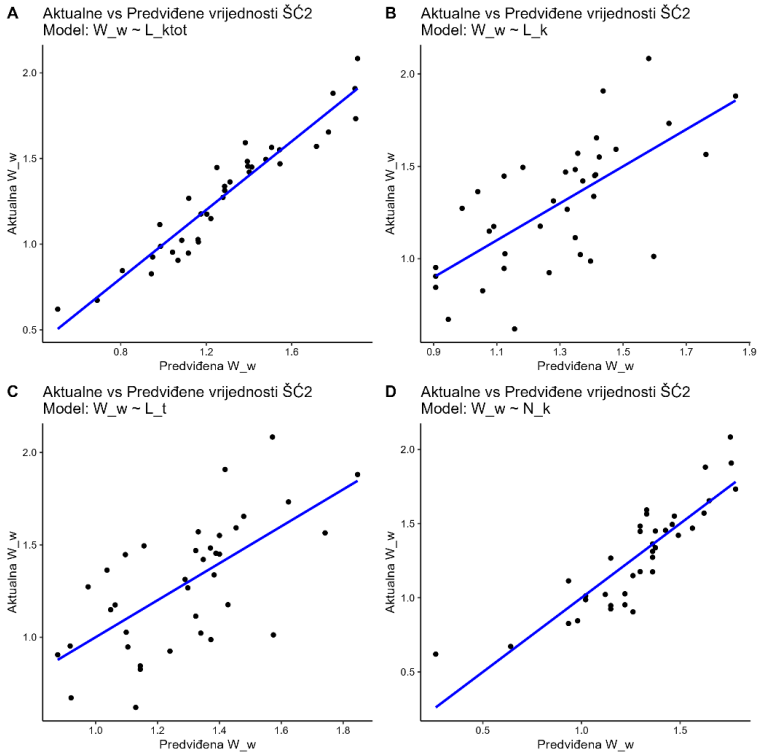


Slika 26. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za univarijatne modele predikcije za lokaciju Šćuza 2: model koji uključuje ukupnu duljinu kauloida – L_ktot (A), model koji uključuje duljinu kauloida – L_k (B), model koji uključuje duljinu talusa – L_t (C) i model koji uključuje broj kauloida – N_k (D).

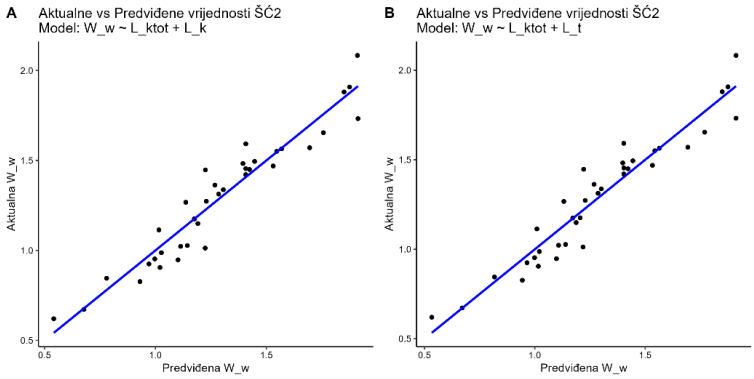


Slika 27. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za dva visokorangirana multivarijatna modela predikcije za lokaciju Šćuza 2: model koji uključuje ukupnu duljinu kauloida – L_ktot i duljinu kauloida – L_k (A) i model koji uključuje ukupnu duljinu kauloida – L_ktot i duljinu talusa – L_t (B).

Modeli predikcije specifični za lokaciju Bijela uvala samo u 4 od 15 slučajeva objašnjavaju više od 80% varijacije u mokroj biomasi (Prilog Tablica P4). Najbolji univarijatni model koji uključuje varijablu N_k objašnjava tek 72% varijacije u mokroj biomasi, dok ostali univarijatni modeli pokazuju puno niže vrijednosti ($R^2$ (L_ktot) = 68%, $R^2$ (L_k) = 51%, $R^2$ (L_t) = 48%) (Slika 28A, B, C, D).

Za lokaciju Bijela uvala, najbolji modeli su: W_w ~ L_t + N_k ΔAICc: -17,882439 R2: 0,8486283; W_w ~ L_ktot + L_t + N_k ΔAICc: -15,399172 $R^2$: 0,8438619; W_w ~ L_k + L_t + N_k ΔAICc: -15,276677 $R^2$: 0,8432437 (Prilog Tablica P4; Slika 29A, B). Najbolji multivarijatni model za lokaciju Bijela uvala objašnjava čak 12% više varijacije u mokroj biomasi od najboljeg univarijatnog modela (N_k).

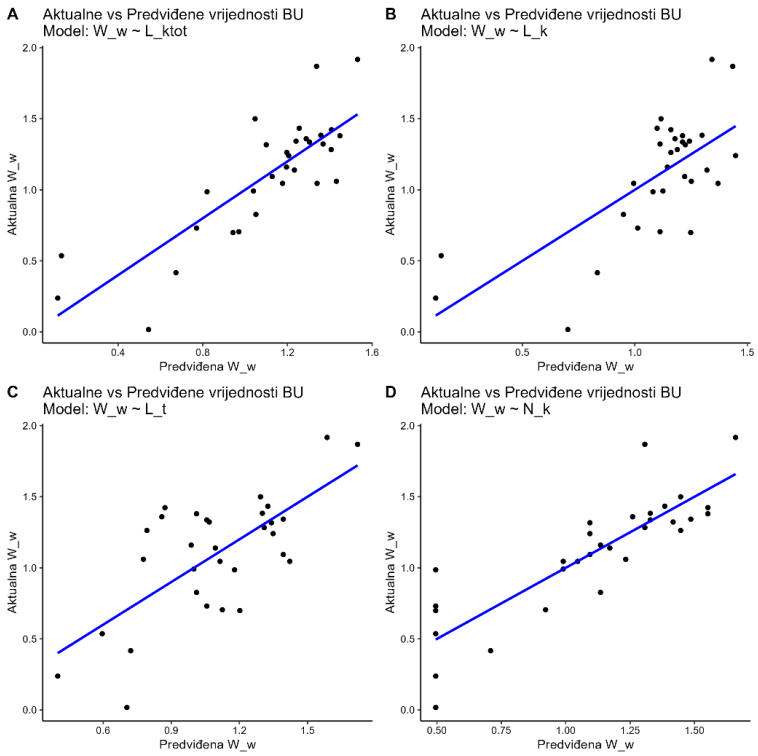


Slika 28. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za univarijatne modele predikcije za lokaciju Bijela uvala: model koji uključuje ukupnu duljinu kauloida – L_ktot (A), model koji uključuje duljinu kauloida – L_k (B), model koji uključuje duljinu talusa – L_t (C) i model koji uključuje broj kauloida – N_k (D).

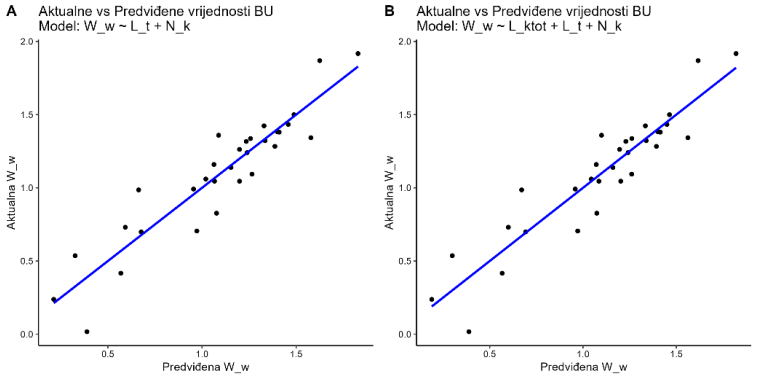


Slika 29. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za dva visokorangirana multivarijatna modela predikcije za lokaciju Bijela uvala: model koji uključuje duljinu talusa – L_t i broj kauloida – N_k (A) i model koji uključuje ukupnu duljinu kauloida – L_ktot, duljinu talusa – L_t i broj kauloida – N_k (B).

Osam od 15 modela za lokaciju Funtana objašnjavaju preko 80% varijacije u mokroj biomasi (Prilog Tablica P5). Model koji najbolje objašnjava varijaciju mokre biomase je univarijatni model koji uključuje varijablu L_ktot ($R^2$ = 90%) (Slika 30A). Ostali univarijatni modeli za lokaciju Funtana su gotovo pri dnu liste generiranih modela ($R^2$ (L_t) = 66%, $R^2$ (N_k) = 64%, $R^2$ (L_k) = 35%) (Prilog Tablica P5; Slika 30B, C, D). Najbolji multivarijatni modeli imaju mogućnost predikcije usporedivu s najboljim modelom koji uključuje ukupnu duljinu kauloida (Slika 31A, B).

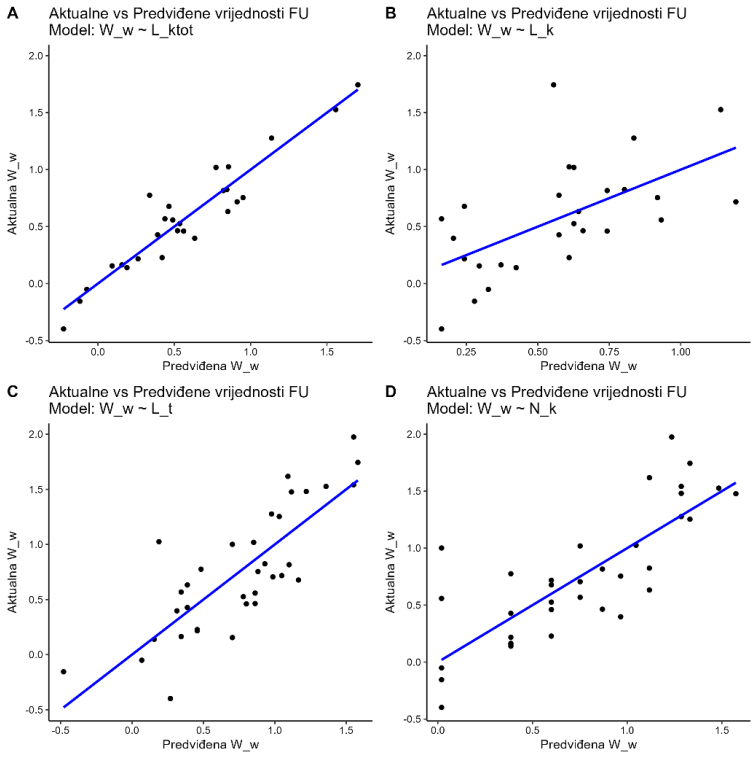


Slika 30. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za univarijatne modele predikcije za lokaciju Funtana: model koji uključuje ukupnu duljinu kauloida – L_ktot (A), model koji uključuje duljinu kauloida – L_k (B), model koji uključuje duljinu talusa – L_t (C) i model koji uključuje broj kauloida – N_k (D).

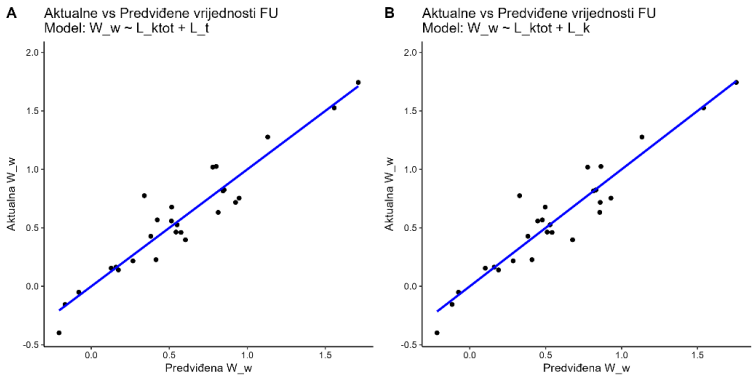


Slika 31. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za dva visokorangirana multivarijatna modela predikcije za lokaciju Funtana: model koji uključuje ukupnu duljinu kauloida – L_ktot i duljinu talusa – L_t (A) i model koji uključuje ukupnu duljinu kauloida – L_ktot i duljinu kauloida – L_k (B).

Najbolji model za lokaciju Kamenjak pokazuje tek 66% varijacije mokre biomase (uključuje varijablu N_k), dok ostali univarijatni modeli pokazuju 46% (L_ktot), 22% (L_t) i 13% (L_k) varijacije (Prilog Tablica P6; Slika 32A, B, C, D). Najbolji multivarijatni modeli za lokaciju Kamenjak hijerarhijski se nalaze ispod najboljeg univarijatnog modela koji uključuje varijablu N_k (Prilog Tablica P6; Slika 33A, B).

Za lokaciju Lanterna univarijatni modeli opisuju tek 54% (N_k), 52% (L_ktot), 31% (L_k) i 31% (L_t) varijacije u mokroj biomasi (Prilog Tablica P7; Slika 34A, B, C, D). Najboljim modelima, pokazali su se multivarijatni modeli koji također opisuju samo 55% varijacije u mokroj biomasi, što su iznimno niske vrijednosti $R^2$ (Prilog Tablica P7; Slika 35A, B). Ti modeli uključuju varijable L_ktot, L_k i N_k.

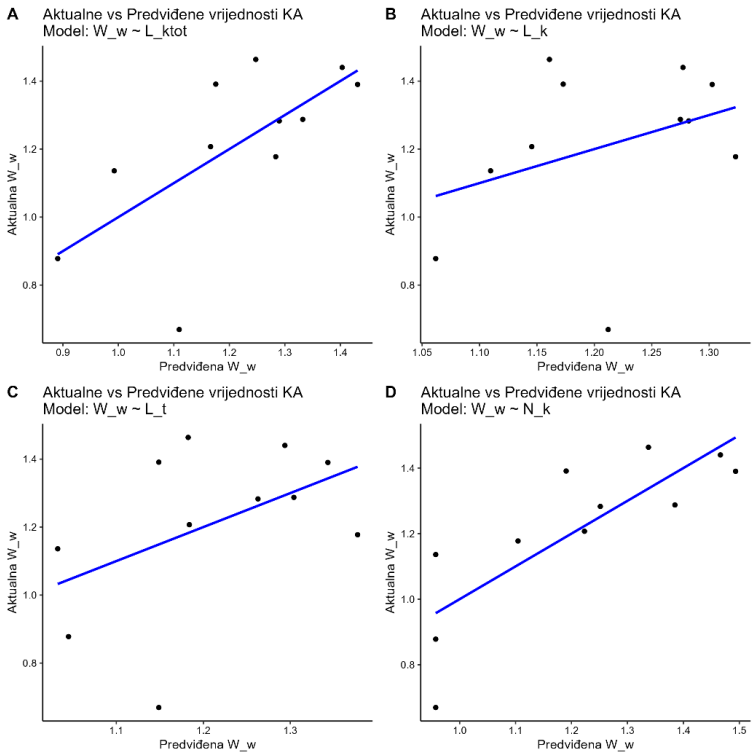


Slika 32. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za univarijatne modele predikcije za lokaciju Kamenjak: model koji uključuje ukupnu duljinu kauloida – L_ktot (A), model koji uključuje duljinu kauloida – L_k (B), model koji uključuje duljinu talusa – L_t (C) i model koji uključuje broj kauloida – N_k (D).

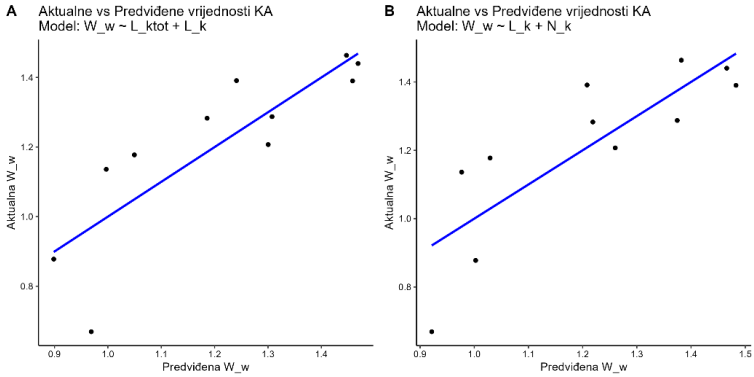


Slika 33. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za dva visoko rangirana multivarijatna modela predikcije za lokaciju Kamenjak: model koji uključuje ukupnu duljinu kauloida – L_ktot i duljinu kauloida – L_k (A) i model koji uključuje ukupnu duljinu kauloida – L_ktot i broj kauloida – N_k (B).

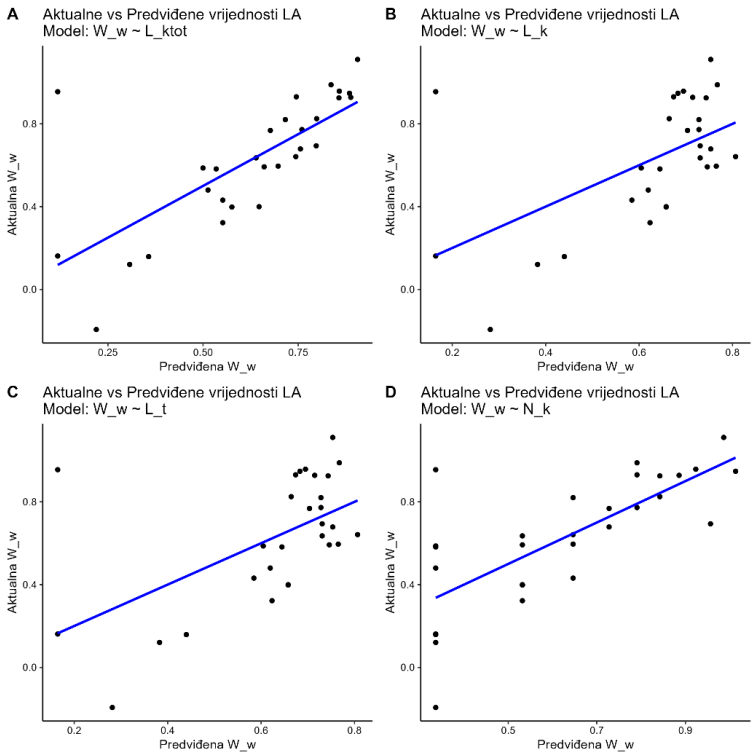


Slika 34. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za univarijatne modele predikcije za lokaciju Lanterna: model koji uključuje ukupnu duljinu kauloida – L_ktot (A), model koji uključuje duljinu kauloida – L_k (B), model koji uključuje duljinu talusa – L_t (C) i model koji uključuje broj kauloida – N_k (D).

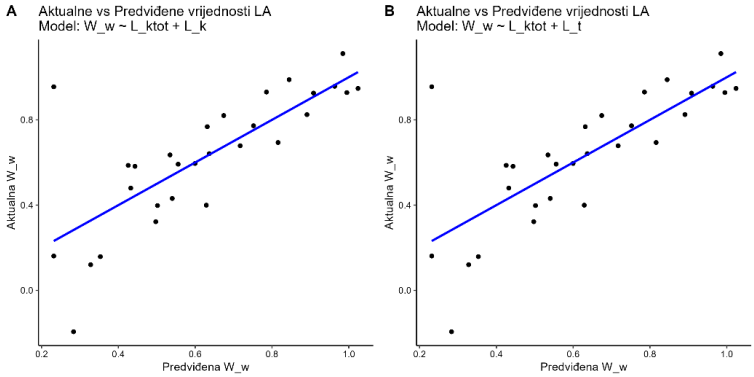


Slika 35. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za dva visoko rangirana multivarijatna modela predikcije za lokaciju Lanterna: model koji uključuje ukupnu duljinu kauloida – L_ktot i broj kauloida – N_k (A) i model koji uključuje ukupnu duljinu kauloida – L_ktot i duljinu talusa – L_t (B).

#### 5.1.3.2. Analiza općih prediktivnih modela mokre biomase

Kako bi se procijenila mogućnost izrade općih modela za predikciju mokre biomase (W_w) vrste *Gongolaria barbata*, analizirani su modeli koji uključuju interakcije između prediktorskih varijabli i faktora Lokacija. Cilj je bio utvrditi može li se izraditi opći model predikcije biomase, te je li on generalno bolji od modela koji uključuju faktor Lokacija (modela koji uzimaju u obzir pojedine lokacije).

Gotovo 20 od 45 modela objašnjava preko 80% varijacije u biomasi (Prilog Tablica P8). Svih 20 modela, uključuju faktor Lokacija kao aditivnu varijablu ili kao interakcijsku varijablu, dok prvi najbolji model koji ni na koji načine ne sadržava faktor Lokacija opisuje tek 79% varijacije u biomasi (Prilog Tablica P8).

Usporedbom svih modela, može se zaključiti da su modeli koji uključuju faktor Lokacija pokazali najbolje AICc i $R^2$ vrijednosti, te se značajno razlikuju od modela koji ne uključuju navedeni faktor. Primjerice, ako uspoređujemo model W_w ~ L_ktot * Lokacija + N_k * Lokacija + L_t * Lokacija (AICc = -172,743570, $R^2$ = 0,8982677) on značajno bolji od modela W_w ~ L_ktot+L_k+N_k+L_t + Lokacija (AICc = -112,814025, $R^2$ = 0,8513544), i opisuje gotovo 5% više varijacije, te je također značajno bolji od modela koji potpuno isključuje faktor Lokacija W_w ~ L_ktot + N_k + L_t (AICc = -44,061133, $R^2$ = 0,7858297) te opisuje gotovo 11% više varijacije u mokroj biomasi (Prilog Tablica P8; Slika 37A, B). Ovi rezultati sugeriraju da su ove varijable zajedno s faktorom Lokacija ključne za izradu modela za predikciju mokre biomase.

Od univarijatnih modela koji ne sadržavaju faktor Lokacija, najboljim se pokazao model koji sadržava varijablu L_ktot (AICc = 7,879278, $R^2$ = 0,7218719). Dakle objašnjava 72% varijacije u mokroj biomasi, što ukazuje na najveći utjecaj navedene varijable na varijablu W_w, u kombinaciji s faktorom Lokacija. Ostali univarijatni modeli objašnjavaju po 4% (N_k), 22% (L_t) i 28% (L_k) manje varijacije u mokroj biomasi od modela koji uključuje L_ktot (Prilog Tablica P8; Slika 36A, B, C, D).

Generalno, modeli koji uključuju cijeli set podataka, pokazivali su niže vrijednosti predikcije od onih koji uključuju faktor Lokacija.

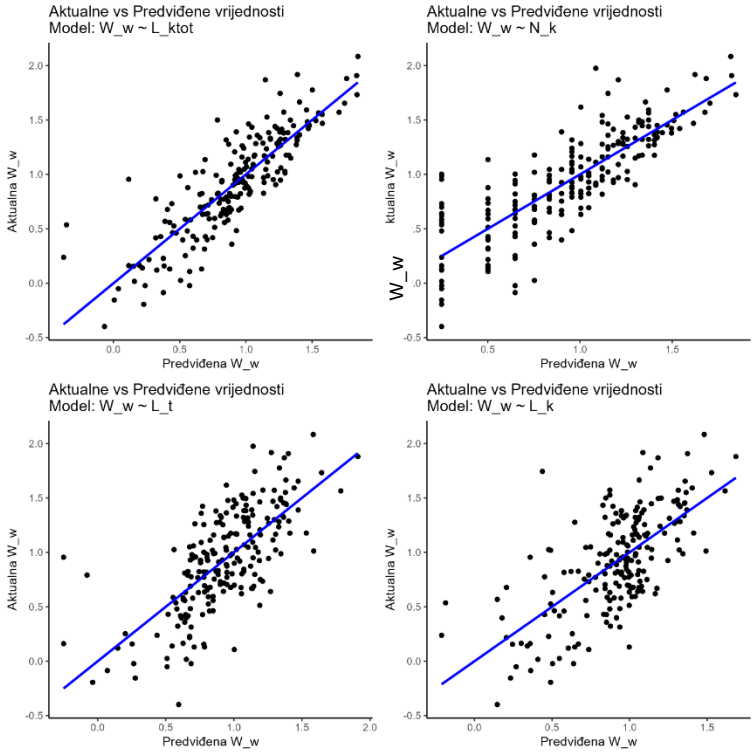


Slika 36. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za opće univarijatne modele predikcije: model koji uključuje ukupnu duljinu kauloida – L_ktot (A), model koji uključuje broj kauloida – N_k (B), model koji uključuje duljinu talusa – L_t (C) i model koji uključuje duljinu kauloida – L_k (D).

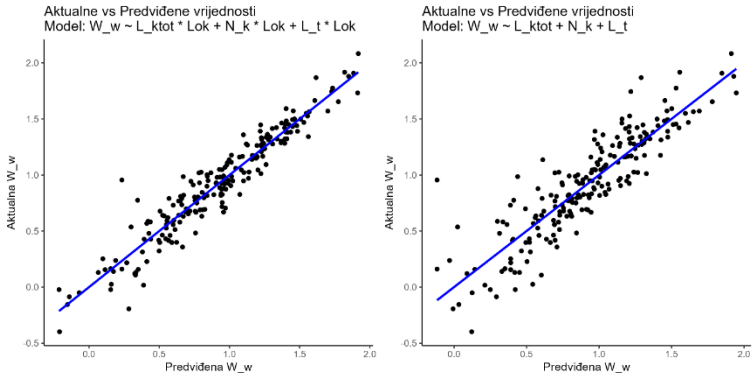


Slika 37. Grafički prikazi aktualnih i predviđenih vrijednosti biomase za najviše rangirani multivarijatni model koji uključuje interakciju s faktorom Lokacija (A) i opći model koji uključuje iste varijable, ali bez interakcije s faktorom Lokacija (B).

5.1.3.3. Alometrija povijesnih podataka

Kako bi se procijenila mogućnost izrade modela za predikciju ukupne mokre biomase u kvadratu (Tot_WW) vrste *Gongolaria barbata* u plitkim staništima zapadne obale Istre, analizirani su univarijatni i multivarijatni modeli koji uključuju sumirane vrijednosti pojedinih morfometrijskih karakteristika i karakteristika biomase (na razini 34 uzoraka kvadrata).

Gotovo 24 od ukupno 31 modela (univarijatnih ili multivarijatnih), pokazuje mogućnost objašnjavanja varijacije u mokroj biomasi od više od 90%. Od navedenih, 16 ih objašnjava varijaciju u mokroj biomasi od preko 99%. Iz rezultata je vidljivo da gotovo svi multivarijatni i onaj univarijatni koji uključuju varijablu Grane objašnjavaju preko 99% varijacije u mokroj biomasi (Prilog Tablica P9; Slika 38A; Slika 39A, B).

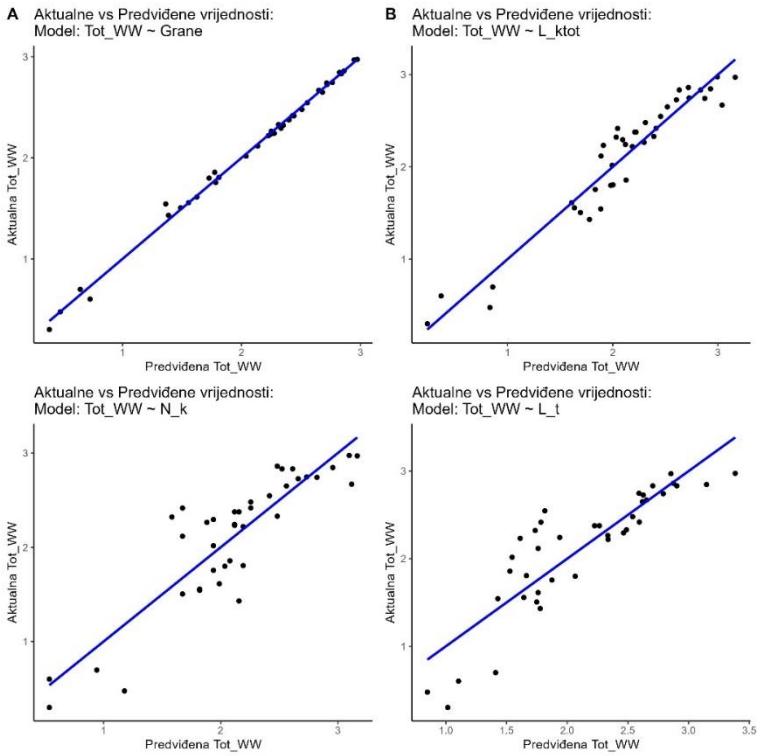


Slika 38. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za univarijatne modele predikcije na razini kvadrata: model koji uključuje biomasu grana - Grane (A), model koji uključuje ukupnu duljinu kauloida – L_ktot (B), model koji uključuje broj kauloida – N_k (C) i model koji uključuje duljinu talusa – L_t (D).

Najbolji multivarijatni model (Tot_WW ~ L_ktot + Grane + N_k) objašnjava gotovo 99,85% varijacije u mokroj biomasi, dok najbolji univarijatni model (Tot_WW ~ Grane) objašnjava tek 0.3% manje varijacije (99,55%) (Prilog Tablica P9). Unatoč tome što je multivarijatni model prema AICc uvjetu pokazao bolje značajke za predikciju (AICc (L_ktot + Grane + N_k) = -164,026064, AICc (Grane) = -122,295083), minimalna razlika u $R^2$ vrijednosti ukazuje na visoku značajnost varijable Grane u predikciji mokre biomase na razini kvadrata.

Od ostalih univarijatnih modela, model koji uključuje samo varijablu L_ktot objašnjava 92% varijacije u mokroj biomasi, model koji uključuje varijablu N_k objašnjava 78% varijacije, model koji uključuje varijablu L_t objašnjava 76% varijacije, te općenito najgore rangiran model koji uključuje varijablu N_axes objašnjava tek 43% varijacije u mokroj biomasi (Prilog Tablica P9; Slika 38A, B, C, D).

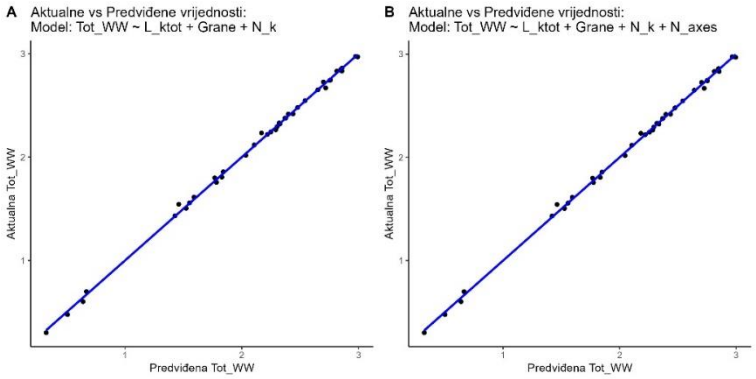


Slika 39. Grafički prikaz aktualnih i predviđenih vrijednosti biomase za dva visokorangirana multivarijatna modela predikcije na razini kvadrata: model koji uključuje ukupnu duljinu kauloida – L_ktot, biomasu grana - Grane i broj kauloida – N_k (A) i model koji uključuje ukupnu duljinu kauloida – L_ktot, biomasu grana - Grane, broj kauloida – N_k i broj jedinki – N_axes (B).

Nadalje, osim same izrade i testiranja modela, izvršen je i eksperiment ponovnog uzorkovanja u svrhu određivanja minimalnog broja uzoraka za izradu učinkovitog modela predikcije biomase na razini kvadrata (u obzir je uzet univarijatni model Tot_WW~Grane). Rezultati eksperimenta ponovnog uzorkovanja pokazali su da je izrada univarijatnog modela sa sličnim karakteristikama kao što je onaj model koji uključuje samo varijablu Grane moguća s brojem uzoraka od 12 do 15 kvadrata (Slika 40A, B).

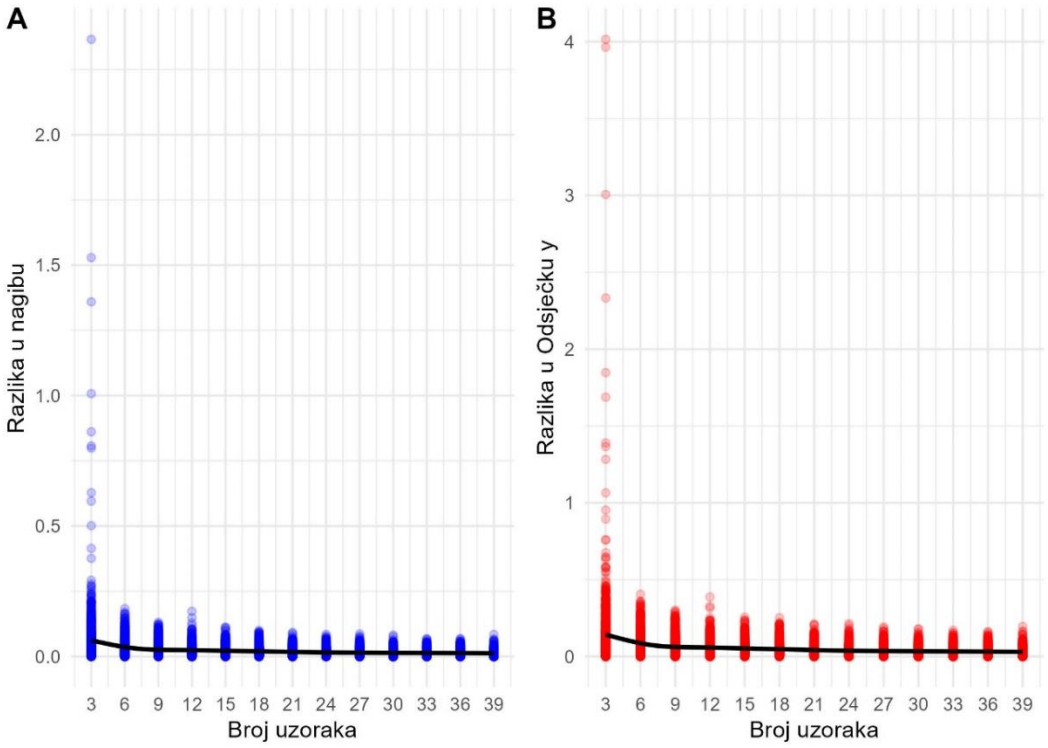


Slika 40. Grafički prikaz rezultata ekperimenta ponovnog uzorkovanja gdje je prikazano odstupanje koeficijenta nagiba i koeficijenta odsječka na osi y pri izradi univarijatnog modela (Tot_WW~Grane) s brojem uzoraka u rasponu od 3 do 39 (broj kvadrata).

## 5.3. Termotolerancija

### 5.3.1. Temperaturni uvjeti površinskog sloja u laguni Šćuza

Laguna Šćuza izložena je vrlo hladnim zimama i vrlo toplim ljetima. Temperature površinskog sloja mora mogu pasti ispod 0 °C u zimskom razdoblju, pri čemu dolazi do zamrzavanja dijela lagune, pogotovo onog dijela gdje se nalazi dobro razvijena populacija vrste *Gongolaria barbata* koja tijekom zimskih mjeseci zna imati plodne receptakule. Ljeti temperature redovito prelaze vrijednosti od 34 °C.

U 2020. godini temperatura je premašila 28 °C ukupno 51 dan, 30 °C 27 dana, 32 °C 6 dana i 34 °C 2 dana (Slika 41). Najduže razdoblje temperature iznad 28 °C trajalo je 42 dana (20.06. – 30.08.; Slika 42A). Također, najduže razdoblje temperature iznad 30 °C trajalo je 11 dana (07.08. – 17.08.; Slika 42B). Temperatura je premašila 32 °C najviše 6 dana (27.06. – 2.07.; Slika 42C). Naposljetku, najduže razdoblje s temperaturom iznad 34 °C bilo je 2 dana (31.07. – 01.08.; Slika 42D). U 2021.

godini temperatura je premašila 28 °C ukupno 76 dana, 30 °C 56 dana, 32 °C 35 dana i 34 °C 6 dana (Slika 41). Najduže razdoblje temperature iznad 28 °C trajalo je uzastopno 45 dana (01.06 – 15.07.; Slika 42E). Nadalje, temperatura je ostala iznad 30 °C 27 dana (16.06. – 12.07.; Slika 42F). Dodatno, temperatura je premašila 32 °C 18 dana (30.07. – 16.08.; Slika 42G). Premašivanje temperature od 34 °C zabilježeno je po jedan dan u lipnju, srpnju i kolovozu (Slika 42H).

U 2022. godini temperatura je premašila 28 °C ukupno 112 dana, 30 °C 57 dana, 32 °C 19 dana i 34 °C 3 dana (Slika 41). Najduže razdoblje temperature iznad 28 °C trajalo je uzastopno 70 dana (02.06. – 10.08.; Slika 42I). Također, temperatura je ostala iznad 30 °C 23 dana (15.06. – 07.07; Slika 42J), te je premašila 32 °C 14 dana (23.06. – 06.07.; Slika 42K). Konačno, premašivanje od 34 °C trajalo je tri dana (07.07.- 09.07.; Slika 42L). Podaci su tablično prikazani u Prilozima (Prilog Tablice P10–P13).

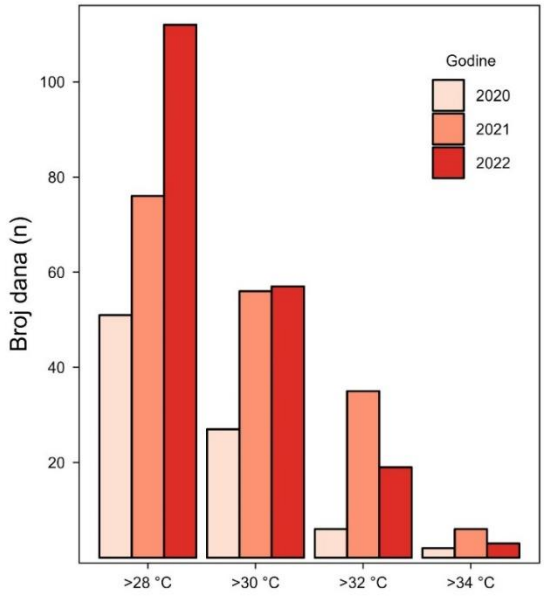


Slika 41. Grafički prikaz broja dana tijekom kojih je temperatura mora u laguni Šćuza premašila određene granice (28, 30, 32 i 34 °C) u 2020., 2021. i 2022. godini.

Kada se uspoređuju temperaturni uvjeti izvan lagune s *in situ* temperaturama iz lagune, *in situ* podaci pokazuju da su prosječne temperature morske vode znatno više u toplijem dijelu godine, dok su znatno niže u hladnijem dijelu godine (Prilog Slika P5). Osim toga, kada se razmatraju podaci o SST-u izvan lagune i vremensko razdoblje od ranih 1980-ih do danas, postaje očito: učestalost, trajanje (Prilog Slika P6) i intenzitet (Prilog Slika P7) toplinskih valova značajno su se

povećali tijekom zadnjeg desetljeća. Uspoređujući učestalost događaja toplinskih valova u desetljeću 2013.–2022. s učestalošću događaja u razdobljima 1983.–1992., 1993.–2002. i 2003.–2013., učestalost se povećala redom za 14,6, 4 i 2,1 puta. Kada se zbroji trajanje toplinskih valova u svakom desetljeću, u posljednjem desetljeću trajanje se povećalo za 19,7, 4,5 i 2,7 puta, redom, a kada se zbroji kumulativni intenzitet (koji je funkcija trajanja događaja toplinskih valova i prosječnog intenziteta događaja toplinskih valova), povećao se redom za 19,5, 4,6 i 2,5 puta.

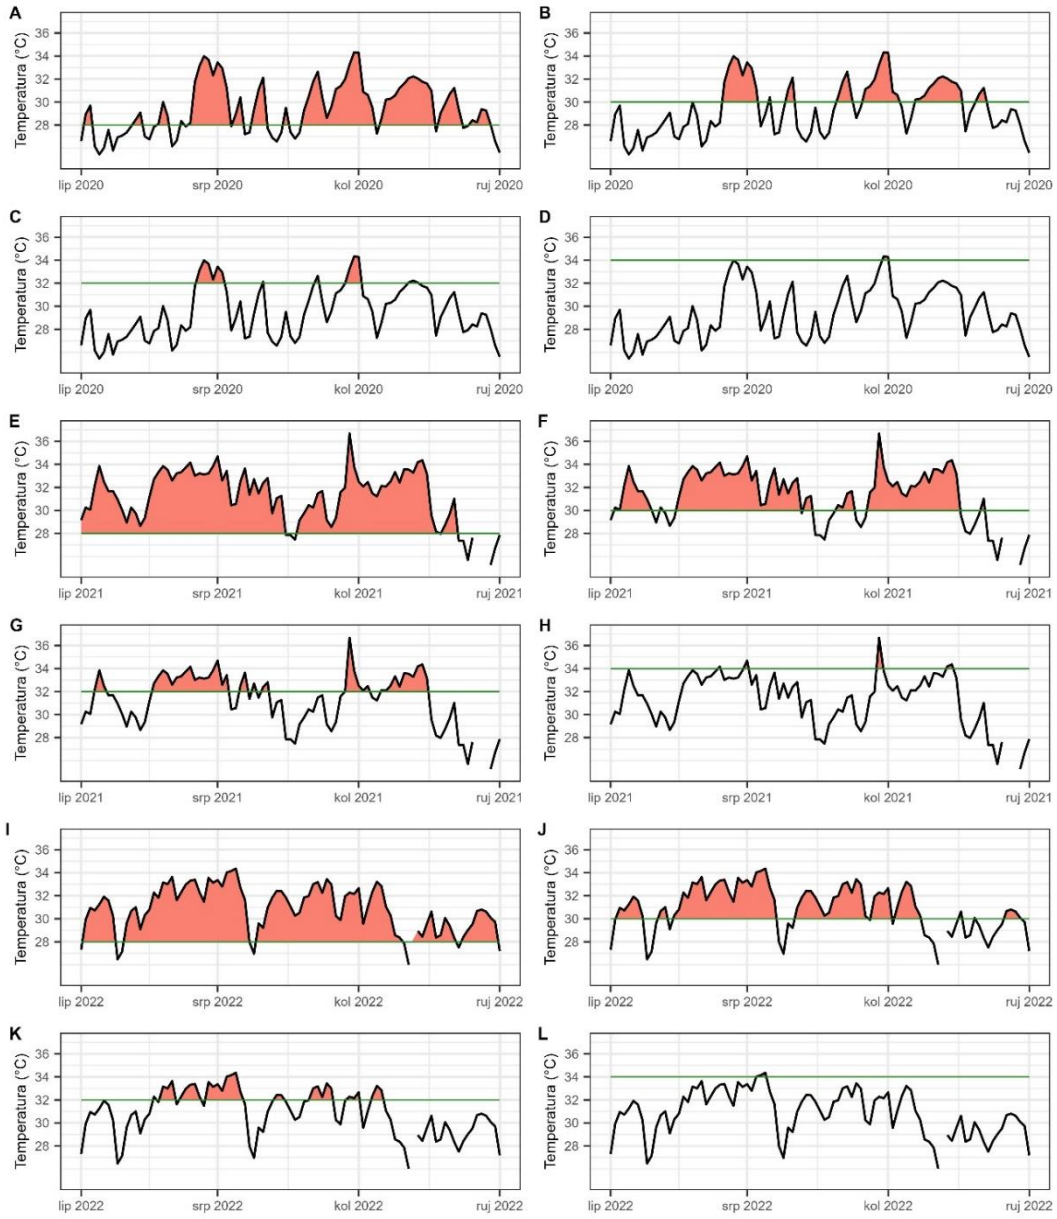


Slika 42. Prekoračenje temperaturnih granica od 28, 30, 32 i 34 °C u razdoblju od 1. lipnja do 1. rujna za godine 2020. (A–D), 2021. (E–H) i 2022. (I–L).

### 5.3.2. Eksperiment termotolerancije

Biomasa za jedinke u tretmanu od 18 °C ostala je relativno stalna tijekom cijelog eksperimenta u usporedbi s četiri ostala tretmana (Slika 43A). Jedinke u tretmanu 28 °C pokazale su vrijednosti veće od 80% početnih vrijednosti do kraja eksperimenta, dok su one u tretmanima od 30 i 32 °C pale ispod 80%, a jedinke u tretmanu od 34 °C pale su ispod 60% (Slika 43A). Jedina značajna razlika u biomasi uočena je između tretmana 34 i 18 °C (Prilog Tablica P14). Duljina talusa bila je relativno konzistentna i usporediva za jedinke u tretmanima 18, 28, 30 i 32 °C (Slika 43B). Međutim, došlo je do drastičnog smanjenja duljine talusa za jedinke u tretmanu 34 °C na 14. i 17. danu, rezultirajući konačnom vrijednošću od 63,63% (Slika 43B). Značajne razlike uočene su između tretmana od 34 °C i tretmana od 18 i 28 °C (Prilog Tablica P14).

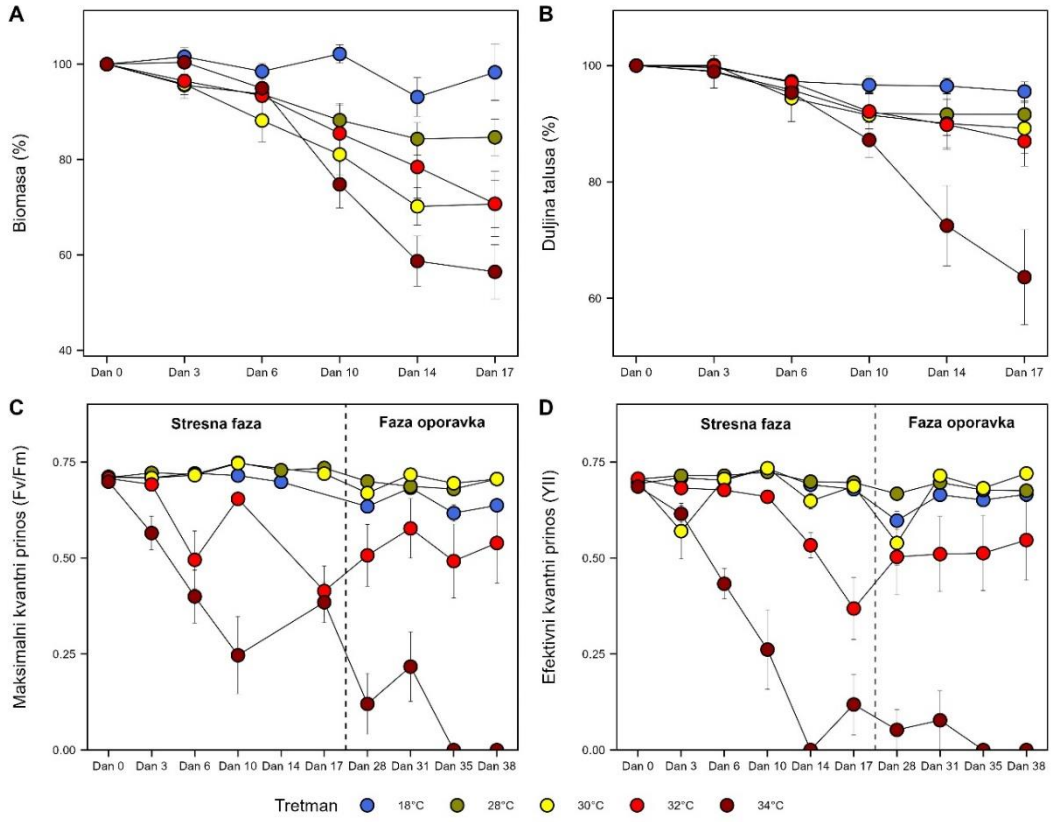


Slika 43. Utjecaj različitih tretmana u eksperimentu termotolerancije na promjenu biomase (srednja vrijednost ± standardna pogreška), A; duljine talusa (srednja vrijednost ± standardna pogreška), B; maksimalnog kvantnog prinosa (*Fv/Fm*; srednja vrijednost ± standardna pogreška), C; i efektivnog kvantnog prinosa (*YII*; srednja vrijednost ± standardna pogreška), D. *Fv/Fm* i *YII* su izmjereni i vizualizirani u fazama stresa i oporavka (C, D). Srednje vrijednosti su izračunate na temelju veličine uzorka n = 9.

Vrijednosti *Fv/Fm* i *YII* ostale su stalne tijekom cijelog eksperimenta za jedinke u tretmanima 18, 28 i 30 °C (Slika 43C, D). No, veća varijabilnost primijećena je u tretmanima 32 i 34 °C. Jedinke u tretmanu 34 °C pokazale su opadajući trend u varijablama *Fv/Fm* i *YII* (s ograničenim potencijalom oporavka). Tretman 32 °C je također pokazao pad, ali bez daljnjeg pada u fazi oporavka, kada su se vrijednosti prinosa stabilizirale.

Značajne razlike pronađene su za *Fv/Fm* između tretmana 34 i 18 °C, tretmana 32 i 28 °C, tretmana 34 i 28 °C, tretmana 32 i 30 °C, te tretmana 34 i 30 °C (Prilog Tablica P14). Dodatno, značajne razlike u *YII*-u otkrivene su između tretmana od 32 i 18 °C, tretmana 32 i 28 °C, te između tretmana 34 °C i svih ostalih tretmana (Prilog Tablica P14).

### 5.3.3. Vizualna opažanja

Na 10. dan eksperimenta termotolerancije, primijećena je vrlo blaga nekroza na vrhovima grana pri temperaturama od 28–32 °C, ali značajna oštećenja talusa opažena su na algama pri temperaturi 34 °C (Slika 44). U 17. danu, nisu primijećene značajne promjene pri 28 i 30 °C, ali veće nekroze grana i raspadanja primijećeni su pri 32 °C. Alge izložene temperaturi od 34 °C izgubile su gotovo sve grane, a boja kauloida je počela primjetno tamniti. Blaža nekroza i raspadanje primijećeni su 28. dana kod jedinki izloženih temperaturama u rasponu od 28–32 °C, ali nisu uočena veća oštećenja talusa. Alge izložene na temperaturi od 34 °C dalje su se raspadale, s primjetnim raspadom kauloida. U tretmanu od 18 °C primijećena je blaga nekroza grana. Isti trend opažen je u 38. danu, ali neke od algi koje su bile izložene temperaturi od 34 °C su uvenule. Zanimljivo je da je na svim temperaturnim tretmanima primijećen podmladak na kamenitoj podlozi za koju su bile pričvršćene odrasle jedinke, ali samo su juvenilne jedinke u tretmanu na 18 °C preživjele do kraja eksperimenta.

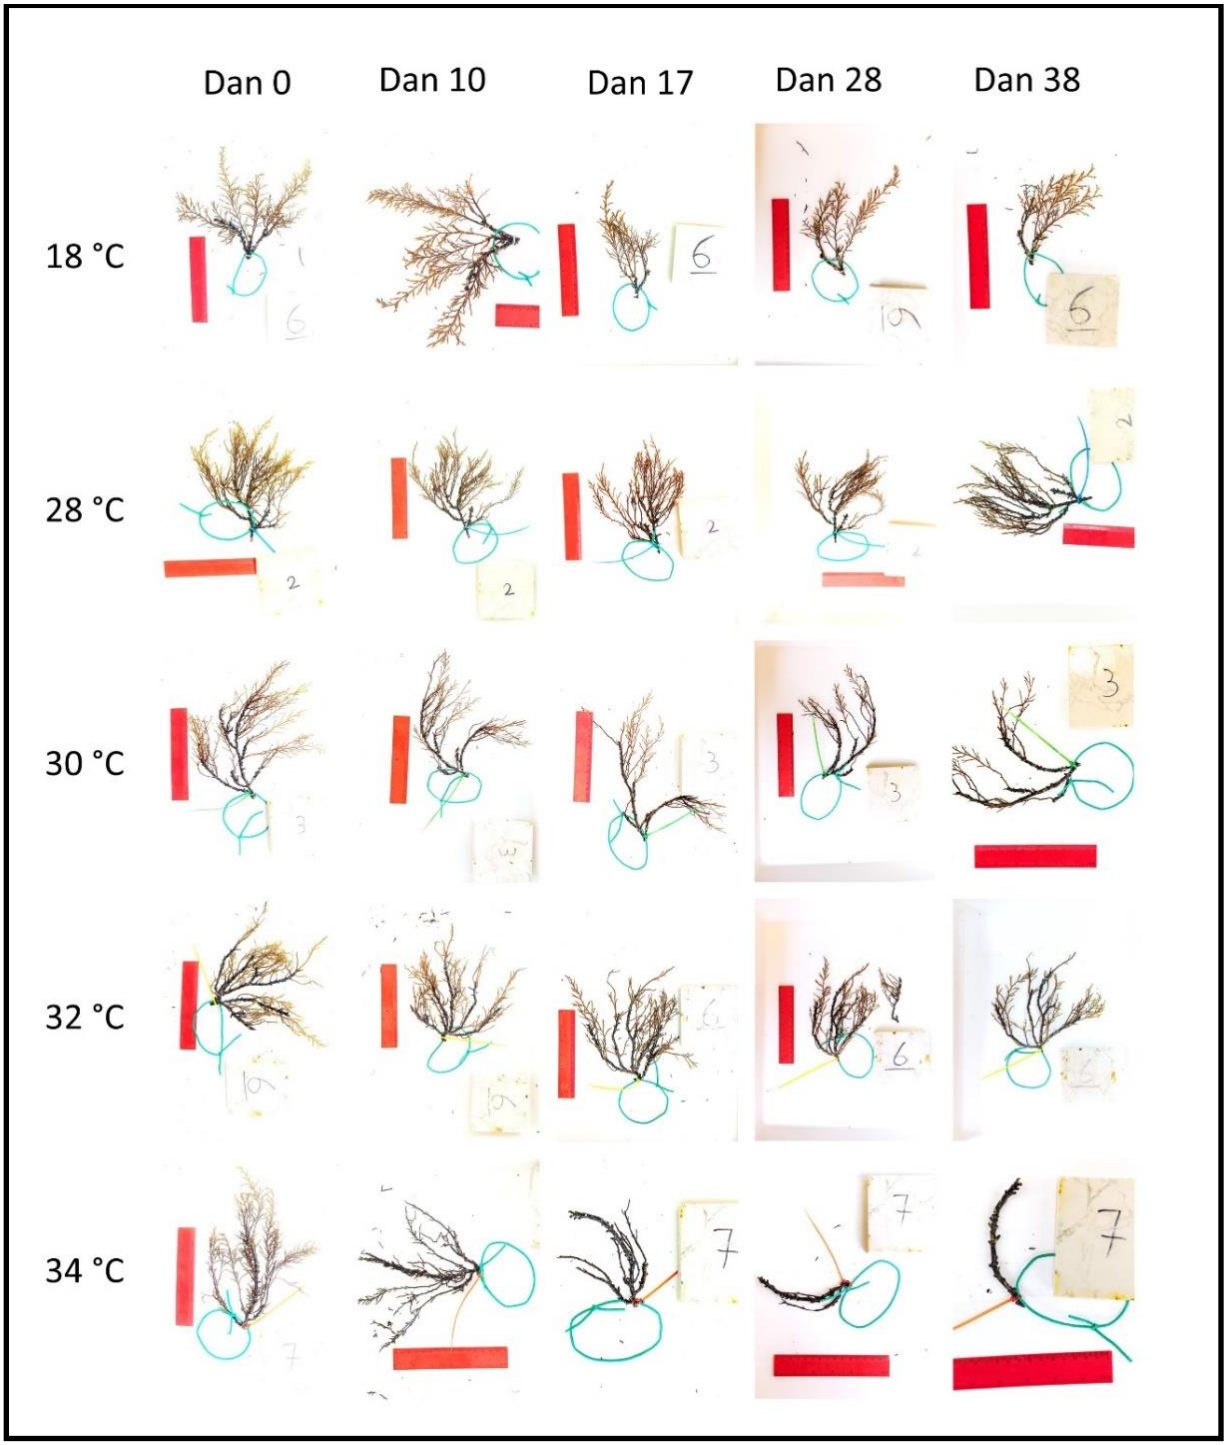


Slika 44. Fotografije odabranih jedinki iz eksperimenta termotolerancije, izloženih različitim temperaturnim tretmanima (28, 30, 32 i 34 °C) i promjene u izgledu tijekom različitih mjernih intervala. “Dan 17” je završni dan faze stresa, dok je “Dan 38” završni dan faze oporavka.

## 5.4. Uzgoj

### 5.4.1. Rezultati *ex situ* ranog uzgoja - rast

Linearni mješoviti model i analiza devijacije (Wald $\chi^2$ test) provedeni su kako bi se istražio utjecaj svjetlosti i vremena na logaritam visine alge. Rezultati su pokazali značajan utjecaj vremena na visinu alge, s vrijednošću hi-kvadrata od 34 017,05 i p-vrijednošću manjom od 0,001, što ukazuje da promjene u vremenu značajno utječu na visinu alge. Također je utvrđena značajna interakcija između svjetlosti i vremena ($\chi^2 = 277{,}44$, $p < 0{,}001$; Prilog Tablica P15), što sugerira da utjecaj svjetlosti na visinu varira ovisno o točki u vremenu. Međutim, glavni faktor svjetlosti sam po sebi nije bio statistički značajan ($\chi^2 = 1{,}78$, $p = 0{,}183$; Prilog Tablica P15), što ukazuje da sama svjetlost nije značajno mijenjala visinu alge tijekom svih vremenskih točaka.

Kako bi se dodatno istražile ove interakcije, proveden je Tukey HSD post-hoc test kako bi se usporedio utjecaj različitih razina svjetlosti (visoka razina naspram niske razine) u različitim vremenskim točkama. Rezultati su pokazali značajne razlike u visini algi između uvjeta visoke i niske razine svjetlosti u određenim vremenskim točkama (Prilog Tablica P16). Konkretno, u vremenskoj točki T4 (28.04.2023.) utvrđena je značajna razlika, s procijenjenom razlikom od 0,176, t-omjerom od 3,53 i p-vrijednošću od 0,010. Slično tome, u vremenskoj točki T5 (02.05.2023.) utvrđena je značajna razlika, s procijenjenom razlikom od 0,160, t-omjerom od 3,19 i p-vrijednošću od 0,016. Također razlike su uočene i u točki T7 (12.05.2023.), s procijenjenom razlikom od 0,143, t-omjerom od 2,68 i p-vrijednošću od 0,026. Međutim, nisu utvrđene značajne razlike između razina svjetlosti u ranijim vremenskim točkama (T1, T2 i T3), što sugerira da utjecaj svjetlosti na visinu alge postaje izraženiji tijekom vremena (Slika 45).

Ovi rezultati ukazuju na to da, iako sama svjetlost nema značajan utjecaj na visinu alge tijekom svih vremenskih točaka, njezin utjecaj postaje značajan u kasnijim fazama rasta, posebno u interakciji s vremenom.

### 5.4.2. Rezultati *ex situ* ranog uzgoja - preživljavanje

Generalizirani linearni mješoviti model (GLMM) korišten je za ispitivanje utjecaja svjetlosti i vremena na preživljavanje, pri čemu je glinena pločica tretirana kao nasumični faktor. Analiza je pokazala da i svjetlost i vrijeme značajno utječu na preživljavanje, što je naznačeno vrijednošću Wald-ovog hi-kvadrata od 19,31 za svjetlost i 728,08 za vrijeme, obje s p-vrijednostima manjim

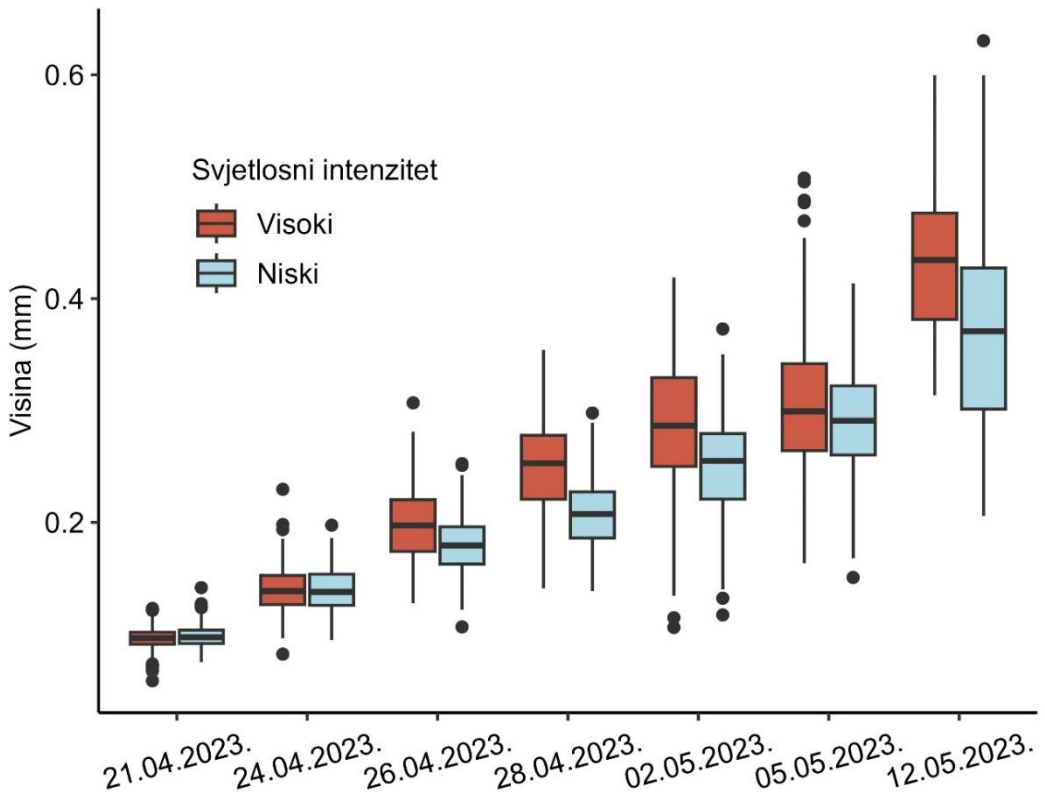


Slika 45. Promjene u veličini prilikom *ex situ* uzgoja juvenilnih jedinki vrste *Gongolaria barbata* pri različitom intenzitetu svjetlosti, prikazane dijagramom pravokutnika od 21.04.2023. godine do 12.05.2023. godine. Za svaku točku mjerenja, korišten je cijeli set podataka za pojedinu svjetlosnu razinu. Dijagram pravokutnika prikazuje medijan (središnja crta), interkvartilni raspon (obojani dio), raspon podataka unutar 1,5 puta interkvartilnog raspona (vertikalne linije) i odstupanja (točke izvan 1,5 puta interkvartilnog raspona).

od 0,001 (Prilog Tablica P17). Nadalje, utvrđeno je da je interakcija između svjetlosti i vremena također značajna, s vrijednošću hi-kvadrata od 129,07 i p-vrijednošću manjom od 0,001 (Prilog Tablica P17). Ova značajna interakcija sugerira da utjecaj svjetlosti na preživljavanje varira ovisno o vremenskoj točki, naglašavajući važnost razmatranja kombiniranog utjecaja ovih čimbenika.

Kako bi se dodatno istražile ove interakcije, proveden je Tukey HSD post-hoc test. On je pokazao da su u određenim vremenskim točkama postojale značajne razlike u preživljavanju između uvjeta visoke i niske svjetlosti (Prilog Tablica P18; Slika 46). Konkretno, u vremenskoj točki T5 (02.05.2023.) razlika između visoke i niske svjetlosti bila je značajna, s p-vrijednošću manjom od 0,001, što ukazuje na znatno smanjenje preživljavanja u uvjetima visoke svjetlosti u toj vremenskoj točki. Slično tome, u vremenskoj točki T6 (05.05.2023.) i T7 (12.05.2023.) razlika je također bila

statistički značajna, s p-vrijednošću manjom od 0,001 što dodatno potvrđuje “negativan” utjecaj visoke svjetlosti na preživljavanje u toj fazi.

Ovi nalazi pokazuju da svjetlost i vrijeme neovisno i interaktivno utječu na preživljavanje, pri čemu uvjeti visoke svjetlosti imaju posebno štetan utjecaj tijekom određenih vremenskih razdoblja (Slika 46). Značajna interakcija između svjetlosti i vremena naglašava složenost ovih učinaka i potrebu za razmatranjem oba čimbenika u istraživanju dinamike preživljavanja juvenilnih jedinki vrste *Gongolaria barbata*.

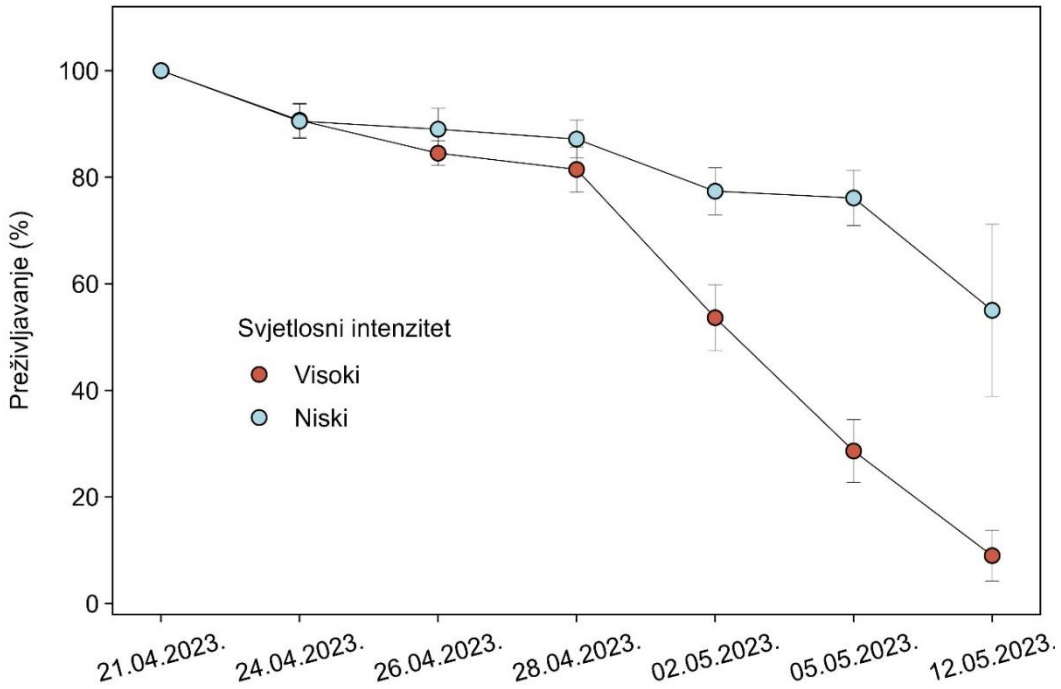


Slika 46. Promjene u preživljavanju prilikom *ex situ* uzgoja juvenilnih jedinki vrste *Gongolaria barbata* pri različitom intenzitetu svjetlosti od 21.04.2023. godine do 12.05.2023. godine. Srednje vrijednosti su izračunate na temelju veličine uzorka n = 4 (četiri glinene pločice), te je za svaku vrijednost prikazana standardna pogreška.

### 5.4.3. Rezultati *in situ* rasta

Linearni mješoviti model korišten je za ispitivanje utjecaja svjetlosti i vremena na logaritam visine alge, pri čemu je glinena pločica tretirana kao nasumični faktor. Analiza je otkrila značajan glavni utjecaj svjetlosti, s vrijednošću hi-kvadrata od 7,52 i p-vrijednošću od 0,006, što ukazuje na to da svjetlost značajno utječe na visinu alge (Prilog Tablica P19). Vrijeme je također imalo vrlo

značajan utjecaj, s vrijednošću hi-kvadrata od 3066,72 i p-vrijednošću manjom od 0,001, što pokazuje da su promjene tijekom vremena snažno povezane s varijacijama u visini alge. Dodatno, zabilježena je značajna interakcija između svjetlosti i vremena ($\chi^2 = 189{,}02$, $p < 0{,}001$), što sugerira da utjecaj svjetlosti na visinu alge varira ovisno o vremenskoj točki (Prilog Tablica P19; Slika 47).

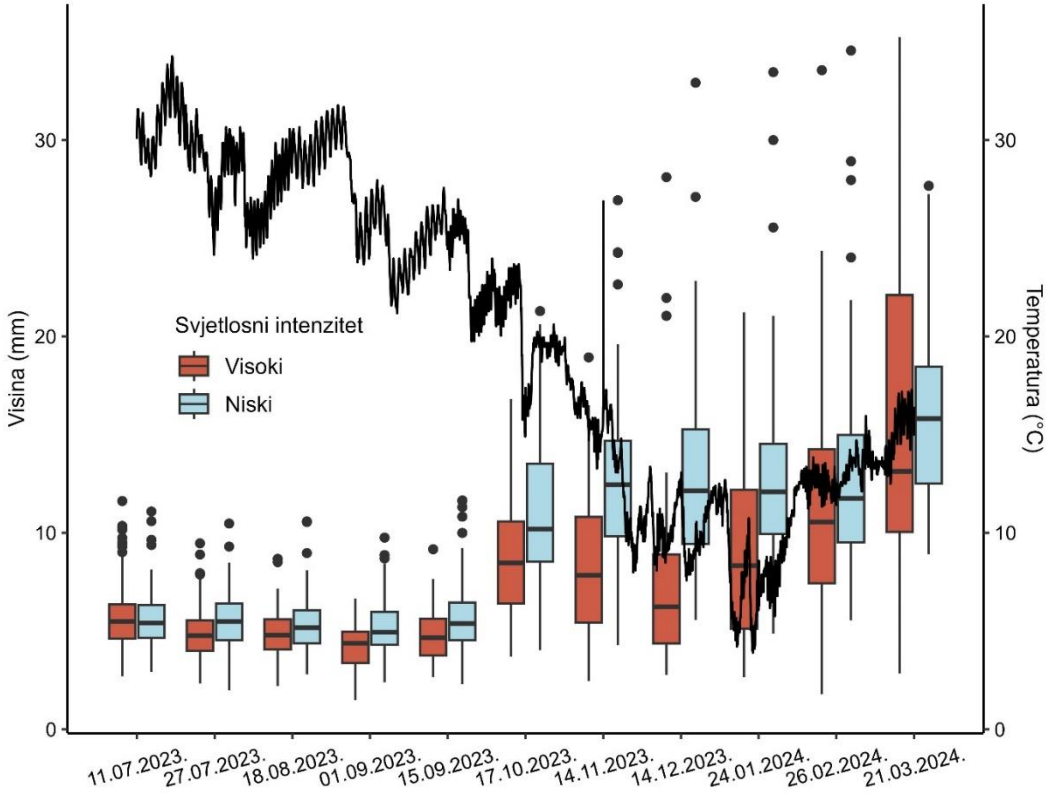


Slika 47. Promjene u veličini (y os 1 – dijagram pravokutnika) prilikom in situ faze uzgoja juvenilnih jedinki vrste *Gongolaria barbata* iz dva mrežasta kaveza i temperatura mora (y os 2 – crna linija) u laguni Šćuza. Prikaz se odnosi na razdoblje od 11.07.2023. godine do 21.03.2024. godine. Za svaku točku mjerenja, korišten je cijeli set podataka za pojedini uzgojni kavez. Dijagram pravokutnika prikazuje medijan (središnja crta), interkvartilni raspon (obojani dio), raspon podataka unutar 1,5 puta interkvartilnog raspona (vertikalne linije) i odstupanja (točke izvan 1,5 puta interkvartilnog raspona).

Tukey HSD test otkrio je nekoliko vremenskih točaka u kojima su razlike između uvjeta svjetlosti bile statistički značajne (Prilog Tablica P20; Slika 47). U vremenskoj točki T6 (17.10.2023.), razlika u visini algi između uvjeta svjetlosti bila je značajna, s p-vrijednošću manjom od 0,05, što ukazuje na znatno smanjenje visine algi. U vremenskoj točki T7 (14.11.2023.), zabilježena je značajna razlika, s p-vrijednošću manjom od 0,001. U vremenskoj točki T8 (14.12.2023.), razlika

u visini algi bila je značajna, s p-vrijednošću manjom od 0,001. U vremenskoj točki T9 (24.01.2024.), zabilježena je značajna razlika, s p-vrijednošću od 0,0014. U vremenskoj točki T10 (26.02.2024.), zabilježena je još jedna značajna razlika, s p-vrijednošću manjom od 0,05.

Ovi rezultati sugeriraju da, iako svjetlost općenito utječe na visinu talusa, njen utjecaj je posebno izražen u određenim vremenskim točkama, posebno u T6, T7, T8, T9 i T10, gdje su uočene značajne razlike.

### 5.4.4. Abiotički parametri

Temperatura mora je u razdoblju stagnacije rasta vrste *Gongolaria barbata* varirala od 20 °C do 30 °C (Slika 47). Uglavnom je temperatura u tom razdoblju bila iznad 25 °C, s visokom frekvencijom pojavljivanja temperature iznad 30 °C. U razdoblju kad se temperatura stabilizirala tek nekoliko stupnjeva iznad 20 °C, bilježio se „oporavak“, odnosno početak faze rasta mladih jedinki. Zatim je došlo do stagnacije rasta kada je temperatura postepeno padala do 5 °C krajem siječnja, te je stagnacija trajala do kraja veljače, kada su temperature počele rasti i dosegle vrijednosti od 13 do 15 °C. U posljednjem mjerenju tijekom ožujka 2024., zabilježen je ponovni rast mladih jedinki kad je temperatura dosegla vrijednosti iznad 15 °C (Slika 47).

Postotni udjeli sedimenta i organske tvari u ukupnom protoku slično su varirali u oba kaveza. U kavezu 1 određen je udio sedimenta od 71,03% do 82,86%, a organske tvari od 17,14% do 28,97%, dok je kod kaveza 2 udio sedimenta varirao između 64,38% i 83,08%, a organske tvari između 16,92 do 35,62% (Slika 48).

Također, vrijednosti ukupnog protoka sedimenta (anorganska + organska frakcija) uglavnom se preklapaju za dva kaveza u pojedinim vremenima s minimalnim varijacijama. Ukupni protok je nešto niži u razdoblju od 27.07.2023. do 02.10.2023. (kavez 1: min-0,54 mg/cm$^2$/dan, max-1,12 mg/cm$^2$/dan; kavez 2: min-0,37 mg/cm$^2$/dan, max-1,19 mg/cm$^2$/dan), te se zatim gotovo trostruko povećava u idućih 15 dana (kavez 1: 3,33 mg/cm$^2$/dan; kavez 2: 2,34 mg/cm$^2$/dan). Zatim dolazi do smanjenja do 14.11.2023. (kavez 1: 1,45 mg/cm$^2$/dan; kavez 2: 1,37 mg/cm$^2$/dan). U idućih mjesec dana protok se povećava (kavez 1: 4,57 mg/cm$^2$/dan; kavez 2: 3,32 mg/cm$^2$/dan) i doseže najviše vrijednosti 24.01.2024. od 11,75 mg/cm$^2$/dan u kavezu 1 i 10,97 mg/cm$^2$/dan u kavezu 2. Sedimentacija opada u veljači 2024. (kavez 1: 1,29 mg/cm$^2$/dan; kavez 2: 0,82 mg/cm$^2$/dan) i ožujku 2024. (kavez 1: 2,16 mg/cm$^2$/dan; kavez 2: 2,01 mg/cm$^2$/dan), no onda se povećava tijekom iduća tri mjeseca (kavez 1: 4,03 mg/cm$^2$/dan; kavez 2: 4,53 mg/cm$^2$/dan).

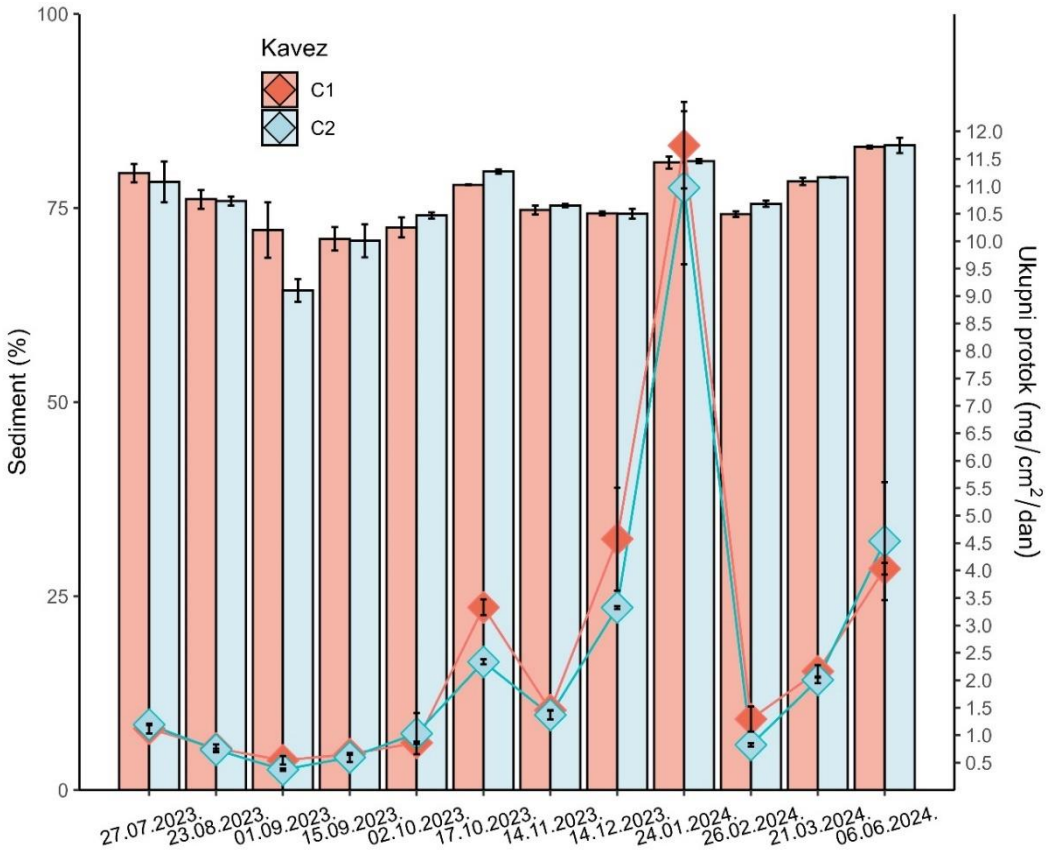


Slika 48. Udio sedimenta (y os 1/stupičasti graf) i ukupni protok sedimenta (y os 2/linijski graf) u razdoblju od 27.07.2023. do 06.06.2024. Za obje varijable prikazane su standardne pogreške.

Salinitet u lipnju i srpnju 2023. godine bio oko 38,50, nakon čega su se vrijednosti u rujnu snizile na 33,71, a polovicom rujna povećale na 37,40. Zatim se postepeno smanjiva od listopada kad je iznosio 38,40, do prosinca kad je iznosio 35,52. Najniža vrijednost saliniteta od 27,24 zabilježena je krajem siječnja 2024, krajem veljače 2024. iznosio je 36,10, dok je krajem ožujka 2024. iznosio 30,70.

Ukupni anorganski dušik (TIN; nitrati, nitriti i amonij) pokazuje trend opadanja od lipnja 2023. (5,280 µmol/L), do sredine rujna, kada su zabilježene minimalne vrijednosti (1,720 µmol/L). Zatim slijedi rast do maksimalne zabilježene vrijednosti polovicom studenog 2023. (10,468 µmol/L), te postepeni pad do ožujka 2024. kad je vrijednost TIN-a iznosila 3,320 µmol/L (Slika 49A).

Nešto viša koncentracija fosfata ($PO_4^{3-}$) zabilježena je u lipnju i srpnju 2023., s vrijednostima od 0,05 i 0,081 µmol/L, dok su vrlo niske koncentracije fosfata mjerene od rujna 2023. godine do siječnja 2024. (Slika 49B). Ponovni rast uočen je tijekom veljače 2024. (0,05 µmol/L).

Koncentracije Chl *a* su najviše bile u ljetnom razdoblju 2023. godine, s maksimalnom vrijednosti od 1,77 µg/L u srpnju 2023. Zatim slijedi pad koncentracija tijekom jeseni i zime na minimalnu vrijednost 0,73 µg/L u siječnju 2024. (Slika 49C).

Koncentracije $SiO_4^{4-}$ bile su visoke u lipnju i srpnju 2023 (10,412 µmol/L i 11,194 µmol/L), dok je nagli pad zabilježen početkom rujna 2023. (3,619 µmol/L). Nakon blagog porasta do polovice studenog 2023. (5,954 µmol/L), slijedi lagani pad do minimalne vrijednosti krajem veljače 2024. (2,027 µmol/L) (Slika 49D).

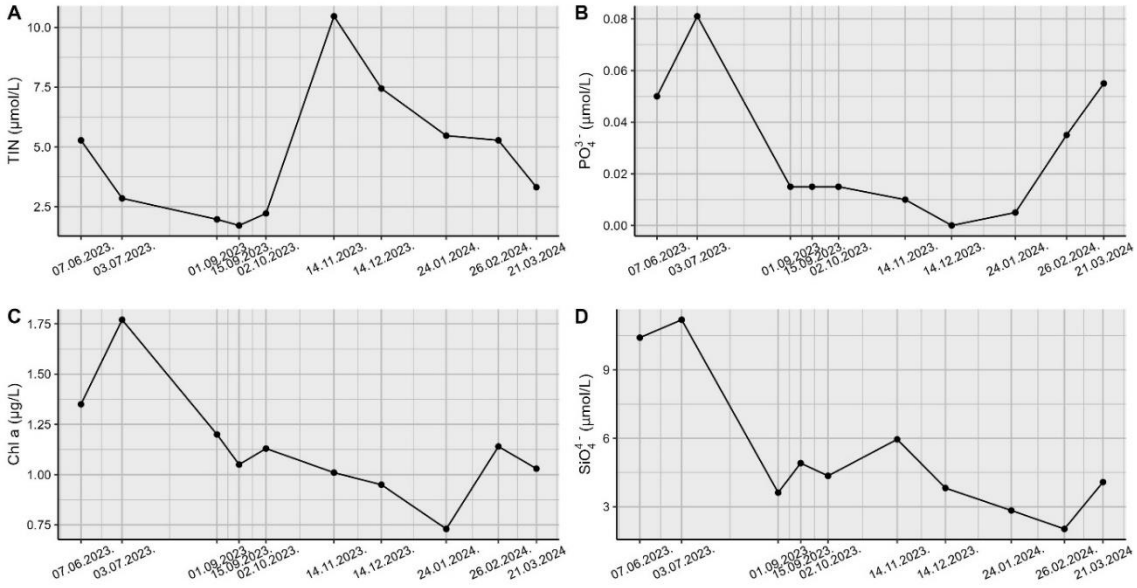


Slika 49. Dinamika ukupnog anorganskog dušika (A), fosfata (B), klorofila a (C) i silikata (D) u laguni Šćuza u razdoblju od lipnja 2023. do ožujka 2024. Svaka vrijednost na grafičkom prikazu se temelji na mjerenju iz jednog uzorka morske vode.

Odnos između varijabli okoliša i prirasta juvenilnih jedinki vrste *Gongolaria barbata* u dva eksperimentalna kaveza (C1 Δrast i C2 Δrast) prikazan je na dijagramu analize glavnih komponenti (Slika 50) gdje PC1 i PC2 objašnjavaju 56% odnosno 14,9% ukupne varijance. Na PC1, prirast juvenilnih jedinki (C1 Δrast i C2 Δrast) snažno je negativno povezan sa Temp (-0,409), Chl *a* (-

0,373), $SiO_4^{4-}$ (0,342), Sal (-0,314) i Svj (-0,309), dok umjereno pozitivno sa ukupnim fluksom (0,299) i TIN (0,170). Na PC2, prirast jedinki pokazuje pozitivan odnos sa $PO_4^{3-}$ (0,622), Chl *a* (0,280) i $SiO_4^{4-}$ (0,168), dok je sa ostalim okolišnim varijablama blago negativno povezan. Ovi odnosi pokazuju da je najveći prirast juvenilnih jedinki ostvaren u hladnijem dijelu godine (kasna zima / rano proljeće).

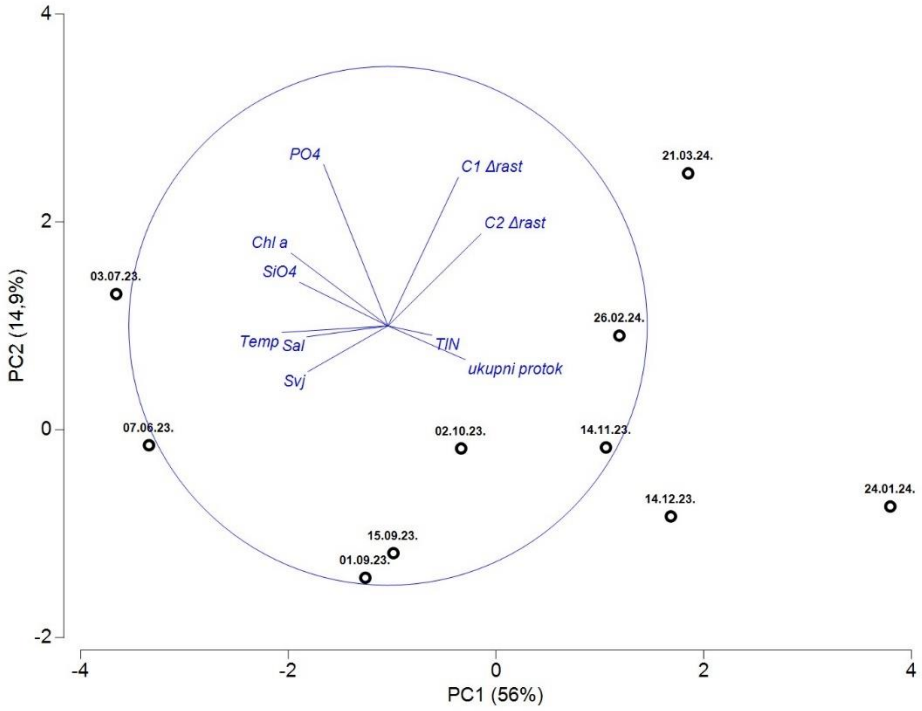


Slika 50. PCA prikaz odnosa abiotičkih parametara i parametara rasta u laguni Šćuza u razdoblju od lipnja 2023. do ožujka 2024. Temp – temperatura, Sal – salinitet, Svj – svjetlost, ukupni protok – ukupni protok sedimenta, TIN – ukupni anorganski dušik, $PO_4^{3-}$ – fosfati, Chl *a* – klorofil a, $SiO_4^{4-}$ – silikati, C1 Δrast – rast juvenilnih jedinki u kavezu 1 i C2 Δrast – rast juvenilnih jedinki u kavezu 2.

# 6. RASPRAVA

## 6.1. Rasprostranjenost i morfometrija vrste *Gongolaria barbata*

Regresija vrste *Gongolaria barbata* primijećena je duž središnjeg dijela zapadne istarske obale, gdje su se populacije vrste *G. barbata* smanjivale od 2016. godine, te je vrsta na lokalnoj razini funkcionalno izumrla u kratkom vremenskom razdoblju.

Kartiranjem preostalih populacija vrste *G. barbata* na zapadnoj i južnoj obali Istre, saznali smo informacije o tome gdje se trenutno nalaze populacije i koja je njihova relativna brojnost, što će uvelike doprinijeti daljnjem dugoročnom praćenju te vrste na istarskoj obali. Generalno, većina preostalih populacija su fragmentirane i često degradirane kao posljedica djelovanja stresora poput utjecaja brstioca. Najbrojnije populacije se nalaze u plitkom infralitoralu i lokvicama obale Lanterne, Poreča, Funtane, Vrsara, te u lokvicama Kamenjaka. Najzdravija populacija, ujedno i jedina kontinuirana morska šuma koju tvori vrsta *G. barbata* nalazi se u obalnoj laguni Šćuza na krajnjem jugu Istre. Na temelju rezultata kartiranja, recentno uzorkovanje jedinki u svrhu usporedbe morfometrijskih karakteristika i biomase provedeno je u tri staništa, u plitkom infralitoralu, mediolitoralnim lokvicama i obalnoj laguni. Usporedba morfometrije i biomase pokazala je da trenutno postoji velika varijabilnost pojedinih izmjerenih karakteristika kako između populacija, tako i unutar populacija, s nekim populacijama poput onih u laguni Šćuza ili lokvica Kamenjaka koje se veličinski ističu po pojedinim karakteristikama.

Na većini lokacija gdje su populacije pronađene i proučavane u razdoblju od 2009.-2013. (Iveša i sur., 2016), vrsta *G. barbata* recentno nije pronađena. Na lokacijama gdje je ona recentno pronađena, što uključuje plitki infralitoral priobalja Lanterne i Funtane, usporedba recentnih podataka morfometrije s povijesnim podacima pokazala je značajno smanjenje vrijednosti većinu morfometrijskih karakteristika, što ukazuje na značajne promjene u ekološkim uvjetima u razdoblju od nešto više od 10 godina, koje su dovele do negativnog utjecaja na preostale populacije.

Vrsta *Gongolaria barbata* formirala je bujne šume tijekom razdoblja od 2003. do 2013. duž zapadne obale Istre u sjevernom Jadranu i bila je najčešća vrsta iz reda Fucales u dubinskom rasponu od 0,5 do 2 m; manje je bila prisutna u dubinskom rasponu od 5 do 7 m i prilično rijetka na dubinama od 10 do 12 m (Iveša i sur., 2016). U posljednjem desetljeću, vrsta je obitavala na slovenskoj obali (Orlando-Bonaca i sur., 2008), na Conero obali u Italiji (Perkol-Finkel i sur.,

2012), na Balearskim otocima (Sales i Ballesteros, 2009), u Albaniji (Blanfuné i sur., 2019), na crnogorskoj obali (Mačić i sur., 2010) i u nekim drugim mediteranskim regijama (Ribera i sur., 1992; Thibaut i sur., 2016, 2015), kao i u Crnom moru, gdje je nekad bila dominantna vrsta (Sadogurska, 2021). Međutim, malobrojne su studije jasno identificirale stresore koji su ugrozili opstanak i možda potaknuli regresiju vrsta iz reda Fucales (Tamburello i sur., 2019).

Detaljno stanje populacija cistozira u sjevernom Jadranu kao i promjene koje su se dešavale kroz prošlost nisu u potpunosti poznate. Znanstveno je teško precizirati ove promjene, prvenstveno zbog nedostataka standardiziranih metoda prikupljanja podataka tijekom proteklih desetljeća. Dostupni podaci često su fragmentirani i heterogeni, što otežava cjelovito razumijevanje dinamike ovih populacija (npr. Munda, 2000). Međutim, moguće je korelirati zabilježene podatke o različitim stresorima koji su uglavnom deskriptivne prirode s bilješkama istraživača koji su u određenim razdobljima prikupljali informacije o vrstama. Tako je konkretno iz informacija prikupljenih u prošlom stoljeću moguće povezati uzajamno djelovanje faktora eutrofikacije i utjecaja ježinaca na cistozire (Iveša i sur., 2016; Munda, 2000); često se veća brojnost ježinaca povezuje sa smanjenjem populacija cistozira, dok dugotrajna i intenzivnija razdoblja eutrofikacije također negativno utječu na njihovo stanje (Iveša i sur., 2016). Međutim, postoji i hipoteza da intenzivni događaji eutrofikacije mogu dovesti do smanjenja brojnosti ježinaca (Iveša i sur., 2016). Ove korelacije sugeriraju složene međusobne odnose između ekoloških faktora i populacija cistozira, no potrebna su daljnja istraživanja kako bi se te veze preciznije definirale i razumjele.

### 6.1.1. Morfometrijske karakteristike i biomasa

Morfometrija vrste *Gongolaria barbata* općenito pokazuje visok stupanj varijabilnosti i plastičnosti obzirom na okolišne faktore, te obzirom na razdoblje godine, geografsku poziciju i stanište (Ercegović, 1952; Falace i Bressan, 2006). Na primjer, smatra se da varijabilnost i plastičnost receptakula jedinki vrste *G. barbata* u Crnom moru ovisi o režimu hidrodinamike i o razdoblju u godini. Shodno tome, Orlando-Bonaca i sur. (2022a) primjećuju varijabilnost receptakula, aerocista i količine konceptakula između neposredno udaljenih populacija te nazivaju navedene populacije zasebnim ekotipovima, specifično zbog različitih uvjeta u okolišu, razlici u sedimentaciji i stopi suspenzije (što dovodi do povećanog turbiditeta), te zbog utjecaja antropogenog pritiska. Razlike u morfologiji jednogodišnjih i višegodišnjih dijelova alge, također su uočene između neposredno udaljenih populacija u sjevernom Jadranu (Falace i sur., 2024).

Naposlijetku, prepoznavanje velikog broja intraspecijskih taksona (Guiry i Guiry, 2024) vrste *G. barbata* pokazuje da su istraživači smatrali vrstu visoko polimorfnom što je dovelo do potrebe korištenja morfoloških i molekularnih metoda karakterizacije populacija (Falace i sur., 2024).

Navedeno je sukladno opažanjima Ercegovića (1952), koji tvrdi kako općenito sve vrste cistozira pokazuju različiti vegetacijski ciklus i varijabilnost sukladno okolišnim čimbenicima poput temperature, sedimentacije i izloženosti. Vegetativno razdoblje vrste *G. barbata* prema Ercegoviću (1952) započinje u drugoj polovici jeseni, obično početkom do sredine studenog. Ovo razdoblje obilježava pojava kratkih primarnih i sekundarnih grana, koje razvijaju kompaktne receptakule i aerociste. Primarne grane doživljavaju značajan rast tijekom zime i prvog dijela proljeća, pokazujući maksimalnu duljinu i gustoću svih strukturnih komponenti tijekom travnja ili početkom svibnja. Alga se ponekad tijekom ljeta nalazi u stanju mirovanja. U zaklonjenim područjima alga ne pokazuje intenzivan rast, a od lipnja do kraja rujna kauloidi su goli i prekriveni epibiontima. Na izloženijim staništima alga ne prekida vegetacijsko razdoblje, ali je ono tijekom ljeta usporeno.

Iz recentnog istraživanja morfometrije i biomase jedinki *G. barbata* s različitih lokacija i staništa, vidljivo je kako glavne karakteristike koje u ljetno doba najviše doprinose ukupnoj biomasi (ukupna duljina kauloida, duljina kauloida, broj kauloida, duljina talusa) kao i biomasa jedinki, pokazuju najviše vrijednosti kod pleustofitskih primjeraka u laguni Šćuza (grupa Šćuza 2; Prilog Slika P1). Neovisno o tome što su jedinke uzorkovane u neposrednoj blizini (nekoliko desetaka metara) epilitskih jedinki u laguni Šćuza (grupa Šćuza 1), kao i o manjem uzorku jedinki (nŠĆ2 = 37, nŠĆ1 = 72), jedinke s lokacije Šćuza 1 nisu uspjele zahvatiti toliko širok raspon vrijednosti pojedinih varijabla koji su pokazivale jedinke s lokacije Šćuza 2. Primjerice, varijabla koja uključuje ukupnu duljinu kauloida je dosezala u pojedinim opažanjima s lokacije Šćuza 2 i preko 550 cm, dok je kod lokacije Šćuza 1 maksimalna vrijednost bila tek negdje ispod 200 cm. Međutim, minimalne vrijednosti pleustofitskih jedinki nalazile su se u rasponu jedinki s lokacije Šćuza 1 kod svih navedenih parametara. U usporedbi s drugim populacijama vrste *G. barbata* na zapadnoj obali Istre, veličina i broj kauloida sugeriraju da je vrsta *G. barbata* u laguni Šćuza ekotip/morfotip prilagođen životu u lagunama. Laguna je također domaćin drugih pleustofitskih vrsta poput zelenih alga *Cladophora prolifera* i *Valonia aegagropila*, kao i crvene alge *Rytiphlaea tinctoria*. Populacije pleustofita, tipične za lagunska okruženja Sredozemnog mora, najčešće uključuju vrste *Valonia aegagropila*, *Rytiphlaea tinctoria*, *Lychaete echinus* (Biasoletto) Wynne, i *Chaetomorpha*

*linum* (O.F.Müller) Kützing (Calvo i sur., 1980; Cecere i sur., 1992; Orestano i Calvo, 1985). Slična obalna laguna, poznata kao Stjuža, nalazi se u Strunjanu, Sloveniji, i predstavlja isti tip staništa, ali s različitom dominantnom vrstom koja tvori šume makroalgi, točnije vrsta *Cystoseira foeniculacea*. U navedenoj laguni je također zabilježena vrsta *G. barbata* f. *aurantia* (Kützing) Falace, Alongi & Kaleb koja se uglavnom pojavljuje u pleustofitskom „slobodno-plutajućem“ obliku, kao i brojne druge makroalge (pronalazimo ih također u laguni Šćuza) koje se često pojavljuju u ovom obliku (Battelli i Catra, 2023, 2021). Također, slične pojave slobodnoživućih cistozira opažene su i u drugim mediteranskim lagunama, poput *G. barbata* f. *aurantia* u laguni Nador u Maroku (Ramdani i sur., 2021), te *G. barbata* u laguni Orbetello, gdje se slobodnoživuće jedinke, slično kao u laguni Šćuza, pronalaze u agregacijama na dnu lagune (Lenzi i sur., 2024). Slično, pleustofitske jedinke taksona *G. barbata* f. *repens* (A.D.Zinova & Kalugina) Sadogurska pronalaze se u Crnom moru u zaljevu Dzharylhach (Sadogurska, 2021).

Vrsta *G. barbata* obično ima jedan glavni kauloid pričvršćen na hridinastu podlogu te nekoliko bočnih kauloida koji proizlaze iz glavnog kauloida (Ercegović, 1952). Sličan opis ima vrsta *G. barbata* iz Crnog mora (Khailov, 1979). Talus se sastoji od glavnog kauloida i bočnih kauloida na kojima rastu adventivne i glavne grane. Autor opisuje tek nekoliko bočnih kauloida na talusu kod jedinki starih 4–6 godina; nadalje, u dobi od 6 do 19 godina, formiranje bočnih kauloida se povećava, dosežući do 16 bočnih kauloida. Očito je da je vrsta u laguni Šćuza pokazala veći stupanj morfološke varijabilnosti, posebno u broju bočnih kauloida; epilitske jedinke imale su nešto ispod 40 kauloida, dok pleustofitske do 81 kauloid (Iveša i sur., 2022). Broj kauloida u obje forme sugerira da su talusi u laguni prilično stari, iako je teško točno precizirati starost budući da vrste pokazuju različite stupnjeve rasta ovisno o specifičnim uvjetima u okolišu (Lenzi i sur., 2024).

Također je zanimljivo opažanje da je lagunska populacija vrste *G. barbata* (epilitske i pleustofitske jedinke), pokazivala najniže vrijednosti promjera kauloida i promjera bazalne pločice kod proučenih populacija. To se ističe pogotovo u usporedbi s promjerom bazalne pločice jedinki u Lanterni, koje su uglavnom bile degradirane, međutim s nešto većim bazalnim pločicama. Pojedine pleustofitske jedinke iz lagune još uvijek su zadržavale bazalnu pločicu (Prilog Slika P1B), koja je s vremenom postala izobličena i nefunkcionalna, dok druge uopće nisu zadržavale bazalnu pločicu (neprepoznatljiva), gubeći time prepoznatljivu stablastu strukturu i "visoki" uzorak rasta tipičan za vrstu (Cormaci i sur., 2012; Gómez Garreta i sur., 2001). Time, može se pretpostaviti da lagunarni

uvjeti, koji su općenito karakterizirani manjom izloženošću i hidrodinamikom zbog različitih endogenih procesa, ne dovode do formacije bazalnih pločica većeg promjera (Fowler-Walker i sur., 2006). Slično je primijetio i Ercegović (1952), da dubinski primjerci vrste *Gongolaria barbata* (30-40 m dubine) imaju malu pločicu kao rezultat mirnijih uvjeta, dok primjerci plitkih izloženih staništa imaju nešto šire bazalne pločice. Međutim, uslijed stohastičkih događaja poput oluja ili jačeg vjetra, a time i izraženije hidrodinamike, pretpostavka je da se epilitska forma vrste *G. barbata* u laguni s vremenom transformira u pleustofitsku formu i ostatak svog života provodi na dnu. Izoliranost, mala dubina i mirni uvjeti lagune zatim omogućuju preživljavanje odvojenih talusa u plitkom infralitoralu, proizvodnju velikog broja kauloida, kao i sezonalnu proizvodnju primarnih grana i reproduktivnih struktura, receptakula.

Odvajanje bazalne pločice je često opažena pojava, posebno kod nekih vrsta kelpova (Koehl i Wainwright, 1977; Milligan i DeWreede, 2000). Do odvajanja bazalne pločice može doći primjerice zbog modifikacije podloge od strane beskralješnjaka (Dayton i sur., 1984; McLay i Hayward, 1987) ili fizičkog utjecaja valova (Dayton i sur., 1984).

Neovisno o uzorkovanju u sličnim staništima, uočljiva je razlika u duljini kauloida i duljini talusa između jedinki uzorkovanih u lokvicama u Bijeloj uvali i na Kamenjaku (Prilog Slika P2). Naime, lokvice na lokaciji Bijela uvala su veličinski manje i dubinski pliće od onih na Kamenjaku, stoga potencijalno stabilniji uvjeti lokvica Kamenjaka omogućuju efikasniju formaciju viših kauloida i bolji rast primarnih grana od onih u Bijeloj uvali. U Bijeloj uvali i na Kamenjaku uočene su jedinke koje formiraju receptakule čak i tijekom ljeta, što je sukladno opažanjima Ercegovića (1952) kako jedinke na izloženim staništima ne pokazuju istaknuto razdoblje mirovanja. Međutim, to nije bio slučaj s jedinkama u laguni Šćuza. Također to nije bio slučaj s jedinkama na lokaciji Funtana, iako su jedinke imale dobro razvijene primarne grane, dok jedinke na lokaciji Lanterna nisu imale razvijene primarne grane, ali su bile obrasle epibiontima te se njihov talus nalazio u degradiranom stanju (Prilog Slika P3A, B, C).

Kao dodatno opažanje, može se uočiti kako je u laguni Šćuza zbog fizičke izolacije (prvenstveno most koji odvaja lagunu od Medulinskog zaljeva) prisutnost ježinaca ograničena na mali dio u blizini mosta, posebno na vanjskoj strani. Međutim iznimno visoke temperature u laguni potencijalno ograničavaju širenje ježinaca na dio lagune gdje je vrsta *G. barbata* najbrojnija (Yeruham i sur., 2015). Nedostatak glavnih brstioca može biti jedan od glavnih čimbenika koji

omogućuje preživljavanje ove vrste. U laguni je također uočena prisutnost i djelovanje herbivorne ribe *Sarpa salpa* na jednogodišnje dijelove alge (primarne grane i receptakule), kao i na višegodišnje dijelove (na vegetacijske vrškove). Isto tako, lokvice su također dobro izolirane od glavnih brstioca, što može biti razlog preživljavanja pojedinih vrsta cistozira u njima, te istovremenog odsustva ili uglavnom niske brojnosti na istim lokacijama u plitkom infralitoralu. Na lokaciji Funtana prisustvo ježinaca nije bilo zabilježeno, dok je na lokaciji Lanterna uočena iznimno visoka brojnost ježinaca u infralitoralu pa sve do granice mediolitorala što je potencijalno doprinijelo zabilježenoj degradaciji talusa *G. barbata* (Prilog Slika P3A, B, C).

Navedene usporedbe populacija pružaju uvid u varijabilnost morfometrijskih karakteristika i biomase jedinki u pojedinim staništima, ističu ekološku posebnost i osjetljivost pojedinih populacija, te završno pružaju referentne vrijednosti pojedinih karakteristika za buduće praćenje populacija i detekciju promjena. U budućim istraživanjima usporedbe morfometrijskih karakteristika, svakako bi trebalo u obzir uzeti i abiotičke parametre poput temperature, svjetlosti, saliniteta, količine nutrijenata i izloženosti, kao i biotičke parametre poput djelovanja brstioca, budući da su oni ključni elementi koji značajno utječu na morfometriju pojedinih populacija.

### 6.1.2. Povijesni i recentni podaci morfometrijskih karakteristika

Kontinuirano mjerenje pojedinih morfometrijskih karakteristika makroalgi kroz vrijeme, omogućuje prikupljanje dugog niza podataka o morfometriji. Na taj način, ovisno o kontekstu istraživanja ili monitoringa, odabiru se metode i morfometrijske karakteristike koje su jednostavne za praćenje u često otežanim terenskim uvjetima, a dovoljno su precizne za detekciju utjecaja pojedinih prirodnih ili antropogenih stresora. Postojanje povijesnih i recentnih podataka može uvelike doprinijeti detekciji razine utjecaja pojedinih stohastičkih ili predvidivih događaja na populacije makroalgi. Tako je, primjerice moguće detektirati utjecaj pojedinih stresora na veličinske frakcije populacije, i time uvidjeti je li utjecaj više usmjeren ka manjim jedinkama ili pak odraslim, uglavnom reproduktivno zrelim jedinkama.

Verdura i sur. (2021) mjerenjem i praćenjem distribucije veličinskih klasa vrste *Ericaria crinita* prije, tijekom i nakon morskog toplinskog vala, ustanovljuju razliku u utjecaju morskog toplinskog vala na dvije populacije, gdje su odrasle (reproduktivno zrele) jedinke s jedne lokacije nastradale, dok su mikrouvjeti druge lokacije omogućili opstanak veće frakcije duljinskih klasa algi. Navarro i sur. (2011) koriste morfometrijske karakteristike (veličinska struktura) za procjenu utjecaja

stohastičkog događaja, oluje, na populacije smeđe alge *Ericaria zosteroides* (C.Agardh) Molinari i Guiry u dubokim vodama, te zaključuju da je oluja drastično promijenila distribuciju veličine eliminirajući većinu viših jedinki, dok druga lokacija zbog manje izloženosti oluje nije nastradala. Nadalje, Mulas i sur. (2022a) koriste dugoročne podatke morfometrijskih karakteristika za procjenu utjecaja temperature i sezonalnosti na formaciju biomase, kao i za samu nedestruktivnu procjenu biomase.

Osim utjecaja fizičkih čimbenika poput stohastičkih oluja ili morskih toplinskih valova, promjene u veličinskoj strukturi prirodne ili eksperimentalne populacije može poslužiti i u detekciji negativnih bioloških čimbenika poput utjecaja herbivora. Tako Monserrat i sur. (2023) koriste veličinske klase juvenilnih jedinki vrste *Cystoseira compressa* kao jednu od mjera detekcije razine utjecaja brstioca na juvenilne jedinke.

U sveobuhvatnom istraživanju cistozira gdje je uzorkovanje vršeno godine 2009. u zoni infralitorala, lokacije uzorkovanja na području Novigrada (Novigrad sjever, Lanterna i Červar) i Vrsara (Funtana sjever, Funtana jug i Petalon) pokazivale su iznimno visoku biomasu vrste *Gongolaria barbata* (Iveša i sur., 2016). Međutim, u kasnijem razdoblju, od 2021. do 2023., kada su iste lokacije ponovno pregledane, jedinke vrste *G. barbata* pronađene su samo na lokaciji Lanterna, i to u izgriženom, degradirajućem stanju, te na lokaciji Funtana. U rovinjskom akvatoriju vrsta nije zabilježena kartiranjem u razdoblju 2021.-2023., dok je u razdoblju od 2009.-2015. lokalizirano utvrđena na pojedinim lokacijama (Ferrairo i sur., 2016; Kolić, 2013). Vrsta je do 2015. godine činila gusta naselja u Uvali Faborso (Ferrario i sur., 2016) te manja izolirana naselja na lokaciji Barabiga (Kolić, 2013). Međutim, unutar WICOS istraživanja ove lokacije nisu uzete u obzir, jer se nasumičnim uzorkovanjem nastojalo ispitati prisustvo vrste *G. barbata* u širem rovinjskom području. Za područje Rovinja, postoje povijesni podaci koji ukazuju da je *G. barbata* bila jedna od češćih vrsta plitkog infralitorala, međutim i u prošlom stoljeću je prvenstveno zbog urbanog onečišćenja uočen pad brojnosti populacija i zamjena ove alge s manje kompleksnim, oportunističkim vrstama (Munda, 1980, 1982, 1993, 2000).

U ovom istraživanju, na temelju provedenih morfometrijskih usporedbi alge *G. barbata* na lokacijama Lanterna i Funtana za godine 2009. i 2023., vidljive su značajne promjene u morfometrijskim karakteristikama između povijesnih i recentnih uzoraka na obje lokacije. Zanimljivo je da su jedinke prikupljene na lokaciji Funtana 2023. godine pokazale djelomično

preklapanje s grupom koje tvore jedinke uzorkovane 2009. godine, potencijalno zbog bolje razvijenosti i boljeg fizičkog stanja talusa (odsustvo ježinaca; Prilog Slika P4A, B) u usporedbi s jedinkama iz Lanterne uzorkovanih 2023. godine.

Na lokacijama Lanterna i Funtana, recentni uzorci iz 2023. godine nisu obuhvatili veće veličinske klase ukupne duljine kauloida, duljine kauloida i duljine talusa. Smanjena prisutnost većih jedinki u recentnim uzorcima može ukazivati na promjene u ekološkim uvjetima ili antropogene utjecaje koji su mogli ograničiti rast i razvoj ovih algi. Uzorkovanje 2023. godine, detektiralo je trend veće frekvencije jedinki s manjim brojem kauloida, međutim također su izostajale određene veće veličinske frakcije koje upućuju na smanjenje broja starijih jedinki (Khailov, 1979). Gubitak većih veličinskih frakcija jedinki, predstavlja direktnu prijetnju populacijama, prvenstveno zbog toga što su odrasle jedinke reproduktivno zrele (Verdura i sur., 2021), stoga njihovo isključivanje iz populacije dovodi do niže otpornosti i ograničava mogućnost daljnjeg širenja i oporavka naselja.

Ukupno gledano, rezultati ukazuju na značajne promjene u morfometrijskim karakteristikama vrste *G. barbata* između 2009. i 2023. godine, posebno ističući degradiranu populaciju na lokaciji Lanterna (Prilog Slika P3A, B, C, D). Ove promjene mogu biti rezultat različitih faktora, uključujući promjene u okolišnim uvjetima, pritiske na staništa ili promjene u dinamici populacija (Verdura i sur., 2023). Uzimajući u obzir da recentnim uzorkovanjem nisu zabilježene populacije vrste *G. barbata* na većini lokacija uzorkovanja iz 2009. godine, te razinu degradiranosti preostalih populacija osobito u plitkim staništima duž istarske obale, zaključujemo da su potrebna daljnja istraživanja i praćenje preostalih populacija kako bi se bolje razumjeli uzroci ovih promjena i njihovi potencijalni učinci na morski ekosustav.

### 6.1.3. Alometrija

Alometrijski modeli pružaju korisne informacije o mokroj biomasi cistozira. Ako je poznat biometrijski odnos mokre biomase i suhe biomase što se također eksperimentalno procjenjuje (Ballesteros, 1990; Mulas i sur., 2022b), moguće je iz mokre biomase dobiti informacije o suhoj biomasi. Kao nekakav krajnji cilj, dobiva se godišnja produkcija suhe biomase po metru kvadratnom godišnje za pojedinu vrstu na određenom području (Ballesteros, 1990, 1988; Mulas i sur., 2022a; Sales i Ballesteros, 2012), ili pak stanje zaliha ugljika makroalgi (Mulas i sur., 2022a, 2022b). Nedavno je dokazana značajna dugoročna (~70 godina) sekvestracija organskog ugljika iz makroalgi unutar i izvan naselja vrste *G. barbata* u plitkim priobalnim uvalama Sredozemnog mora

(Moreda i sur., 2024). Budući da je vrsta *Gongolaria barbata* ujedno i vrsta koja je pod direktnom prijetnjom mnogih lokalnih i globalnih stresora (Verdura i sur., 2023), razvoj nedestruktivnih metoda procjene biomase, značajan je u kontekstu praćenja stanja vrste generalno, ali i u kontekstu praćenja promjena uzrokovanih klimatskim promjenama.

Osim usporedbe morfometrijskih karakteristika i biomase recentno uzorkovanih jedinki vrste *G. barbata* s različitih lokacija, i usporedbe morfometrijskih karakteristika povijesnih i recentnih podataka, testirana je i mogućnost izrade predikcijskih modela biomase na temelju morfometrijskih karakteristika. Najprije su korišteni podaci recentnih mjerenja izvršenih u razdoblju od 2021.-2023. te su u tom slučaju izrađeni univarijatni i multivarijatni modeli specifični za svaku lokaciju. Zatim je testirana mogućnost izrade općeg modela predikcije tako da se sve lokacije obuhvate kao jedan skup podataka ali s uključenim faktorom Lokacija, u krajnju svrhu usporedbe modela specifičnih za lokaciju i općih modela predikcije.

Usporedba modela interakcije s modelima koji uključuju cijeli set podataka (sve lokacije), pokazala je bolji predikcijski potencijal modela koji uključuju interakcije/adicije (hijerarhijski najbolje rangirani model W_w ~ L_ktot * Lok + N_k * Lok + L_t * Lok; AICc = -172.743570 i $R^2$ = 0.8982677), u usporedbi s najbolje rangiranim općim modelima predikcije (npr. model W_w ~ L_ktot + N_k + L_t; AICc = -44.061133 i $R^2$ = 0.7858297), pogotovo univarijatnih modela koji uključuju samo jednu prediktornu varijablu (dakle varijable L_ktot, N_k, L_t, L_k). Slični rezultati su česti u takvim istraživanjima, pogotovo iz razloga što je rast i razvoj algi na različitim lokacijama uvjetovan varijabilnim pritiscima brojnih okolišnih parametara. Ako su uvjeti na različitim lokacijama isti ili slični, moguće je napraviti opći model predikcije, dok je u suprotnom preporučeno testiranje izrade modela specifičnog za lokaciju ili regiju (Campbell i Starko, 2021). Prema ovoj analizi, univarijatni modeli su se prema moći predikcije hijerarhijski pronašli gotovo na dnu liste svih modela (L_ktot – objašnjava 72% varijacije u biomasi, N_k – objašnjava 68% varijacije u biomasi, L_t – objašnjava 50% varijacije u biomasi, L_k – objašnjava 44% varijacije u biomasi).

U kontekstu nedestruktivnog uzorkovanja u svrhu predikcije jedne varijable na temelju drugih, univarijatni modeli su često poželjni zbog jednostavnosti prikupljanja mjerenja samo jedne varijable u terenskim uvjetima, npr. duljine talusa (Mulas i sur., 2022a). U slučaju da predikcijska moć jedne varijable ne objašnjava dovoljni postotak varijabilnosti u željenoj varijabli, nužno je

koristiti više varijabli kako bi predikcija bila preciznija, no navedeno u tom slučaju zahtjeva produženi boravak i rad u često otežanim terenski uvjetima. Varijabla L_ktot u slučaju gdje je u interakciji s faktorom Lokacija objašnjava 87% varijabilnosti u biomasi, u slučaju adicije objašnjava 82% varijabilnosti, te u slučaju gdje nema interakcije ili adicije gotovo 72% varijabilnosti. Stoga ona predstavlja najveći potencijal za izradu relativno pouzdanih univarijatnih modela, ali prema rezultatima ovog istraživanja, onih modela koji su specifično izrađeni i testirani za pojedinu lokaciju.

Pri izradi modela specifičnih za pojedine lokacije, doista su u većini slučajeva multivarijatni modeli pokazali najbolje prediktorne karakteristike: $R^2$ (Šćuza 1) = 92%, $R^2$ (Šćuza 2) = 91%, $R^2$ (Bijela uvala) = 85%, $R^2$ (Lanterna) = 55%. Jedino su kod lokacije Funtana i lokacije Kamenjak univarijatni modeli bili rangirani iznad multivarijatnih (redom $R^2$ = 90% i $R^2$ = 66%). Prema tome, na lokacijama Šćuza 1, Šćuza 2 i Funtana, univarijatni modeli koji uključuju faktor L_ktot (ukupna duljina kauloida) najbolje opisuju varijabilnost u biomasi (s $R^2$ od preko 90%). Tako univarijatni modeli s navedenom varijablom za lokacije Šćuza 1 i Šćuza 2 nisu najviše rangirani modeli, međutim objašnjavaju samo nekoliko posto manje varijabilnosti od najviše rangiranih multivarijatnih modela (za lokaciju Šćuza 1 samo 2% razlike s multivarijatnim modelom u objašnjavanju varijabilnosti, dok kod lokacije Šćuza 2 nema razlike). Najbolji univarijatni model za lokaciju Bijela uvala uključuje varijablu N_k, međutim objašnjava gotovo 12% manje varijabilnosti u biomasi u usporedbi s visokorangiranim multivarijatnim modelom. Univarijatni model za lokaciju Funtana koji uključuje L_ktot je najbolje rangirani model ($R^2$ = 90%). Svi modeli za lokacije Kamenjak i Lanterna objašnjavaju jako nizak postotak varijabilnosti biomase (Kamenjak – manje od 66%, Lanterna – manje od 55%).

U 2009. godini, mjerenje biomase i morfometrijskih karakteristika provedeno je na zapadnoj obali Istre u plitkim staništima (Iveša i sur., 2016) te su za morfometrijske karakteristike dobiveni podaci na razini jedinki, dok je biomasa dobivena samo na razini kvadrata (sumarna biomasa jedinki u kvadratu; sveukupno uzorak od 39 kvadrata). Iz tog razloga, morfometrijske karakteristike su sumirane zbog standardizacije s biomasom. U ovom istraživanju, izrađeni su univarijatni i multivarijatni modeli koji su naposlijetku uspoređeni u svrhu odabira najpraktičnijeg modela u kontekstu vjerodostojnosti predikcije i praktičnosti korištenja.

Multivarijatni modeli su se pokazali najpouzdanijima za predikciju biomase na razini kvadrata (npr. najbolji model Tot_WW ~ L_ktot + Grane + N_k; AICC = -164.026064 i $R^2$ = 0.9985057). Neovisno o tome, pri izradi prikaza odnosa aktualnih/izmjerenih vrijednosti i modelom predviđenih vrijednosti, vidljivo je da varijabla Grane predstavlja najbolju varijablu za predikciju biomase zasebno, dakle kao univarijatni model. Iako su neki od multivarijatnih modela hierarhijski rangirani na višoj poziciji od zasebne varijable Grane, univarijatni model s navedenom varijablom objašnjava samo 0,03% manje varijabilnosti nego najbolji multivarijatni model, što opravdava njegovo korištenje u kontekstu praktičnosti (Campbell i Starko, 2021). Iz grafičkog prikaza aktualnih i predviđenih vrijednosti, jasno je vidljivo da svaki multivarijatni model koji sadržava navedenu varijablu pokazuje odlične performanse pri predikciji biomase. Potrebno je napomenuti da varijabla Grane zapravo ne predstavlja morfometrijsku karakteristiku, već veliki dio ukupne biomase unutar kvadrata, stoga je visoko korelirana sa samom varijablom koja se predviđa, ukupnom biomasom. Dakle, jedinke su uzorkovane i odijeljene na višegodišnje (višegodišnji kauloid) i sezonske dijelove (grane). Uzorkovanje je obavljeno u proljeće kada je vrsta na vrhuncu svog vegetacijskog razdoblja, stoga su primarne grane (Grane) bile potpuno razvijene i generalno su činile veliku frakciju ukupne biomase (uglavnom preko 66%).

Samo saznanje o efikasnosti modela koji uključuje varijablu Grane, predstavlja korak ka smanjenju invazivnosti i destruktivnosti trenutnih metoda prikupljanja podataka o biomasi. Trenutna praksa za monitoring, praćenje stanja ili provođenje eksperimenata je prikupljanje cijelih jedinki i mjerenje istih u laboratorijskim uvjetima. Budući da su grane dijelovi organizma koji se razvijaju preko zime, proljeća i ranog ljeta, nakon čega zbog endogenih procesa najvjerojatnije uvjetovanih okolišnim čimbenicima (poglavito temperaturom) otpadaju ili degradiraju (Ercegović, 1952; Marzocchi i sur., 2003; Mulas i sur., 2022a), uzorkovanje samih grana u razdoblju prije samog otpuštanja istih ne bi značajno degradiralo ostatak talusa alge, tj. višegodišnji kauloid, iz kojeg bi iduće sezone izrasla gotovo ista količina biomase grana (uz vjerojatno minimalna odstupanja zbog same starosti jedinke ili varijacija u okolišnim čimbenicima; Ercegović, 1952).

Budući da se za plitka staništa, korištenje modela koji obuhvaća varijablu Grane pokazalo efikasno na širem području zapadne obale Istre, što prema definiciji predstavlja opći model predikcije, postoji mogućnost da se ista metoda ili model može iskoristiti u drugim dijelovima Jadrana ili Sredozemnog mora kao učinkovit alat za procjenu ukupne biomase. Šire područje (na razini

Jadranskog mora) nije testirano, stoga je za ostale regije potrebno prvo izraditi regionalno specifične modele, te izvršiti usporedbu modela uključujući regiju kao jedan od glavnih faktora. Shodno tome, nakon odabira najboljeg univarijatnog modela, izvršen je eksperiment ponovnog uzorkovanja kako bi se utvrdio minimalni uzorak potreban za izradu pouzdanog modela predikcije ukoliko bude bilo potrebe za izradu novih modela na drugim lokacijama/regijama Jadrana ili Mediterana (vidi Campbell i Starko, 2021). Prema rezultatima provedenog eksperimenta ponovnog uzorkovanja, korištenje uzorka od 12 do 15 kvadrata trebalo bi biti dovoljno za izradu modela predikcije sa sličnim karakteristikama (iste vrijednosti koeficijenta nagiba i koeficijenta odsječka na osi y) onog modela izrađenog koristeći podatke iz 39 kvadrata/uzoraka (veličina uzorka korištenog u našem istraživanju). Navedeno predstavlja korak naprijed ka izradi preciznih modela predikcije biomase na širokom području, pri tome koristeći učinkovite i nedestruktivne metode uzorkovanja, koje su manje invazivnog karaktera od postojećih.

Zaključno, najveći potencijal za daljnja istraživanja ima univarijatni model koji uključuje varijablu L_ktot (ukupnu duljinu kauloida) za lokacije Šćuza 1 (Šćuza-epilitske jedinke), Šćuza 2 (Šćuza-pleustofitske jedinke) i Funtana. Modeli za lokacije Bijela uvala, Kamenjak i Lanterna nisu dovoljno dobro opisali varijabilnost biomase. Razlog niske razine opisa biomase potencijalno ovisi o nekoj varijabli koja nije obuhvaćena ovim uzorkovanjem i analizom, ili o razdoblju uzorkovanja zbog same sezonske varijabilnosti vrste (Mulas i sur., 2022a; Valdazo i sur., 2020). Shodno tome, kao jedan od nedostataka ali ujedno i poteškoća pri izradi modela na razini jedinki iz recentnih podataka, svakako je razdoblje prikupljanja uzoraka. Jedinke u različitim staništima pokazuju različiti vegetacijski rast (Ercegović, 1952). Primjerice zbog iznimno visokih temperatura u laguni Šćuza, uzorci prikupljeni ljeti zadržavaju samo određeni postotak grana u usporedbi s maksimumom vegetacije koji je uglavnom u zimsko/proljetnom razdoblju. Često zbog veće hidrodinamike, jedinke u lokvicama i plitkom infralitoralu ne doživljavaju toliko ekstremne temperaturne uvjete, te ukoliko im otpadaju grane, dolazi do rasta novih, što doprinosi održavanju biomase. Međutim i kod njih se dakako ističu sezonalne razlike u formaciji primarnih grana. Stoga, osim ljetnog uzorkovanja provedenog u ovom istraživanju, potrebno je uzeti u obzir utjecaj sezone na rezultate, te u budućnosti obuhvatiti uzorkovanje i u ostalim sezonama. Dodatno, praćenje abiotičkih parametara na različitim lokacijama i sezonama, bi pružalo kvalitetniju sliku o glavnim čimbenicima koji utječu na alometrijske odnose. Nasuprot tome, povijesni podaci uzorkovanja u

vegetacijskom maksimumu vrste, predstavljaju vrijedne informacije u kontekstu točne procjene biomase.

## 6.2. Termotolerancija

U eksperimentu termotolerancije, primijetili smo da vrsta *Gongolaria barbata* pokazuje izuzetnu otpornost na klimatske ekstreme, podnoseći temperature mora do 32 °C i pokazuje sposobnost morfološkog i fiziološkog oporavka nakon dugotrajne izloženosti toplinskom stresu. Testirane jedinke pokazuju termalnu toleranciju veću od one ranije zabilježene za ovu vrstu, s procijenjenim pragovima od 23 °C (Ercegović, 1952) i ≤ 30 °C u izoliranim slučajevima (Iveša i sur., 2022; Orfanidis, 1991).

Istraživanjem morskih toplinskih valova na južnoj istarskoj obali, uključujući razdoblje od 1983. do 2023. godine, naši rezultati potvrđuju da su u posljednjem desetljeću u usporedbi s prethodnima značajno porasle frekvencija, trajanje i intenzitet morskih toplinskih valova. Trenutačno nije moguće pravilno otkriti MTV-ove unutar lagune, prema definiciji Hobday i sur. (2018, 2016), zbog nedostatka dugoročnih podataka o temperaturi, a SST može biti neprikladan za detekciju varijabilnosti na malim skalama (Smale i Wernberg, 2009; Stobart i sur., 2016). Međutim, analizirajući trendove promatrane izvan lagune putem satelitskih podataka, možemo zaključiti da su uvjeti u laguni vjerojatno slični, pogotovo zbog trendova zagrijavanja. U skladu s prevladavajućim globalnim trendovima, predviđa se rastuća frekvencija i intenzitet MTV-ova u idućim desetljećima (Smith i sur., 2023) što sugerira da je procjena temperaturnih pragova za populaciju *G. barbata* u laguni Šćuza od ključne važnosti za zaštitu, uzimajući u obzir da je ovo posljednja, kontinuirana morska šuma ove vrste duž istarske obale.

Tijekom uzorkovanja talusa, temperatura mora u laguni bila je otprilike 12–13 °C, a vrsta *G. barbata* bila je u svom vegetacijskom maksimumu s dobro razvijenim granama i receptakulima. Međutim, tijekom našeg *ex situ* eksperimenta, postupno smo povećavali temperaturu kako bismo simulirali proljetno/jesenske (18 °C) i ljetne (28, 30, 32 i 34 °C) temperaturne uvjete.

Izuzetno visoke i izuzetno niske temperature opažaju se u laguni svake godine. Osim izraženih sezonalnih varijacija, ekstremne fluktuacije temperature također su opažene na dnevnoj razini (Prilog Slika P8), kao rezultat dnevnih promjena u atmosferskim i morskim uvjetima, dok je raspon bio još viši u hladnijim razdobljima. Naš scenarij MTV-ova od 17 dana realističan je s obzirom na

zabilježene maksimalne vrijednosti, ali moramo uzeti u obzir da dnevne fluktuacije temperature mogu imati ključnu ulogu u ublažavanju i kompenzaciji utjecaja ekstremnih temperatura u prirodi (Csordas i sur., 2024). Reakcije na događaje zagrijavanja mogu varirati ne samo kao posljedica karakteristika MTV-ova, već i zbog postojeće razlike između populacija/jedinki kao rezultat prijašnjih poremećaja ili lokalne prilagodbe (Smith i sur., 2023). Ipak, rezultati našeg pristupa fiksnim temperaturnim granicama sugeriraju da su jedinke iz lagune vjerojatno prilagođene čak i ekstremnijim scenarijima nego što trenutno doživljavaju u prirodi te će vjerojatno izdržati daljnje zagrijavanje. Važno je, međutim, napomenuti da neki istraživači smatraju da uključivanje samo fiksnih termalnih pragova predstavlja pojednostavljeno rješenje, te sugeriraju simulacije u kojima se razmatraju trajno zagrijavanje i MTV-ovi s različitim razinama varijacije temperature, jer najviši temperaturni tretmani ne izazivaju uvijek i najjači učinak (Straub i sur., 2022).

Stres uzrokovan temperaturom ima kapacitet narušiti stanične biološke procese (Davison i Pearson, 1996) i utjecati na fotosintetske performanse (Crafts-Brandner i Salvucci, 2002), uključujući funkcionalnost fotosintetskog aparata (Bischof i Rautenberger, 2012). U našem istraživanju, primijećen je potencijal za oporavak fotosintetskih performansi kod jedinki izloženih temperaturama čak do 32 °C. Pretpostavljamo da čista voda i visoka dostupnost svjetla djelomično ublažava očekivani negativni utjecaj stresa uzrokovanog temperaturom na fotosintetski prinos (*Fv/Fm* i *YII*). Nedavno istraživanje, pokazalo je da su neke smeđe alge iz hladnih voda u uvjetima visoke svjetlosti bile otporne na simulirane aktivnosti MTV-ova (Bass i sur., 2023). U laguni smo primijetili da su stope sedimentacije visoke (što potencijalno ograničava dostupnost svjetla); međutim, obzirom na plitki položaj ove populacije unutar lagune, moguće je da izloženost većim intenzitetima svjetlosti potencijalno ublažava očekivane nepovoljne učinke visokih temperatura.

Vrsta *G. barbata* pokazuje godišnji ciklus rasta u kojem jedinke obično pokazuju kontinuirani rast, s većim stopama rasta u hladnijim sezonama i manjim stopama u toplijim sezonama. Međutim, prema Ercegoviću (1952), u zaklonjenim područjima poput zaljeva i laguna, gdje je cirkulacija vode ograničena, vrsta *G. barbata* doživljava razdoblje estivacije tijekom ljetnog razdoblja zbog intenzivnih uvjeta zagrijavanja. Navedeno razdoblje mirovanja može trajati dulje vrijeme, do 3 mjeseca, tijekom kojeg se gube sezonalni dijelovi alge. Ovaj smo trend primijetili kako *in situ*, tako i u laboratoriju, te pretpostavljamo da se naknadna regeneracija pokreće snižavanjem temperature (Prilog Slika P9). U ovom istraživanju na kraju eksperimenta (nakon 38 dana), sve su jedinke

prenesene u kamene bazene i izložene stalnom otvorenom protoku morske vode, čija je temperatura bila otprilike ~15 °C. Primijetili smo znakove regeneracije i ponovnog rasta grana iz kauloida u razdoblju od nekoliko tjedana, što ukazuje na sposobnost jedinki da podnesu, prežive i morfološki se regeneriraju čak i nakon produljenog izlaganja ekstremnim temperaturama. Međutim, važno je napomenuti da je regeneracija bila ograničena među jedinkama prethodno izloženim tretmanu temperature od 34 °C, kod kojih je samo dvije od devet jedinki pokazalo znakove regeneracije, što sugerira mogući temperaturni prag za oporavak. Slično je uočeno i u slovenskoj laguni Stjuža, gdje u ljetnom razdoblju, pri ekstremnim temperaturama, ukupna duljina talusa i duljina primarnih grana pokazuju niske vrijednosti kod vrste *Cystoseira foeniculacea* (Battelli i Catra, 2023), dok u hladnijem dijelu godine navedene karakteristike pokazuju više vrijednosti.

Iako se očekuje da će ljetni ekstremi i produljeno izlaganje iznad temperaturnih granica dovesti do povećane godišnje smrtnosti odraslih jedinki u laguni, pretpostavlja se da bi MTV-ovi mogli dodatno poremetiti sezonalni vegetativni ciklus vrste, što rezultira raznim odgovorima organizma (Bevilacqua i sur., 2019). Temperatura utječe na reproduktivni potencijal i procese razmnožavanja kod raznih vrsta algi (Andrews i sur., 2014; Bartsch i sur., 2013; de Bettignies i sur., 2018; Lokovšek i sur., 2024; Muth i sur., 2019). Na primjer, zagrijavanje oceana povezano je sa smanjenjem reprodukcije i većom od očekivane smrtnosti sporofita (Breeman, 1988; Ladah i Zertuche-González, 2007; Wernberg i sur., 2011). Lokalno, MTV koji se dogodio u veljači 2019. godine u sjevernom Jadranu, izazvao je fenološki pomak koji je potaknuo rano sazrijevanje jedinki vrste *G. barbata* u nekim naseljima (Bevilacqua i sur., 2019), i još uvijek nisu jasne posljedice takvog pomaka na dugoročnu dinamiku populacije (Csordas i sur., 2024). U našem istraživanju, u trenutku uzorkovanja (veljača 2023.), gotovo su sve jedinke bile plodne, i primijetili smo da je tijekom razdoblja aklimatizacije oslobađanje gameta bilo potaknuto na temperaturi od 18 °C, što je dovelo do uspješne oplodnje i pričvršćivanja propagula na podlogu za koju su bile pričvršćene odrasle jedinke (vapnenački kamen). Međutim, mlade jedinke su preživjele samo u uvjetima kontrole (18 °C). Štetni učinci visoke temperature (28 °C) na juvenilne jedinke također su primijećeni kod vrste *Ericaria crinita* (Verdura i sur., 2021), sredozemne vrste koja dijeli slične biološke značajke s vrstom *G. barbata*. Nasuprot tome, kod drugih vrsta pokazana je prilagodljivost ranih faza životnog ciklusa termalnom stresu. Na primjer, termalno aklimatizirani sporofiti vrste *Saccharina latissima* pokazali su povećanu efikasnost fotosinteze i bilo im je potrebno manje svjetlosti za postizanje maksimalnih stopa fotosinteze pri visokim temperaturama (Davison i sur.,

1991), a embriji toplinski prilagođene vrste *Fucus vesiculosus* pokazali su povećane stope preživljavanja tijekom razdoblja toplinskog stresa (Li i Brawley, 2004). S obzirom na jedinstvenost proučavane populacije u laguni Šćuza, slična istraživanja trebala bi se provesti na juvenilnim jedinkama iz Šćuze, ali i na juvenilnim jedinkama drugih staništa (plitke uvale i lokvice), možda i s ciljem povezivanja otpornosti na visoke temperature s genetskim obilježjima i filogeografijom (Liesner i sur., 2020).

Trenutačno postoji veliki interes za razumijevanje uloge temperature u različitim životnim fazama cistozira (de Caralt i sur., 2023) jer je gubitak populacija sada široko rasprostranjena pojava diljem Sredozemlja (Thibaut i sur., 2015), a aktivna obnova populacija dobiva zamah kao jedna od glavnih mjera zaštite (Cebrian i sur., 2021). Nažalost, kao izvor propagula, populacija vrste *Gongolaria barbata* u laguni Šćuza je geografski izolirana i slabo je povezana sa susjednim priobaljem na jugu Istre (Iveša i sur., 2022). Vrsta *G. barbata* poznata je po niskoj sposobnosti širenja (Verdura i sur., 2018), stoga je mala vjerojatnost da će se širiti izvan lagune osim ako se isto ne potiče aktivnom obnovom. Obzirom na ekstremne temperature izmjerene u laguni Šćuza i neočekivano preživljavanje populacije *G. barbata* u tom okruženju, ova populacija je potencijalan izvor termalno tolerantnog reprodukcijskog materijala za obnovu populacija, što bi moglo poboljšati izglede za uspješne i efikasne pokušaje obnove vrste u istarskom priobalju. Međutim, potrebno je daljnje istraživanje kako bi se utvrdilo je li ova populacija jedinstveni ekotip, koji je razvio termalnu prilagodbu kroz mnoge generacije ili putem izloženosti akutnom toplinskom stresu (Coleman i Wernberg, 2020; King i sur., 2018). Bitno je istaknuti da je korist istraživanja ove vrste dvostruka. Moguće je optimizirati vrijeme sadnje kako bi poboljšali izglede za uspjeh obnove (Cebrian i sur., 2021) ili temeljitije istražiti ranjivost ove rijetke populacije. Nadalje, uloga i interakcija čimbenika poput kisika, svjetlosti, razine hranjivih tvari, eutrofikacije i ekstremno niskih plima ostaju nepoznati. Također, uloga epibionta (primjećujemo visoki pokrov epibionta na jedinkama *G. barbata* tijekom ljeta) i brstioca (npr. poznatih čimbenika koji utječu na opadanje vrsta; Iveša i sur., 2022, 2016) nije još uvijek u potpunosti istražena, te zahtijeva daljnje istraživanje.

## 6.3. Uzgoj

U eksperimentu uzgoja, istražili smo utjecaj abiotičkih čimbenika tijekom početne faze *ex situ* uzgoja na kratkoročne i dugoročne razvojne promjene mladih jedinki vrste *Gongolaria barbata* iz

lagune Šćuza. Također pružamo ključne informacije o praksi skladištenja i rukovanja uzgojenim materijalom prije samog prijenosa *in situ*. Osim toga, naglašava se važnost istovremenog praćenja abiotičkih čimbenika i pokazatelja uspjeha rasta ranih stadija vrste *G. barbata in situ*. Navedeno je ključno radi dobivanja informacija o utjecaju okolišnih čimbenika na rast i razvoj talusa alge, što će pomoći u određivanju optimalnih uvjeta preživljavanja *in situ*, kao i u definiranju optimalnog razdoblja za *in situ* uzgoj algi. Potom ističemo stratešku uporabu donorskih lokacija u ranim fazama obnove. Budući da donorske lokacije već podržavaju zdrave populacije zbog potencijalne odsutnosti štetnih čimbenika (Smith i sur., 2023; Verdura i sur., 2023), "povrat" mladih jedinki u donorske populacije teoretski povećava mogućnost dugoročnog preživljavanja. Abiotičke čimbenike na tim lokacijama potrebno je temeljito pratiti kako bi se prikupile osnovne informacije o abiotičkim zahtjevima vrste, s ciljem olakšavanja procesa odabira budućih lokacija obnove. Posljedično, ovaj pristup će značajno povećati vjerojatnost uspješnih pokušaja obnove populacija.

U prvom dijelu eksperimenta, rezultati su pokazali da svjetlost sama po sebi nije značajno utjecala na rast jedinki nakon 21 dan uzgoja u *ex situ* uvjetima. Međutim interakcija svjetlosti i vremena je bila značajna u pojedinim točkama mjerenja (Slika 45), u korist grupe koja je bila na većoj svjetlosnoj razini, što potvrđuje da više razine svjetlosti potpomažu boljem rastu (Irving i sur., 2009). Rezultati preživljavanja su pak pokazali da je svjetlost imala značajan utjecaj na rast juvenilnih jedinki, s značajnim razlikama detektiranim na datume 02.05.2023., 05.05.2023. i 12.05.2023, u korist većeg preživljavanja kod grupe koja je bila izložena nižoj razini svjetlosti. Iako su jedinke na većoj svjetlosnoj razini pokazivale uglavnom veće vrijednosti rasta, mnogi primjerci u toj skupini su izgledali nezdravo ili su bili depigmentirani, a primijećeno je i odvajanje mnogih jedinki od supstrata (Prilog Slika P10). Navedeno je detektirano praćenjem stope preživljavanja, koje je bilo značajno niže kod grupe izložene višem svjetlosnom intenzitetu. Nadalje, u akvarijima izloženim višim razinama svjetlosti, zabilježeno je intenzivno razmnožavanje dijatomeja, pojava primijećena već 23. travnja, što se manifestiralo kao smeđe obojenje vode. Unatoč filtraciji morske vode namijenjene uzgoju, kontaminacija je trajala tijekom cijele faze *ex situ* uzgoja. Razlog vrlo vjerojatno leži u nemogućnosti temeljitog čišćenja receptakula u početnoj fazi eksperimenta. Pretpostavljamo da su receptakuli sadržavali dijatomeje koje su se brzo razmnožavale pod utjecajem intenzivne svjetlosti i hranjivog uzgojnog medija (Prilog Slika P11). Zanimljivo je da je kontaminacija dijatomejama bila značajno smanjena pri nižim razinama svjetlosti. Većina kontaminacije je uklonjena nježnim ispiranjem površine glinenih

pločica filtriranom morskom vodom i laganim četkanjem površine finom četkicom, te redovitom zamjenom uzgojnog medija. Prisutnost dijatomeja mogla je doprinijeti razlikama u preživljavanju između dvije istražene grupe. U nekim studijama koriste se agensi za kontrolu dijatomeja kao što je $GeO_2$ (Shea i Chopin, 2007). Također vrijedi istaknuti značajnu učinkovitost UV zračenja kao metode predtretmana morske vode prije *ex situ* uzgoja (Lokovšek i sur., 2023).

Prema našim opažanjima, varijacije u intenzitetu svjetlosti, u kombinaciji s hranjivim medijima, vjerojatno mogu značajno utjecati na razmnožavanje dijatomeja, bilo pojačavajući (viša razina svjetlosti) ili suzbijajući njihov rast (niža razina svjetlosti). To, zauzvrat, utječe na ključne razvojne pokazatelje naše kulture makroalgi od interesa. Negativni utjecaj bentičkih i pelagičkih dijatomeja utvrđen je na odraslim jedinkama komercijalnih vrsta makroalgi (Patil i sur., 2024), a slično je utvrđeno i kod bentičkih cvjetanja oportunističkih makroalgi na cistozire *in situ* (Iveša i sur., 2021). Također postoje i dokazi o negativnom utjecaju zasjenjivanja na *in situ* rast kelpa, što je posredovano pelagičkim cvjetanjima (Kavanaugh i sur., 2009).

Također, važno je napomenuti ograničenja naše studije i biti oprezan u tumačenju rezultata. Nedostajao nam je mehanizam za određivanje fiziološkog stanja uzgojenih talusa. Razlike u pigmentaciji bile su vidljive pri analizi vertikalnih fotografija, ali nismo uzimali u obzir razliku između pigmentiranih ili depigmentiranih jedinki tijekom mjerenja. To znači da su mjerene neke depigmentirane jedinke, bez relevantnih informacija o njihovoj vitalnosti, razvojnom potencijalu ili potencijalu oporavka. Unatoč navedenom, značajan broj jedinki je preživio, te bio korišten u sljedećoj fazi eksperimenta. Depigmentacija je također uočena kod jedinki izloženih povišenim temperaturama tijekom ranih razvojnih faza u nekim drugim studijama gdje su autori koristili depigmentaciju kao znak smrtnosti (Lokovšek i sur., 2024).

Premještanje glinenih pločica u otvoreni sustav s nefiltriranom morskom vodom rezultiralo je razvojem nitastih algi (Prilog Slika P12). To je zahtijevalo pažnju te redovno čišćenje akvarija i glinenih pločica. Obzirom na vrijeme i trud potreban za održavanje akvarija i pločica, korištenje nefiltrirane vode, u kombinaciji s nešto višom temperaturom i svjetlosti (Prilog Slika P13), pokazalo se neoptimalnim. Učinkovitija alternativa mogla bi biti zatvoreni sustav koji koristi filtriranu, UV steriliziranu (Lokovšek i sur., 2023) i ohlađenu morsku vodu za skladištenje pločica s mladim jedinkama *G. barbata* prije njihove transplantacije u prirodno okruženje. Ovaj pristup mogao bi značajno smanjiti kontaminaciju morske vode u akvariju, čime bi se umanjila potreba za

čišćenjem. Minimalizacija osvjetljenja u ograničenom razdoblju također bi potencijalno spriječila brzi razvoj obraštaja, no s druge strane, smanjenje osvjetljenja ne bi značajno utjecalo na juvenilne primjerke *G. barbata* (Irving i sur., 2009). Nadalje, premještanje glinenih pločica s juvenilnim jedinkama na lokaciju obnove kratko nakon zasijavanja, utječe na smanjenje onečišćenja pločica, što je i dokazano raznim istraživanjima (Lokovšek i sur., 2023; Orlando-Bonaca i sur., 2021; Savonitto i sur., 2021).

Dvije eksperimentalne skupine uzgojenih jedinki (svaka u svom kavezu) promatrane su tijekom duljeg razdoblja nakon *in situ* transplantacije (Prilog Slika P14). Posebno, u vrijeme transplantacije, temperature mora su prelazile 26 °C, a unutar nekoliko dana, narasle su iznad 30 °C. Primarni pokazatelji uspjeha rasta jedinki (visine talusa) prvi put su izmjereni mjesec dana nakon transplantacije, 11.07.2023. Tijekom tog razdoblja, temperature su često dosezale 30 °C, i to do 28.08.2023., kada su počele postupno padati. Zanimljivo, ponovno povećanje rasta jedinki u oba kaveza zabilježeno je tek kad su temperature počele opadati, stabilizirajući se u rasponu između 20 i 24 °C (tijekom jeseni). Kako su temperature nastavile s opadanjem, ukupan rast je stagnirao, odnosno uočen je tek blagi trend povećanja vrijednosti visine talusa. Nadalje, tek kad su temperature krenule rasti negdje iznad 13 °C, zabilježen je ponovni nagli rast talusa (Slika 47). Ova otkrića su posebno zanimljiva u kontekstu vremena transplantacije. Tijekom *ex situ* uzgoja od 18.04.2023. do 07.06.2023. (približno 50 dana), jedinke su očito dovoljno narasle i razvile dovoljno otpornosti da tijekom *in situ* transplantacije izdrže i prežive stresne temperaturne uvjete tipične za lagunu tijekom ljeta. Osim samog preživljavanja i tolerancije, jedinke su također pokazale sposobnost aktivnog oporavka i rasta nakon izlaganja tako ekstremnim temperaturama.

U studiji koju su proveli Lokovšek i sur. (2024), otkriveno je da izlaganje ranih stadija vrste *G. barbata* visokim temperaturama može izazvati deformacije i povećati smrtnost, posebno pri temperaturama od 24 i 28 °C. Suprotno tome, niske temperature od 15 i 18 °C potiču rast mladih jedinki, kao i regeneraciju odraslih jedinki (Bilajac i sur., 2024). Nadalje, Irving i sur. (2009) zaključili su da niže temperature omogućavaju rast ranih razvojnih faza vrste *G. barbata*. Fabbrizzi i sur. (2023) donose informacije o sposobnosti adaptacije juvenilnih jedinki vrste *Gongolaria barbata* na produljene MTV-ove do temperature od 28,5 °C. U našem eksperimentu termotolerancije, temperature iznad 28 °C bile su pogubne za mlade jedinke u njihovim ranim fazama rasta, dok su zrele jedinke iz lagune pokazale otpornost na znatno više temperature tijekom

duljeg izlaganja (Bilajac i sur., 2024). Povišene temperature također su se pokazale štetnima za rane i adultne razvojne faze jedinki drugih vrsta unutar skupine *Cystoseira sensu lato*, konkretno za adultne i juvenilne stadije vrsta *Ericaria crinita* i *Ericaria mediterranea* (de Caralt i sur., 2023; Verdura i sur., 2021), te za reproduktivne strukture adultnih jedinki i zigote vrste *Ericaria amentacea* (Cimini i sur., 2024).

Jasno odjeljivanje faze najvećeg prirasta juvenilnih jedinki *Gongolaria barbata* od perioda mirovanja i/ili minimalnog prirasta u odnosu na abiotske čimbenike dobiveno je analizom glavnih komponenti (PCA). U skladu s okolišnim uvjetima karakterističnim za period kasne zime i ranog proljeća u laguni Šćuza, aktivni rast juvenilnih jedinki u oba kaveza (C1 Δrast i C2 Δrast; Slika 50) odvijao se u uvjetima nižih temperatura, sniženog saliniteta i svjetlosti, te umjerenog porasta produktivnosti vodenog stupca kao i ukupnog protoka sedimentacije. Generalno, dinamika tvari u moru i u zatvorenim sustavima poput laguna je kompleksna, kao i njihov utjecaj na rast vrste *G. barbata*. Kombinacijom *in situ* i *ex situ* eksperimenata, Lenzi i sur. (2024) su zaključili da odrasle jedinke *G. barbata* nisu posebno osjetljive po pitanju koncentracije nutrijenata te pokazuju rast u oligotrofnim, mezotrofnim i hipertrofnim uvjetima. Međutim, najbolji rast pokazuju u hipertrofnim uvjetima, pri visokim koncentracijama ortofosfata i TIN-a (kojeg uglavnom čine nitrati), no u takvim uvjetima su u kompeticiji s oportunističkim algama koje imaju veće kapacitete asimilacije nutrijenata.

U ovom istraživanju, u laguni Šćuza su izmjerene velike količine organske frakcije sedimenta, kao i u drugim istraživanjima (Podolšak, 2022), što može biti rezultat razgradnje ostataka cvjetnica (Puhr i Pikelj, 2012), konkretno u našem slučaju vrste *Cymodocea nodosa*. Što se tiče nutrijenata, poznato je da oportunističke alge mogu igrati značajnu ulogu u njihovom ciklusu, čineći važan izvor nutrijenata općenito, ali pogotovo u zatvorenim sustavima poput laguna (Lenzi i sur., 2024, 2017). Navedeno je pogotovo zanimljivo zbog toga što se maskimumi vegetacije ne preklapaju kod dviju dominantnih vrsta u laguni, morske cvjetnice *C. nodosa* i smeđe alge *G. barbata*. Teoretski, moguće je da razgradnja jednogodišnjih dijelova jedne vrste ima utjecaja na regeneraciju nutrijenata koje druga vrsta asimilira, i obrnuto. Osim toga, u okolici lagune nalaze se i poljoprivredne površine, stoga je moguć i „vanjski“, tj. antropogeni donos nutrijenata. Kaleb i sur. (2023) dokazuju pozitivni utjecaj uzgojnog medija bogatog nutrijentima, fitohormonima i polisaharidima na rast primarnih grana vrste *G. barbata*, kao i na mogućnost indukcije zrelosti

reproduktivnih struktura. Time naglašavaju važnost nutrijenata (pogotovo dušika i fosfora) kao i mikronutrijenata (Molibden) u rastu i razvoju organizma.

Zaključno, ovaj eksperiment istražuje utjecaj svjetlosti na rane razvojne faze vrste *G. barbata* tijekom *ex situ* uzgoja i njezin dugoročni utjecaj na preživljavanje i rast jedinki nakon transplantacije u prirodno okruženje. Rezultati pokazuju da intenzitet svjetlosti i drugi abiotički čimbenici u prirodnom okolišu, poput temperature, nutrijenata i sedimentacije, igraju ključnu ulogu u uspješnosti uzgoja i transplantacije jedinki *G. barbata*. Jedini rizik tijekom *ex situ* uzgoja predstavljala je kontaminacija dijatomejama u tretmanu uzgoja s visokim svjetlosnim intenzitetom. Ovo istraživanje naglašava važnost optimalnog upravljanja uvjetima uzgoja *ex situ* i skladištenja prije same transplantacije, kao i stratešku uporabu uvjeta donorskih lokacija kako bi se osigurali povoljni uvjeti za dugoročan rast i preživljavanje alge. Na temelju rezultata, preporučuje se daljnje istraživanje i optimizacija uvjeta uzgoja, posebno u pogledu svjetlosnih i temperaturnih čimbenika, kako bi se povećala uspješnost obnove populacija *G. barbata* u prirodnim staništima.

# 7. ZAKLJUČCI

1. Kartiranje vrste *Gongolaria barbata* na zapadnoj i južnoj obali Istre pokazalo je da se preostala nalazišta ove vrste nalaze u plitkom infralitoralu i mediolitoralnim lokvicama, s fragmentiranim naseljima i niskom brojnošću jedinki. U središnjem dijelu zapadne obale Istre, *G. barbata* pronađena je u plitkom infralitoralu na lokacijama Lanterna i Funtana te u mediolitoralnim lokvicama u Bijeloj uvali. Na jugu Istre, na rtu Kamenjak, evidentirano je nekoliko lokvica s mjestimičnim naseljima vrste *G. barbata*, dok je jedina kontinuirana morska šuma ove vrste zabilježena u obalnoj laguni Šćuza.
2. Utvrđene su značajne razlike u morfometriji i biomasi između jedinki *G. barbata* prikupljenih u plitkom infralitoralu, lokvicama i obalnoj laguni Šćuza. Talusi iz lagune Šćuza, kao i oni iz lokvica na Kamenjaku i u Bijeloj uvali, ističu se većim dimenzijama, dok talusi iz plitkog infralitorala pokazuju najniže vrijednosti za većinu izmjerenih morfometrijskih karakteristika i biomase.
3. Pleustofitski talusi s lokacije Šćuza 2 pokazuju najviše vrijednosti mokre biomase (W_w) i većine morfometrijskih karakteristika, pri čemu se posebno ističu ukupna duljina kauloida (L_ktot) i broj kauloida (N_k). Epilitski talusi s lokacije Šćuza 1 također su karakterizirani visokim vrijednostima ukupne duljine kauloida (L_ktot) i broja kauloida (N_k), ali su te vrijednosti znantno niže u usporedbi s talusima s lokacije Šćuza 2. Nasuprot tome, talusi iz lagune Šćuza, u usporedbi s ostalim proučenim populacijama, pokazuju najniže vrijednosti promjera bazalne pločice (Fi_bas) i promjera kauloida (Fi_k).
4. Talusi iz plitkog infralitorala lokacija Lanterna i Funtana pokazuju najniže vrijednosti biomase i većine morfometrijskih karakteristika. U usporedbi s ostalim lokacijama, talusi s ovih dviju lokacija imaju najniže vrijednosti mokre biomase (W_w), ukupne duljine kauloida (L_ktot), duljine kauloida (L_k), duljine talusa (L_t) i broja kauloida (N_k). Suprotno tome, talusi na lokaciji Lanterna izdvajaju se najvećim vrijednostima promjera bazalne pločice (Fi_bas) i promjera kauloida (Fi_k) u usporedbi s ostalim proučavanim lokacijama.
5. Talusi iz mediolitoralnih lokvica lokacije Bijela uvala se ističu s visokim vrijednostima ukupne duljine kauloida (L_ktot), mokre biomase (W_w) i broja kauloida (N_k), dok su vrijednosti duljine kauloida (L_k) i duljine talusa (L_t) niže u usporedbi s talusima na lokacijama Šćuza 1, Šćuza 2 i Kamenjak. Talusi iz mediolitoralnih lokvica lokacije

Kamenjak izdvajaju se visokim vrijednostima mokre biomase (W_w) te izrazito visokim vrijednostima duljine kauloida (L_k), duljine talusa (L_t), promjera bazalne pločice (Fi_bas) i promjera kauloida (Fi_k).

6. Usporedba recentnih i povijesnih podataka ukazuje na značajne promjene u morfometrijskim karakteristikama vrste *G. barbata* između 2009. i 2023. godine u plitkom infralitoralu, s posebnim naglaskom na degradaciju populacije na lokaciji Lanterna. Na lokacijama Lanterna i Funtana talusi iz 2009. godine pokazivali su veće vrijednosti ukupne duljine kauloida (L_ktot), duljine kauloida (L_k), duljine talusa (L_t) i broja kauloida (N_k) u usporedbi s talusima s istih lokacija iz 2023. godine. Ove razlike odražavaju se i na izgled jedinki, koje pokazuju znakove degradacije, što može biti pokazatelj negativnih ekoloških promjena na tim lokacijama tijekom proteklih godina.
7. Testiranje lokalno specifičnih modela za predikciju biomase na temelju morfometrijskih karakteristika pokazalo je značajnu razliku u predikcijskoj moći pojedinih morfometrijskih karakteristika među lokacijama. Općenito, multivarijatni modeli su hijerarhijski bolje rangirani za lokacije Šćuza 1 (W_w ~ L_ktot + L_t + N_k), Šćuza 2 (W_w ~ L_ktot + L_k), Bijela uvala (W_w ~ L_t + N_k) i Lanterna (W_w ~ L_ktot + L_k), dok su univarijatni modeli imali veću predikcijsku moć za lokacije Kamenjak (W_w ~ N_k) i Funtana (W_w ~ L_ktot). U većini slučajeva najbolje ocijenjeni univarijatni modeli uključuju morfometrijske karakteristike ukupnu duljinu kauloida (L_ktot) i broj kauloida (N_k), što ukazuje na njihov značajan potencijal za daljnje istraživanje i razvoj učinkovitih modela predikcije biomase.
8. Lokalno specifični modeli, razvijeni na temelju recentnih podataka na razini pojedinačnih jedinki, pokazuju bolju predikcijsku sposobnost u usporedbi s općim modelima. Opći modeli uključuju jedinke s različitih lokacija, međutim različiti uvjeti u pojedinim staništima dovode do velikih varijacija u odnosu morfometrijskih karakteristika i biomase.
9. Izrada općeg modela za predikciju biomase korištenjem povijesnih podataka na razini kvadrata pokazala se izvedivom. Iako univarijatni model s varijablom Grane (biomasa primarnih grana, Tot_WW ~ Grane) nije najbolje rangirani model, on pokazuje tek nešto slabiju razinu opisivanja varijabilnosti u mokroj biomasi u odnosu na najbolje rangirani multivarijatni model (Tot_WW ~ L_ktot + Grane + N_k), te predstavlja najveći potencijal za praktičnu primjenu na terenu, time smanjujući destruktivnost metode procjene biomase.

10. Rezultati eksperimenta ponovnog uzorkovanja pokazali su da bi optimalani minimalni broj kvadrata za izradu pouzdanog modela predikcije biomase na drugim područjima bio između 12 i 15 kvadrata, čime bi se zaključno dobio model koji je po karakteristikama predikcije sličan onom modelu izrađenom koristeći uzorak od 39 kvadrata, koji je korišten u ovom eksperimentu. Time bi se smanjila destruktivnost metode izrade modela za procjenu biomase.
11. Trendovi povećanja učestalosti, trajanja i intenziteta morskih toplinskih valova u neposrednoj blizini obalne lagune Šćuza, ističu važnost, ali ujedno i osjetljivost populacije vrste *G. barbata* unutar lagune, prvenstveno zbog izoliranosti navedene populacije i već zabilježenih ekstremnih dnevnih i sezonalnih varijacija temperature mora u laguni.
12. Vrsta *G. barbata* pokazuje iznimnu termalnu otpornost, preživljavajući temperature do 32 °C, s dokazanim kapacitetom morfološkog i fiziološkog oporavka nakon produženog temperaturnog stresa, što nadmašuje ranije poznate temperaturne granice za ovu vrstu. Međutim, izlaganje temperaturi od 34 °C uzrokuje propadanje talusa i ograničava mogućnosti regeneracije, što ukazuje na kritičnu temperaturnu granicu.
13. Populacija *G. barbata* u laguni Šćuza, zbog svoje geografske izolacije i iznimne temperaturne otpornosti, predstavlja važan izvor reproduktivnog materijala, koji bi mogao biti ključan za potencijalne akcije obnove i jačanja populacija ove vrste.
14. Intenzitet svjetlosti ima ključan utjecaj na uspješnost rasta i preživljavanja juvenilnih jedinki vrste *G. barbata* tijekom *ex situ* uzgoja. Visoki intenzitet svjetlosti (70 µmol fotona $m^{-2}$ $s^{-1}$) potiče rast u *ex situ* uvjetima, ali smanjuje preživljavanje juvenilnih jedinki. Suprotno tome, niski intenzitet svjetlosti (15 µmol fotona $m^{-2}$ $s^{-1}$) dovodi do boljeg preživljavanja juvenilnih jedinki.
15. Mlade jedinke uzgojene *ex situ* prenesene su u lagunu Šćuza tijekom razdoblja ekstremno visokih temperatura mora (>30 °C). U tom razdoblju rast jedinki je uglavnom stagnirao, međutim većina jedinki iz oba tretmana (visoki i niski intenzitet svjetlosti) preživjela je do razdoblja zahlađenja, kada su temperature pale ispod 20 °C, čime je ponovno potaknut rast. U *in situ* uvjetima uočena je značajna razlika u visini jedinki između skupina uzgajanih pod visokim i niskim intezitetom svjetlosti, pri čemu su jedinke uzgajane na nižoj svjetlosnoj razini pokazale veći rast.

16. Aktivni rast juvenilnih jedinki *in situ* tijekom kasne zime i ranog proljeća bio je najviše potaknut nižim temperaturama, smanjenim salinitetom, umjerenim porastom produktivnosti vodenog stupca, te povećanim ukupnim protokom sedimentacije.

# 8. LITERATURA


Aller-Rojas, O., Moreno, B., Aponte, H., i Zavala, J. (2020). Carbon storage estimation of *Lessonia trabeculata* kelp beds in Southern Peru: An analysis from the San Juan de Marcona region. *Carbon Management*, *11*(5), 525–532. https://doi.org/10.1080/17583004.2020.1808765

Andrews, S., Bennett, S., i Wernberg, T. (2014). Reproductive seasonality and early life temperature sensitivity reflect vulnerability of a seaweed undergoing range reduction. *Marine Ecology Progress Series*, *495*, 119–129. https://doi.org/10.3354/meps10567

Ballesteros, E. (1988). Estructura y dinámica de la comunidad de *Cystoseira mediterranea* Sauvageau en el Mediterráneo Noroccidental. *Investigación Pesquera*, *52*(3), 313-334.

Ballesteros, E. (1989). Production of seaweeds in Northwestern Mediterranean marine communities: its relation with environmental factors. *Scientia Marina*, *53*(2–3), 357-364.

Ballesteros, E. (1990). Structure and dynamics of the *Cystoseira* caespitosa Sauvageau (Fucales, Phaeophyceae) community in the North-Western Mediterranean. *Scientia Marina*, *54*(2), 155-168.

Ballesteros, E., Torras, X., Pinedo, S., García, M., Mangialajo, L., i de Torres, M. (2007). A new methodology based on littoral community cartography dominated by macroalgae for the implementation of the European Water Framework Directive. *Marine Pollution Bulletin*, *55*(1–6), 172–180. https://doi.org/10.1016/J.MARPOLBUL.2006.08.038

Bartsch, I., Vogt, J., Pehlke, C., i Hanelt, D. (2013). Prevailing sea surface temperatures inhibit summer reproduction of the kelp *Laminaria digitata* at Helgoland (North Sea). *Journal of Phycology*, *49*(6), 1061–1073. https://doi.org/10.1111/jpy.12125

Bass, A. V., Smith, K. E., i Smale, D. A. (2023). Marine heatwaves and decreased light availability interact to erode the ecophysiological performance of habitat-forming kelp species. *Journal of Phycology*, *59*(3), 481–495. https://doi.org/10.1111/jpy.13332

Bates, D., Mächler, M., Bolker, B. M., i Walker, S. C. (2015). Fitting linear mixed-effects models using lme4. *Journal of Statistical Software*, *67*(1). https://doi.org/10.18637/jss.v067.i01

Battelli, C., i Alberti, G. (2003). Antonio Zaratin (1846 - 1923): Raccoglitore e preparatore d'alghe dell'Istria e del Quarnero. *Atti*, *33*, 643–684.

Battelli, C., i Catra, M. (2021). First report of *Cystoseira aurantia* (Sargassaceae, Fucophyceae) from the lagoon of Strunjan (Gulf of Trieste, Northern Adriatic). *Annales: Series Historia Naturalis*, *31*(1), 139-146.

Battelli, C., i Catra, M. (2023). Morphological and reproductive phenology of *Cystoseira foeniculacea* f. *tenuiramosa* (Phaeophyceae, Fucales) from the lagoon of Strunjan (Gulf of Trieste, northern Adriatic). *Acta Adriatica*, *64*(1), 1-12. https://doi.org/10.32582/aa.64.1.9

Benedetti-Cecchi, L., Pannacciulli, F., Bulleri, F., Moschella, P. S., Airoldi, L., Relini, G., i Cinelli, F. (2001). Predicting the consequences of anthropogenic disturbance: Large-scale effects of loss of canopy algae on rocky shores. *Marine Ecology Progress Series*, *214*, 137-150. https://doi.org/10.3354/meps214137

Bevilacqua, S., Savonitto, G., Lipizer, M., Mancuso, P., Ciriaco, S., Srijemsi, M., i Falace, A. (2019). Climatic anomalies may create a long-lasting ecological phase shift by altering the reproduction of a foundation species. *Ecology*, *100*(12), 1-4. https://doi.org/10.1002/ecy.2838

Bianchi, C. N. (2007). Biodiversity issues for the forthcoming tropical Mediterranean Sea. *Hydrobiologia*, *580*(1), 7–21. https://doi.org/10.1007/s10750-006-0469-5

Bianchi, C. N., i Morri, C. (2000). Marine biodiversity of the Mediterranean Sea: Situation, problems and prospects for future research. *Marine Pollution Bulletin*, *40*(5), 367-376. https://doi.org/10.1016/S0025-326X(00)00027-8

Bianchi, C. N., Pronzato, R., Cattaneo-Vietti, R., Benedetti-Cecchi, L., Morri, C., Pansini, M., Chemello, R., Milazzo, M., Fraschetti, S., Terlizzi, A., Peirano, A., Salvati, E., Benzoni, F., Calcinai, B., Cerrano, C., i Bavestrello, G. (2004). Hard Bottoms. U: *Mediterranean Marine Benthos: A Manual of Methods for Its Sampling and Study*, *11*(1), 185-215.

Bilajac, A., Gljušćić, E., Smith, S., Najdek, M., i Iveša, L. (2024). Effects of extreme temperatures and recovery potential of *Gongolaria barbata* from a coastal lagoon in the northern Adriatic Sea: An *ex situ* approach. *Annals of Botany*, *134*(3), 415-426. https://doi.org/10.1093/aob/mcae038

Bischof, K., i Rautenberger, R. (2012). Seaweed responses to environmental stress: reactive oxygen and antioxidative strategies. U: Seaweed biology: *Novel insights into ecophysiology, ecology and utilization*, Berlin, Heidelberg: Springer Berlin Heidelberg, 109-132. https://doi.org/10.1007/978-3-642-28451-9_6

Blanfuné, A., Boudouresque, C. F., Verlaque, M., i Thibaut, T. (2019). The ups and downs of a canopy-forming seaweed over a span of more than one century. *Scientific Reports*, *9*(1), 5250. https://doi.org/10.1038/s41598-019-41676-2

Boudouresque, C. F., i Lück, H. B. (1972). Recherches de bionomie structurale au niveau d'un peuplement benthique sciaphile. *Journal of Experimental Marine Biology and Ecology*, *8*(2), 133-144. https://doi.org/10.1016/0022-0981(72)90016-0

Braun-Blanquet, J. (1964). Pflanzensociologie. Springer, Wien, 866 str.

Breeman, A. M. (1988). Relative importance of temperature and other factors in determining geographic boundaries of seaweeds: experimental and phenological evidence. *Helgoländer Meeresuntersuchungen*, *42*, 199-241.

Bridle, J. R., i Vines, T. H. (2007). Limits to evolution at range margins: when and why does adaptation fail? U: *Trends in Ecology and Evolution*, *22*(3), 140-147. https://doi.org/10.1016/j.tree.2006.11.002

Brown, J. H., Mehlman, D. W., i Stevens, G. C. (1995). Spatial Variation in Abundance. *Ecology*, *76*(7), 2028-2043. https://doi.org/10.2307/1941678

Brush, M. J., Mozetič, P., Francé, J., Aubry, F. B., Đakovac, T., Faganeli, J., Harris, L. A., i Niesen, M. (2020). Phytoplankton dynamics in a changing environment. *Coastal Ecosystems in Transition: A Comparative Analysis of the Northern Adriatic and Chesapeake Bay*. Wiley, 256 str. https://doi.org/10.1002/9781119543626.ch4

Calvo, S., Drago, D., i Sortino, M. (1980). Winter and summer submersed vegetation maps of the Stagnone (Western Coast of Sicily). *Biologie et Ecologie Mediterraneenne*, *7*(2), 89–96.

Campanelli, A., Grilli, F., Paschini, E., i Marini, M. (2011). The influence of an exceptional Po River flood on the physical and chemical oceanographic properties of the Adriatic Sea.

*Dynamics of Atmospheres and Oceans*, *52*(1–2), 284-297. https://doi.org/10.1016/j.dynatmoce.2011.05.004

Campbell, J., i Starko, S. (2021). Allometric models effectively predict *Saccharina latissima* (Laminariales, Phaeophyceae) fresh weight at local scales. *Journal of Applied Phycology*, *33*(1), 491-500. https://doi.org/10.1007/s10811-020-02315-w

Cebrian, E., Tamburello, L., Verdura, J., Guarnieri, G., Medrano, A., Linares, C., Hereu, B., Garrabou, J., Cerrano, C., Galobart, C., i Fraschetti, S. (2021). A Roadmap for the Restoration of Mediterranean Macroalgal Forests. *Frontiers in Marine Science*, *8*, 709219. https://doi.org/10.3389/fmars.2021.709219

Cecere, E., Saracino, O. D., Fanelli, M., i Petrocelli, A. (1992). Presence of a drifting algal bed in the Mar Piccolo basin, Taranto (Ionian Sea, Southern Italy). *Journal of Applied Phycology*, *4*(4), 323-327. https://doi.org/10.1007/BF02185789

Cerrano, C., Bavestrello, G., Bianchi, C. N., Cattaneo-Vietti, R., Bava, S., Morganti, C., Morri, C., Picco, P., Sara, G., Schiaparelli, S., Siccardi, A., i Sponga, F. (2000). A catastrophic mass-mortality episode of gorgonians and other organisms in the Ligurian Sea (North-western Mediterranean), summer 1999. *Ecology Letters*, *3*(4), 284-293. https://doi.org/10.1046/j.1461-0248.2000.00152.x

Cheminée, A., Sala, E., Pastor, J., Bodilis, P., Thiriet, P., Mangialajo, L., Cottalorda, J. M., i Francour, P. (2013). Nursery value of *Cystoseira* forests for Mediterranean rocky reef fishes. *Journal of Experimental Marine Biology and Ecology*, *442*, 70-79. https://doi.org/10.1016/j.jembe.2013.02.003

Chiaudani, G., i Vighi, M. (1982). Multistep approach to identification of limiting nutrients in Northern Adriatic eutrophied coastal waters. *Water Research*, *16*(7), 1161-1166. https://doi.org/10.1016/0043-1354(82)90134-8

Cimini, J., Asnaghi, V., Chiantore, M., Kaleb, S., Onida, A., i Falace, A. (2024). Can thermal anomalies impair the restoration of *Cystoseira s.l.* forests? *Marine Environmental Research*, *198*, 106537. https://doi.org/10.1016/J.MARENVRES.2024.106537

Clayton, M. N. (1990). The adaptive significance of life history characters in selectedorders of marine brown maeroalgae. *Australian Journal of Ecology*, *15*(4), 439-452. https://doi.org/10.1111/j.1442-9993.1990.tb01469.x

Coleman, M. A., i Wernberg, T. (2020). The Silver Lining of Extreme Events. *Trends in Ecology and Evolution*, *35*(12), 1065-1067. https://doi.org/10.1016/j.tree.2020.08.013

Cormaci, M., Furnari, G., Catra, M., Alongi, G., i Giaccone, G. (2012). Flora marina bentonica del Mediterraneo: Phaeophyceae. *Bolletino Dell'Accademia Gioenia Di Scienze Naturali*, *45*(375), 508 str.

Cozzi, S., Ibáñez, C., Lazar, L., Raimbault, P., i Giani, M. (2018). Flow regime and nutrient-loading trends from the largest South European watersheds: Implications for the productivity of Mediterranean and Black Sea's Coastal Areas. *Water (Switzerland)*, *11*(1). https://doi.org/10.3390/w11010001

Crafts-Brandner, S. J., i Salvucci, M. E. (2002). Sensitivity of photosynthesis in a C4 plant, maize, to heat stress. *Plant Physiology*, *129*(4), 1773–1780. https://doi.org/10.1104/pp.002170

Cramer, W., Guiot, J., Fader, M., Garrabou, J., Gattuso, J. P., Iglesias, A., Lange, M. A., Lionello, P., Llasat, M. C., Paz, S., Peñuelas, J., Snoussi, M., Toreti, A., Tsimplis, M. N., i Xoplaki, E. (2018). Climate change and interconnected risks to sustainable development in the Mediterranean. *Nature Climate Change*, *8*(11), 972-980. https://doi.org/10.1038/s41558-018-0299-2

Csordas, M., Starko, S., Neufeld, C. J., Thompson, S. A., i Baum, J. K. (2024). Multiscale stability of an intertidal kelp (*Postelsia palmaeformis*) near its northern range edge through a period of prolonged heatwaves. *Annals of Botany*, *133*(1), 61–72. https://doi.org/10.1093/AOB/MCAD148

Darmaraki, S., Somot, S., Sevault, F., i Nabat, P. (2019). Past Variability of Mediterranean Sea Marine Heatwaves. *Geophysical Research Letters*, *46*(16), 9813–9823. https://doi.org/10.1029/2019GL082933

Davison, I. R., Greene, R. M., i Podolak, E. J. (1991). Temperature acclimation of respiration and photosynthesis in the brown alga *Laminaria saccharina*. *Marine Biology*, *110*, 449-454.

Davison, I. R., i Pearson, G. A. (1996). Stress tolerance in intertidal seaweeds. *Journal of Phycology*, *32*(2), 197-211. https://doi.org/10.1111/j.0022-3646.1996.00197.x

Dayton, P. K., Currie, V., Gerrodette, T., Keller, B. D., Rosenthal, R., i Tresca, D. V. (1984). Patch Dynamics and Stability of Some California Kelp Communities. *Ecological Monographs*, *54*(3), 253–289. https://doi.org/10.2307/1942498

Devescovi, M., 2015. Effects of bottom topography and anthropogenic pressure on northern Adriatic *Cystoseira* spp. (Phaeophyceae, Fucales). *Aquatic Botany*, *121*, 26–32. https://doi.org/10.1016/j.aquabot.2014.10.009

de Bettignies, T., Wernberg, T., i Gurgel, C. F. D. (2018). Exploring the influence of temperature on aspects of the reproductive phenology of temperate seaweeds. *Frontiers in Marine Science*, *5*, 218. https://doi.org/10.3389/fmars.2018.00218

de Caralt, S., Verdura, J., Santamaría, J., Vergés, A., i Cebrian, E. (2023). Importance of life history traits for vulnerability to climate change: implications for macroalgal restoration. *Frontiers in Marine Science*, *10*, 1248629. https://doi.org/10.3389/FMARS.2023.1248629/BIBTEX

de Caralt, S., Verdura, J., Vergés, A., Ballesteros, E., i Cebrian, E. (2020). Differential effects of pollution on adult and recruits of a canopy-forming alga: implications for population viability under low pollutant levels. *Scientific Reports*, *10*(1), 17825. https://doi.org/10.1038/s41598-020-73990-5

Degobbis, D., Gilmartin, M., i Revelante, N. (1986). An annotated nitrogen budget calculation for the northern Adriatic Sea. *Marine Chemistry*, *20*(2), 159-177. https://doi.org/10.1016/0304-4203(86)90037-X

Degobbis, D., Precali, R., Ivancic, I., Smodlaka, N., Fuks, D., i Kveder, S. (2000). Long-term changes in the northern Adriatic ecosystem related to anthropogenic eutrophication. *International Journal of Environment and Pollution*, *13*(1), 495-533. https://doi.org/10.1504/ijep.2000.002332

De La Fuente, G., Chiantore, M., Asnaghi, V., Kaleb, S., i Falace, A. (2019). First *ex situ* outplanting of the habitat-forming seaweed *Cystoseira amentacea* var. *stricta* from a restoration perspective. *PeerJ*, *7*, e7290. https://doi.org/10.7717/peerj.7290

Draisma, S. G. A., Ballesteros, E., Rousseau, F., i Thibaut, T. (2010). DNA sequence data demonstrate the polyphyly of the genus *Cystoseira* and other Sargassaceae genera (phaeophyceae). *Journal of Phycology*, *46*(6), 1329-1345. https://doi.org/10.1111/j.1529-8817.2010.00891.x

Đakovac, T., Degobbis, D., Supić, N., i Precali, R. (2012). Marked reduction of eutrophication pressure in the northeastern Adriatic in the period 2000-2009. *Estuarine, Coastal and Shelf Science*, *115*, 25–32. https://doi.org/10.1016/j.ecss.2012.03.029

Đakovac, T., Supić, N., Bernardi Aubry, F., Degobbis, D., i Giani, M. (2015). Mechanisms of hypoxia frequency changes in the northern Adriatic Sea during the period 1972-2012. *Journal of Marine Systems*, *141*, 179–189. https://doi.org/10.1016/j.jmarsys.2014.08.001

Ercegović, A. (1952). Sur les *Cystoseira* adriatiques. Leur morphologie, écologie et évolution. *Fauna et Flora Adriatica*, IOR, Split, 212 str.

Estaque, T., Richaume, J., Bianchimani, O., Schull, Q., Mérigot, B., Bensoussan, N., Bonhomme, P., Vouriot, P., Sartoretto, S., Monfort, T., Basthard-Bogain, S., Fargetton, M., Gatti, G., Barth, L., Cheminée, A., i Garrabou, J. (2023). Marine heatwaves on the rise: One of the strongest ever observed mass mortality event in temperate gorgonians. *Global Change Biology*, *29*(22), 6159-6162. https://doi.org/10.1111/gcb.16931

Europska Unija. (2016). European Red List of Habitats Environment. U *Terrestrial and freshwater habitats.* (Issue December). https://doi.org/10.2779/032638

Fabbrizzi, E., Munari, M., Fraschetti, S., Arena, C., Chiarore, A., Cannavacciuolo, A., Colletti, A., Costanzo, G., Soler-Fajardo, A., Nannini, M., Savinelli, B., Silvestrini, C., Vitale, E., i Tamburello, L. (2023). Canopy-forming macroalgae can adapt to marine heatwaves. *Environmental Research*, *238*(2). https://doi.org/10.1016/j.envres.2023.117218

Fabbrizzi, E., Scardi, M., Ballesteros, E., Benedetti-Cecchi, L., Cebrian, E., Ceccherelli, G., De Leo, F., Deidun, A., Guarnieri, G., Falace, A., Fraissinet, S., Giommi, C., Mačić, V., Mangialajo, L., Mannino, A. M., Piazzi, L., Ramdani, M., Rilov, G., Rindi, L., … i Fraschetti, S. (2020). Modeling macroalgal forest distribution at mediterranean scale: Present status, drivers of changes and insights for conservation and management. *Frontiers in Marine Science*, *7*, 20. https://doi.org/10.3389/fmars.2020.00020

Facca, C., Bilaničovà, D., Pojana, G., Sfriso, A., i Marcomini, A. (2014). Harmful algae records in venice lagoon and in Po River Delta (Northern Adriatic Sea, Italy). *The Scientific World Journal*, *2014*(1), 806032. https://doi.org/10.1155/2014/806032

Falace, A., i Bressan, G. (2006). Seasonal variations of *Cystoseira barbata* (Stackhouse) C. Agardh frond architecture. *Hydrobiologia*, *555*(1), 193–206. https://doi.org/10.1007/s10750-005-1116-2

Falace, A., Kaleb, S., De La Fuente, G., Asnaghi, V., i Chiantore, M. (2018). *Ex situ* cultivation protocol for *Cystoseira amentacea* var. *stricta* (Fucales, Phaeophyceae) from a restoration perspective. *PLoS ONE*, *13*(2), e0193011. https://doi.org/10.1371/journal.pone.0193011

Falace, A., Manfrin, C., Furnari, G., Burchio, S. D., Pallavicini, A., Descourvieres, E., Kaleb, S., Lokovšek, A., Grech, D., i Alongi, G. (2024). Contribution to the knowledge of *Gongolaria barbata* (Sargassaceae, Fucales) from the Mediterranean: insights into infraspecific diversity. *Phytotaxa*, *635*(3), 191–205. https://doi.org/10.11646/phytotaxa.635.3.1

Ferrario, F., Iveša, L., Jaklin, A., Perkol-Finkel, S., i Airoldi, L. (2016). The overlooked role of biotic factors in controlling the ecological performance of artificial marine habitats. *Journal of Applied Ecology*, *53*, 16-24. https://doi.org/10.1111/1365-2664.12533

Filbee-Dexter, K., i Wernberg, T. (2018). Rise of Turfs: A New Battlefront for Globally Declining Kelp Forests. *BioScience*. *68*(2), 64-76. https://doi.org/10.1093/biosci/bix147

Fowler-Walker, M. J., Wernberg, T., i Connell, S. D. (2006). Differences in kelp morphology between wave sheltered and exposed localities: Morphologically plastic or fixed traits? *Marine Biology*, *148*(4), 755–767. https://doi.org/10.1007/S00227-005-0125-Z/TABLES/5

Fox, J., i Weisberg, S. (2019). An {R} Companion to Applied Regression, Third Edition. *Thousand Oaks CA: Sage.*, *September 2012*.

Franco, J. N., Wernberg, T., Bertocci, I., Duarte, P., Jacinto, D., Vasco-Rodrigues, N., i Tuya, F. (2015). Herbivory drives kelp recruits into “hiding” in a warm ocean climate. *Marine Ecology Progress Series*, *536*, 1-9. https://doi.org/10.3354/meps11445

Frölicher, T. L., Fischer, E. M., i Gruber, N. (2018). Marine heatwaves under global warming. *Nature*, *560*(7718), 360–364. https://doi.org/10.1038/s41586-018-0383-9

Gann, G. D., McDonald, T., Walder, B., Aronson, J., Nelson, C. R., Jonson, J., Hallett, J. G., Eisenberg, C., Guariguata, M. R., Liu, J., Hua, F., Echeverría, C., Gonzales, E., Shaw, N., Decleer, K., i Dixon, K. W. (2019). International principles and standards for the practice of ecological restoration. Second edition. *Restoration Ecology*, *27*(S1). https://doi.org/10.1111/rec.13035

Garrabou, J., Coma, R., Bensoussan, N., Bally, M., Chevaldonné, P., Cigliano, M., Diaz, D., Harmelin, J. G., Gambi, M. C., Kersting, D. K., Ledoux, J. B., Lejeusne, C., Linares, C., Marschal, C., Pérez, T., Ribes, M., Romano, J. C., Serrano, E., Teixido, N., … i Cerrano, C. (2009). Mass mortality in Northwestern Mediterranean rocky benthic communities: Effects of the 2003 heat wave. *Global Change Biology*, *15*(5), 1090–1103. https://doi.org/10.1111/j.1365-2486.2008.01823.x

Garrabou, J., Gómez-Gras, D., Medrano, A., Cerrano, C., Ponti, M., Schlegel, R., Bensoussan, N., Turicchia, E., Sini, M., Gerovasileiou, V., Teixido, N., Mirasole, A., Tamburello, L., Cebrian, E., Rilov, G., Ledoux, J. B., Souissi, J. Ben, Khamassi, F., Ghanem, R., … Harmelin, J. G. (2022). Marine heatwaves drive recurrent mass mortalities in the Mediterranean Sea. *Global Change Biology*, *28*(19), 5708–5725. https://doi.org/10.1111/gcb.16301

Gevaert, F., Davoult, D., Creach, A., Kling, R., Janquin, M. A., Seuront, L., i Lemoine, Y. (2001). Carbon and nitrogen content of *Laminaria saccharina* in the eastern English Channel: Biometrics and seasonal variations. *Journal of the Marine Biological Association of the United Kingdom*, *81*(5), 727-734. https://doi.org/10.1017/s0025315401004532

Gevaert, F., Janquin, M. A., i Davoult, D. (2008). Biometrics in *Laminaria digitata*: A useful tool to assess biomass, carbon and nitrogen contents. *Journal of Sea Research*, *60*(3), 215–219. https://doi.org/10.1016/j.seares.2008.06.006

Giaccone, G., i Bruni, A. (1973). Le Cistoseire e la vegetazione sommersa del Mediterraneo. *Atti Del Reale Istituto Veneto Di Scienze, Lettere Ed Arti*, 59–103.

Gianguzza, P., Agnetta, D., Bonaviri, C., Di Trapani, F., Visconti, G., Gianguzza, F., i Riggio, S. (2011). The rise of thermophilic sea urchins and the expansion of barren grounds in the Mediterranean Sea. *Chemistry and Ecology*, *27*(2), 129–134. https://doi.org/10.1080/02757540.2010.547484

Giani, M., Rinaldi, A., i Degobbis, D. (2005). Mucilages in the Adriatic and Tyrrhenian Sea: An introduction. *Science of the Total Environment*. *353*(1-3), 3-9. https://doi.org/10.1016/j.scitotenv.2005.09.006

Gianni, F., Bartolini, F., Airoldi, L., Ballesteros, E., Francour, P., Guidetti, P., Meinesz, A., Thibaut, T., i Mangialajo, L. (2013). Conservation and restoration of marine forests in the Mediterranean Sea and the potential role of Marine Protected Areas. *Advances in Oceanography and Limnology*, *4*(2), 83-101. https://doi.org/10.1080/19475721.2013.845604

Gianni, F., Mačić, V., Bartolini, F., Pey, A., Laurent, M., i Mangialajo, L. (2020). Optimizing canopy-forming algae conservation and restoration with a new herbivorous fish deterrent device. *Restoration Ecology*, *28*(4), 750–756. https://doi.org/10.1111/rec.13143

Gljušćić, E., Bilajac, A., Smith, S. M., Najdek, M., i Iveša, L. (2023). First Restoration Experiment for Endemic *Fucus virsoides* on the Western Istrian Coast—Is It Feasible? *Plants*, *12*(7), 1445. https://doi.org/10.3390/plants12071445

Gómez Garreta, A., Barceló, M. C., Gallardo, T., Pérez-Ruzafa, I. M., Ribera, M. A., i Rull, J. (2001). Flora Phycologica Iberica Vol. 1. Fucales. U: *Universidad de Murcia*, 192 str .

Gómez-Gras, D., Bensoussan, N., Ledoux, J. B., López-Sendino, P., Cerrano, C., Ferretti, E., Kipson, S., Bakran-Petricioli, T., Serrao, E. A., Paulo, D., Coelho, M. A. G., Pearson, G. A., Boavida, J., Montero-Serra, I., Pagès-Escolà, M., Medrano, A., López-Sanz, A., Milanese, M., Linares, C., i Garrabou, J. (2022). Exploring the response of a key Mediterranean gorgonian to heat stress across biological and spatial scales. *Scientific Reports*, *12*(1), 21064. https://doi.org/10.1038/s41598-022-25565-9

Granéli, E., Carlsson, P., Turner, J. T., Tester, P. A., Béchemin, C., Dawson, R., i Funari, E. (1999). Effects of N:P:Si ratios and zooplankton grazing on phytoplankton communities in the northern Adriatic Sea. I. Nutrients, phytoplankton biomass, and polysaccharide production. *Aquatic Microbial Ecology*, *18*(1), 37-54. https://doi.org/10.3354/ame018037

Grilli, F., Accoroni, S., Acri, F., Aubry, F. B., Bergami, C., Cabrini, M., Campanelli, A., Giani, M., Guicciardi, S., Marini, M., Neri, F., Penna, A., Penna, P., Pugnetti, A., Ravaioli, M., Riminucci, F., Ricci, F., Totti, C., Viaroli, P., i Cozzi, S. (2020). Seasonal and interannual trends of oceanographic parameters over 40 years in the Northern Adriatic Sea in relation to

nutrient loadings using the EMODnet chemistry data portal. *Water (Switzerland)*, *12*(8), 2280. https://doi.org/10.3390/w12082280

Guern, M. (1962). Embryologie de quelques espèces du genre *Cystoseira* Agardh 1821 (Fucales). *Vie et Milieu*, 649-680.

Guidetti, P., i Dulčić, J. (2007). Relationships among predatory fish, sea urchins and barrens in Mediterranean rocky reefs across a latitudinal gradient. *Marine Environmental Research*, *63*(2), 168–184. https://doi.org/10.1016/j.marenvres.2006.08.002

Guiry, M. D., i Guiry, G. M. (2024). *AlgaeBase. World-wide electronic publication. National University of Ireland, Galway.* http://www.Algaebase.org/. pristup: 01.04.2024.

Hanley, M. E., Firth, L. B., i Foggo, A. (2024). Victim of changes? Marine macroalgae in a changing world. *Annals of Botany*, *133*(1), 1-16. https://doi.org/10.1093/aob/mcad185

Hanel, R. (2002). Recovery of Fucacean associations and associated fish assemblages in the vicinity of Rovinj, Istrian coast, northern Adriatic Sea. *Periodicum biologorum*, *104*(2), 159-163.

Hereu, B. (2006). Depletion of palatable algae by sea urchins and fishes in a Mediterranean subtidal community. *Marine Ecology Progress Series*, *313*, 95-103. https://doi.org/10.3354/meps313095

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

Hobday, A. J., Oliver, E. C. J., Gupta, A. Sen, Benthuysen, J. A., Burrows, M. T., Donat, M. G., Holbrook, N. J., Moore, P. J., Thomsen, M. S., Wernberg, T., i Smale, D. A. (2018). Categorizing and naming marine heatwaves. *Oceanography*, *31*(2), 162–173. https://doi.org/10.5670/oceanog.2018.205

Holm-Hansen, O., Lorenzen, C. J., Holmes, R. W., i Strickland, J. D. H. (1965). Fluorometric determination of chlorophyll. *ICES Journal of Marine Science*, *30*(1), 3-15. https://doi.org/10.1093/icesjms/30.1.3

Hothorn, T., Bretz, F., i Westfall, P. (2008). Simultaneous Inference in General Parametric Models. *Biometrical Journal*, *50*(3), 346–363. https://doi.org/10.1002/BIMJ.200810425

Irving, A. D., Balata, D., Colosio, F., Ferrando, G. A., i Airoldi, L. (2009). Light, sediment, temperature, and the early life-history of the habitat-forming alga *Cystoseira barbata*. *Marine Biology*, *156*(6), 1223–1231. https://doi.org/10.1007/s00227-009-1164-7

Iveša, L., Bilajac, A., Gljušćić, E., i Najdek, M. (2022). *Gongolaria barbata* forest in the shallow lagoon on the southern Istrian Coast (northern Adriatic Sea). *Botanica Marina*, *65*(4), 255–268. https://doi.org/10.1515/bot-2022-0021

Iveša, L., i Devescovi, M. (2014). Distribution and composition of *Cystoseira* stands along the west Istrian coast (northern Adriatic, Croatia) and comparison with historical data. U: *Proceedings of the 5th Mediterranean Symposium on Marine Vegetation*, RAC/SPA, 102-107.

Iveša, L., Đakovac, T., Bilajac, A., Gljušćić, E., i Devescovi, M. (2021). Increased ammonium levels occurring during benthic algal blooms are potentially toxic to fucalean algae. *Botanica Marina*, *64*(4), 267–274. https://doi.org/10.1515/bot-2021-0033

Iveša, L., Đakovac, T., i Devescovi, M. (2015). Spreading patterns of the invasive *Caulerpa cylindracea* Sonder along the west Istrian Coast (northern Adriatic Sea, Croatia). *Marine Environmental Research*, *107*, 1-7. https://doi.org/10.1016/j.marenvres.2015.03.008

Iveša, L., Đakovac, T., i Devescovi, M. (2016). Long-term fluctuations in *Cystoseira* populations along the west Istrian Coast (Croatia) related to eutrophication patterns in the northern Adriatic Sea. *Marine Pollution Bulletin*, *106*(1–2), 162–173. https://doi.org/10.1016/j.marpolbul.2016.03.010

Johnson, G. C., i Lyman, J. M. (2020). Warming trends increasingly dominate global ocean. *Nature Climate Change*, *10*(8), 757–761. https://doi.org/10.1038/s41558-020-0822-0

Justić, D. (1988). Trend in the transparency of the northern Adriatic Sea 1911-1982. *Marine Pollution Bulletin*, *19*(1), 32-35. https://doi.org/10.1016/0025-326X(88)90751-5

Kaleb, S., Sánchez de Pedro, R., Bañares-España, E., Alboresi, A., Savonitto, G., Natale, S., Bevilacqua, S., i Falace, A. (2023). Cultivation of *Gongolaria barbata* (Fucales, Phaeophyceae) with a seaweed-derived biostimulant in order to improve photophysiological fitness and promote fertility to advance the restoration of marine macroalgal forests. *Journal of Applied Phycology*, *35*, 2337-2350. https://doi.org/10.1007/s10811-023-02984-3

Kavanaugh, M. T., Nielsen, K. J., Chan, F. T., Menge, B. A., Letelier, R. M., i Goodrich, L. M. (2009). Experimental assessment of the effects of shade on an intertidal kelp: Do phytoplankton blooms inhibit growth of open coast macroalgae? *Limnology and Oceanography*, *54*(1), 276–288. https://doi.org/10.4319/LO.2009.54.1.0276

Khailov, K. M. (1979). Ontogenetic Trends in Morphologic Parameters of *Cystoseira barbata* Thalli. *Botanica Marina*, *22*(5), 299-311. https://doi.org/10.1515/botm.1979.22.5.299

King, N. G., McKeown, N. J., Smale, D. A., i Moore, P. J. (2018). The importance of phenotypic plasticity and local adaptation in driving intraspecific variability in thermal niches of marine macrophytes. *Ecography*, *41*(9), 1469-1484. https://doi.org/10.1111/ecog.03186

Koehl, M. A. R., i Wainwright, S. A. (1977). Mechanical adaptations of a giant kelp. *Limnology and Oceanography*, *22*(6), 1067–1071. https://doi.org/10.4319/LO.1977.22.6.1067

Kolić, M. (2013). Kartiranje naselja smeđih algi roda *Cystoseira* u rovinjskom priobalju. Sveučilište Jurja Dobrile u Puli.

Kolzenburg, R. (2022). The direct influence of climate change on marginal populations: a review. *Aquatic Sciences*, *84*(2), 24. https://doi.org/10.1007/s00027-022-00856-5

Krumhansl, K. A., Okamoto, D. K., Rassweiler, A., Novak, M., Bolton, J. J., Cavanaugh, K. C., Connell, S. D., Johnson, C. R., Konar, B., Ling, S. D., Micheli, F., Norderhaug, K. M., Pérez-Matus, A., Sousa-Pinto, I., Reed, D. C., Salomon, A. K., Shears, N. T., Wernberg, T., Anderson, R. J., … i Byrnes, J. E. K. (2016). Global patterns of kelp forest change over the past half-century. *Proceedings of the National Academy of Sciences of the United States of America*, *113*(48), 13785-13790. https://doi.org/10.1073/pnas.1606102113

Ladah, L. B., i Zertuche-González, J. A. (2007). Survival of microscopic stages of a perennial kelp (*Macrocystis pyrifera*) from the center and the southern extreme of its range in the Northern

Hemisphere after exposure to simulated El Niño stress. *Marine Biology*, *152*(3), 677–686. https://doi.org/10.1007/s00227-007-0723-z

Lenzi, M., Leporatti Persiano, M., Gennaro, P., i Rubegni, F. (2017). Artificial Top Layer Sediment Resuspension To Counteract Chaetomorpha Linum (Muller) Kutz Blooms In A Eutrophic Lagoon. Three Years Full-Scale Experience. *Journal of Aquaculture i Marine Biology*, *5*(2), 2378-3184. https://doi.org/10.15406/JAMB.2017.05.00114

Lenzi, M., M, L. P., i Agostino, D. A. (2024). Growth tests of *Gongolaria barbata* ( Ochrophyta Sargassaceae ), a native species producing pleustophitic blooms in a hypertrophic Mediterranean lagoon. *Journal of Aquaculture i Marine Biology*, *13*(2), 71–78. https://doi.org/10.15406/jamb.2024.13.00399

Liesner, D., Fouqueau, L., Valero, M., Roleda, M. Y., Pearson, G. A., Bischof, K., Valentin, K., i Bartsch, I. (2020). Heat stress responses and population genetics of the kelp *Laminaria digitata* (Phaeophyceae) across latitudes reveal differentiation among North Atlantic populations. *Ecology and Evolution*, *10*(17), 9144–9177. https://doi.org/10.1002/ece3.6569

Lima, F. P., i Wethey, D. S. (2012). Three decades of high-resolution coastal sea surface temperatures reveal more than warming. *Nature Communications*, *3*, 704. https://doi.org/10.1038/ncomms1713

Ling, S. D., Scheibling, R. E., Rassweiler, A., Johnson, C. R., Shears, N., Connell, S. D., Salomon, A. K., Norderhaug, K. M., Pérez-Matus, A., Hernández, J. C., Clemente, S., Blamey, L. K., Hereu, B., Ballesteros, E., Sala, E., Garrabou, J., Cebrian, E., Zabala, M., Fujita, D., i Johnson, L. E. (2015). Global regime shift dynamics of catastrophic sea urchin overgrazing. *Philosophical Transactions of the Royal Society B: Biological Sciences*, *370*(1659), 1–10. https://doi.org/10.1098/rstb.2013.0269

Li, R., i Brawley, S. H. (2004). Improved survival under heat stress in intertidal embryos (*Fucus* spp.) simultaneously exposed to hypersalinity and the effect of parental thermal history. *Marine Biology*, *144*(2), 205–213. https://doi.org/10.1007/s00227-003-1190-9

Lokovšek, A., Pitacco, V., Falace, A., Trkov, D., i Orlando-Bonaca, M. (2024). Too Hot to Handle: Effects of Water Temperature on the Early Life Stages of *Gongolaria barbata* (Fucales).

*Journal of Marine Science and Engineering*, *12*(3), 514. https://doi.org/10.3390/JMSE12030514/S1

Lokovšek, A., Pitacco, V., Trkov, D., Zamuda, L. L., Falace, A., i Orlando-Bonaca, M. (2023). Keep It Simple: Improving the *Ex Situ* Culture of *Cystoseira s.l.* to Restore Macroalgal Forests. *Plants*, *12*(14), 2615. https://doi.org/10.3390/plants12142615

Mačić, V., Antolic, B., Thibaut, T., i Svircev, Z. (2010). Distibution of the most common *Cystoseira* C. agardh species (Heterokontophyta, Fucales) on the coast of Montenegro (South-East Adriatic Sea). *Fresenius Environmental Bulletin*, *19*(6), 1191-1198.

Mariani, S., Cefalì, M. E., Chappuis, E., Terradas, M., Pinedo, S., Torras, X., Jordana, E., Medrano, A., Verdura, J., i Ballesteros, E. (2019). Past and present of Fucales from shallow and sheltered shores in Catalonia. *Regional Studies in Marine Science*, *32*, 100824. https://doi.org/10.1016/j.rsma.2019.100824

Marzocchi, M., Curiel, D., Dri, C., i Scattolin, M. (2003). Fenologia morfologica e riproduttiva di *Cystoseira barbata* (Stackhouse) C. Agardh var. *barbata* (Fucales, Fucophyceae) nella laguna di Venezia (Nord Adriatico). *Lavori della Societta Veneziana di Scienze Naturali*, 28.

Matek, A., i Ljubešić, Z. (2024). Primary production research in the Adriatic Sea - a review. *Acta Adriatica*, *65*(2), 1-17. https://doi.org/10.32582/AA.65.2.1

McLay, C. L., i Hayward, T. L. (1987). Population structure and use of *Durvillaea antarctica* holdfasts by the intertidal spider *Desis marina* (Araneae: Desidae). *New Zealand Journal of Zoology*, *14*(1), 29–42. https://doi.org/10.1080/03014223.1987.10422679

Milligan, K. L. D., i DeWreede, R. E. (2000). Variations in holdfast attachment mechanics with developmental stage, substratum-type, season, and wave-exposure for the intertidal kelp species *Hedophyllum sessile* (C. Agardh) Setchell. *Journal of Experimental Marine Biology and Ecology*, *254*(2), 189–209. https://doi.org/10.1016/S0022-0981(00)00279-3

Mineur, F., Arenas, F., Assis, J., Davies, A. J., Engelen, A. H., Fernandes, F., Malta, E. jan, Thibaut, T., Van Nguyen, T., Vaz-Pinto, F., Vranken, S., Serrão, E. A., i De Clerck, O. (2015). European seaweeds under pressure: Consequences for communities and ecosystem

functioning. *Journal of Sea Research*, *98*, 91–108. https://doi.org/10.1016/j.seares.2014.11.004

Molinari-Novoa, E. A., i Guiry, M. D. (2020). Reinstatement of the genera *Gongolaria* Boehmer and *Ericaria* Stackhouse (Sargassaceae, Phaeophyceae) Eduardo. *Notulae Algarum*, *172*, 1–10.

Molinier, R. (1960). Étude des biocénoses marines du Cap Corse. *Vegetatio Acta Geobotanica*, *9*(4–5). https://doi.org/10.1007/BF02917032

Monserrat, M., Verdura, J., Comeau, S., Cottalorda, J. M., Priouzeau, F., Romero, G., i Mangialajo, L. (2023). The role of grazers in early-life stages of *Cystoseira sensu lato* can be crucial in the restoration of marine forests. *Frontiers in Marine Science*, *10*, 1176780. https://doi.org/10.3389/fmars.2023.1176780

Moreda, U., Mazarrasa, I., Cebrian, E., Kaal, J., Ricart, A. M., Serrano, E., i Serrano, O. (2024). Role of macroalgal forests within Mediterranean shallow bays in blue carbon storage. *Science of The Total Environment*, *934*, 173219. https://doi.org/10.1016/J.SCITOTENV.2024.173219

Mulas, M., Silverman, J., Guy-Haim, T., Noè, S., i Rilov, G. (2022a). Thermal vulnerability of the Levantine endemic and endangered habitat-forming macroalga, *Gongolaria rayssiae*: implications for reef carbon. *Frontiers in Marine Science*, *9*, 862332. https://doi.org/10.3389/FMARS.2022.862332/BIBTEX

Mulas, M., Silverman, J., i Rilov, G. (2022b). Biomass calibration of nine dominant native and non-native Levantine seaweeds. *Aquatic Botany*, *178*, 103496. https://doi.org/10.1016/j.aquabot.2022.103496

Munda, I. M. (1980). Survey of the algal biomass in the polluted area around Rovinj ( Istrian coast, North Adriatic). *Acta Adriatica*, *21*(2), 333-354.

Munda, I. M. (1982). The effects of organic pollution on the distribution of fucoid algae from the Istrian coast. *Acta Adriatica*, *23*, 329–337.

Munda, I. M. (1993). Changes and degradation of seaweed stands in the Northern Adriatic. Hydrobiologia, *260*, 239-253.

Munda, I. M. (2000). Long-term marine floristic changes around Rovinj (Istrian coast, North Adriatic) estimated on the basis of historical data from Paul Kuckuck's field diaries from the end of the 19th century. *Nova Hedwigia*, *71*, 1–36.

Muth, A. F., Graham, M. H., Lane, C. E., i Harley, C. D. G. (2019). Recruitment tolerance to increased temperature present across multiple kelp clades. *Ecology*, *100*(3), e02594. https://doi.org/10.1002/ecy.2594

Navarro, L., Ballesteros, E., Linares, C., i Hereu, B. (2011). Spatial and temporal variability of deep-water algal assemblages in the Northwestern Mediterranean: The effects of an exceptional storm. *Estuarine, Coastal and Shelf Science*, *95*(1), 52–58. https://doi.org/10.1016/j.ecss.2011.08.002

Nellemann, C., Corcoran, E., Duarte, C. M., De Young, C., Fonseca, L. E., i Young, D. (2009). Blue Carbon: The role of healthy oceans in binding carbon Blue Carbon: The role of healthy oceans in binding carbon. U.N.E.P., GRID-Arendal. 78 str.

Oliver, E. C. J. (2019). Mean warming not variability drives marine heatwave trends. *Climate Dynamics*, *53*(3–4), 1653–1659. https://doi.org/10.1007/s00382-019-04707-2

Oliver, E. C. J., Benthuysen, J. A., Darmaraki, S., Donat, M. G., Hobday, A. J., Holbrook, N. J., Schlegel, R. W., i Gupta, A. Sen. (2021). Marine Heatwaves. *Annual Reviews*, *13*(1), 313-342.

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

Orellana, S., Hernández, M., & Sansón, M. (2019). Diversity of *Cystoseira sensu lato* (Fucales, Phaeophyceae) in the eastern Atlantic and Mediterranean based on morphological and DNA evidence, including *Carpodesmia* gen. emend. and *Treptacantha* gen. emend. *European Journal of Phycology*, *54*(3), 447-465. https://doi.org/10.1080/09670262.2019.1590862

Orestano, C., i Calvo, S. (1985). La fitocenosi in forma “Aegagropila” nelle acque dello Stagnone (Marsala, Sicilia). *Bollettino dell’Accademia Gioenia di Scienze Naturali di Catania*, *18*(326), 809–820.

Orfanidis, S. (1991). Temperature Responses and Distribution of Macroalgae Belonging to the Warm-temperate Mediterranean-Atlantic Distribution Group. *Botanica Marina*. *34*, 541-552. https://doi.org/10.1515/botm.1991.34.6.541

Orfanidis, S., Iveša, L., Gounaris, S., Tsioli, S., Devescovi, M., i Papathanasiou, V. (2017). *Cystoseira* scale-based biometric relationships. *Botanica Marina*, *60*(3), 1-11. https://doi.org/10.1515/bot-2017-0024

Orfanidis, S., Panayotidis, P., i Ugland, K. I. (2011). Ecological Evaluation Index continuous formula (EEI-c) application: A step forward for functional groups, the formula and reference condition values. *Mediterranean Marine Science*, *12*(1). https://doi.org/10.12681/mms.60

Orfila, E. (2014). Estudi de les condicions òptimes per l’assentament de *Cystoseira* spp. com a mesura de conservació de les últimes poblacions de la costa catalana. Universitat de Girona.

Orlando-Bonaca, M., i Lipej, L. (2005). Factors affecting habitat occupancy of fish assemblage in the Gulf of Trieste (Northern Adriatic Sea). *Marine Ecology*, *26*(1), 42-53. https://doi.org/10.1111/j.1439-0485.2005.00037.x

Orlando-Bonaca, M., Lipej, L., i Orfanidis, S. (2008). Benthic macrophytes as a tool for delineating, monitoring and assessing ecological status: The case of Slovenian coastal waters. *Marine Pollution Bulletin*, *56*(4), 666-676. https://doi.org/10.1016/j.marpolbul.2007.12.018

Orlando-Bonaca, M., Pitacco, V., Slavinec, P., Šiško, M., Makovec, T., i Falace, A. (2021). First restoration experiment for *Gongolaria barbata* in slovenian coastal waters. What can go wrong? *Plants*, *10*(2), 1–17. https://doi.org/10.3390/plants10020239

Orlando-Bonaca, M., Savonitto, G., Asnaghi, V., Trkov, D., Pitacco, V., Šiško, M., Makovec, T., Slavinec, P., Lokovšek, A., Ciriaco, S., Chiantore, M., Kaleb, S., Descourvières, E. P., Srijemsi, M., i Falace, A. (2022a). Where and how - new insight for brown algal forest restoration in the Adriatic. *Frontiers in Marine Science*, *9*, 988584. https://doi.org/10.3389/fmars.2022.988584

Orlando-Bonaca, M., Trkov, D., Klun, K., i Pitacco, V. (2022b). Diversity of Molluscan Assemblage in Relation to Biotic and Abiotic Variables in Brown Algal Forests. *Plants*, *11*(16), 2131. https://doi.org/10.3390/plants11162131

Overrein, M. M., Tinn, P., Aldridge, D., Johnsen, G., i Fragoso, G. M. (2024). Biomass estimations of cultivated kelp using underwater RGB images from a mini-ROV and computer vision approaches. *Frontiers in Marine Science*, *11*, 1324075. https://doi.org/10.3389/FMARS.2024.1324075/BIBTEX

Patil, V., Sun, L., Mohite, V., Liang, J., Wang, D., Gao, Y., i Chen, C. (2024). Effect of benthic and planktonic diatoms on the growth and biochemical composition of the commercial macroalga *Pyropia haitanensis*. *Marine Pollution Bulletin*, *203*, 116411. https://doi.org/10.1016/J.MARPOLBUL.2024.116411

Perez, T., Garrabou, J., Sartoretto, S., Harmelin, J. G., Francour, P., i Vacelet, J. (2000). Mass mortality of marine invertebrates: An unprecedented event in the Northwestern Mediterranean. *Comptes Rendus de l'Academie Des Sciences - Serie III*, *323*(10), 853-65. https://doi.org/10.1016/S0764-4469(00)01237-3

Perkol-Finkel, S., i Airoldi, L. (2010). Loss and recovery potential of marine habitats: An experimental study of factors maintaining resilience in subtidal algal forests at the Adriatic Sea. *PLoS ONE*, *5*(5), e10791. https://doi.org/10.1371/journal.pone.0010791

Perkol-Finkel, S., Ferrario, F., Nicotera, V., i Airoldi, L. (2012). Conservation challenges in urban seascapes: Promoting the growth of threatened species on coastal infrastructures. *Journal of Applied Ecology*, *49*(6), 1457–1466. https://doi.org/10.1111/j.1365-2664.2012.02204.x

Piazzi, L., Bonaviri, C., Castelli, A., Ceccherelli, G., Costa, G., Curini-Galletti, M., Langeneck, J., Manconi, R., Montefalcone, M., Pipitone, C., Rosso, A., i Pinna, S. (2018). Biodiversity in canopy-forming algae: Structure and spatial variability of the Mediterranean *Cystoseira* assemblages. *Estuarine, Coastal and Shelf Science*, *207*, 132-141. https://doi.org/10.1016/j.ecss.2018.04.001

Pinedo, S., Arévalo, R., i Ballesteros, E. (2015). Seasonal dynamics of upper sublittoral assemblages on Mediterranean rocky shores along a eutrophication gradient. *Estuarine, Coastal and Shelf Science*, *161*, 93–101. https://doi.org/10.1016/j.ecss.2015.05.004

Pinna, S., Piazzi, L., Ceccherelli, G., Castelli, A., Costa, G., Curini-Galletti, M., Gianguzza, P., Langeneck, J., Manconi, R., Montefalcone, M., Pipitone, C., Rosso, A., i Bonaviri, C. (2020). Macroalgal forest vs sea urchin barren: Patterns of macro-zoobenthic diversity in a large-scale Mediterranean study: Macro-zoobenthos of barren and macroalgal forests. *Marine Environmental Research*, *159*, 104955. https://doi.org/10.1016/j.marenvres.2020.104955

Pitacco, V., Orlando-Bonaca, M., Mavrič, B., Popović, A., i Lipej, L. (2014). Mollusc fauna associated with the *Cystoseira* algal associations in the Gulf of Trieste (Northern Adriatic Sea). *Mediterranean Marine Science*, *15*(2), 225-238. https://doi.org/10.12681/mms.466

Podolšak, I. (2022). Mikrobna zajednica u sedimentima livada morskih cvjetnica *Cymodocea nodosa* i *Zostera noltii* u priobalju zapadne Istre. *Sveučilište u Zagrebu, Prirodoslovno-Matematički Fakultet, Geološki Odsjek*.

Puhr, K., i Pikelj, K. (2012). The effect of *in situ* shading on a *Posidonia oceanica* meadow situated within a fish farm induced moderately nutrient enriched environment. *Marine Pollution Bulletin*, *64*(8), 1537–1548. https://doi.org/10.1016/J.MARPOLBUL.2012.05.022

Ramdani, M., Oufekkir, M. B., El Asri, O., El Khiati, N., Ramdani, M., Denis, F., i Flower, R. J. (2021). First report of *Cystoseira aurantia* Kützing from the Mediterranean coast of Morocco. *Botanica Marina*, *64*(1), 41–47. https://doi.org/10.1515/bot-2020-0061

R Core Team (2023). R: A language and environment for statistical computing. R foundation for statistical computing. *R Foundation for Statistical Computing*. https://www.R-project.org/.

Ribera, M. A., Garreta, A. G., Gallardo, T., Cormaci, M., Furnari, G., i Giaccone, G. (1992). Check-list of Mediterranean Seaweeds: I. Fucophyceae (Warming, 1884). *Botanica Marina*, *35*(2), 109-130. https://doi.org/10.1515/botm.1992.35.2.109

Rindi, F., Vergés, A., Zuchegna, I., Bianchelli, S., de Caralt, S., Galobart, C., Santamaría, J., Martini, F., Monserrat, M., Orfanidis, S., Sitjà, C., Tsioli, S., Verdura, J., Mangialajo, L., Fraschetti, S., Danovaro, R., i Cebrian, E. (2023). Standardized protocol for reproductive phenology monitoring of fucalean algae of the genus *Cystoseira s.l.* with potential for restoration. *Frontiers in Marine Science*, *10*, 1250642. https://doi.org/10.3389/fmars.2023.1250642

Ripley, B., Venables, B., Bates, D. M., Hornik, K., Gebhardt, A., i Firth, D. (2019). Package 'MASS' (Version 7.3-51.4). *Cran-R Project*.

Riquet, F., De Kuyper, C. A., Fauvelot, C., Airoldi, L., Planes, S., Fraschetti, S., Mačić, V., Milchakova, N., Mangialajo, L., i Bottin, L. (2021). Highly restricted dispersal in habitat-forming seaweed may impede natural recovery of disturbed populations. *Scientific Reports*, *11*(1), 16792. https://doi.org/10.1038/S41598-021-96027-X

Sadogurska, S. S. (2021). Unattached *Cystoseira s. l.* in the Black Sea: taxonomy of *Gongolaria barbata* f. *repens* comb. nov. *Algologia*, *31*(2), 150–162. https://doi.org/10.15407/alg31.02.150

Sala, E., Ballesteros, E., Dendrinos, P., Di Franco, A., Ferretti, F., Foley, D., Fraschetti, S., Friedlander, A., Garrabou, J., Güçlüsoy, H., Guidetti, P., Halpern, B. S., Hereu, B., Karamanlidis, A. A., Kizilkaya, Z., Macpherson, E., Mangialajo, L., Mariani, S., Micheli, F., … i Zabala, M. (2012). The structure of mediterranean rocky reef ecosystems across environmental and human gradients, and conservation implications. *PLoS ONE*, *7*(2), e32742. https://doi.org/10.1371/journal.pone.0032742

Sala, E., Boudouresque, C. F., i Harmelin-Vivien, M. (1998). Fishing, Trophic Cascades, and the Structure of Algal Assemblages: Evaluation of an Old but Untested Paradigm. *Oikos*, *82*(3). 425-439. https://doi.org/10.2307/3546364

Sala, E., Kizilkaya, Z., Yildirim, D., i Ballesteros, E. (2011). Alien marine fishes deplete algal biomass in the Eastern Mediterranean. *PLoS ONE*, *6*(2), e17356. https://doi.org/10.1371/journal.pone.0017356

Sales, M., i Ballesteros, E. (2009). Shallow *Cystoseira* (Fucales: Ochrophyta) assemblages thriving in sheltered areas from Menorca (NW Mediterranean): Relationships with environmental factors and anthropogenic pressures. *Estuarine, Coastal and Shelf Science*, *84*(4), 476–482 . https://doi.org/10.1016/j.ecss.2009.07.013

Sales, M., i Ballesteros, E. (2012). Seasonal dynamics and annual production of *Cystoseira crinita* (Fucales: Ochrophyta)-dominated assemblages from the northwestern Mediterranean. *Scientia Marina*, *76*(2), 391–401. https://doi.org/10.3989/SCIMAR.03465.16D

Sales, M., Cebrian, E., Tomas, F., i Ballesteros, E. (2011). Pollution impacts and recovery potential in three species of the genus *Cystoseira* (Fucales, Heterokontophyta). *Estuarine, Coastal and Shelf Science*, *92*(3), 347–357. https://doi.org/10.1016/j.ecss.2011.01.008

Savonitto, G., Alongi, G., i Falace, A. (2019). Reproductive phenology, zygote embryology and germling development of the threatened *Carpodesmia barbatula* (= *Cystoseira barbatula*) (Fucales, Phaeophyta) towards its possible restoration. *Webbia*, *74*(2), 317-323. https://doi.org/10.1080/00837792.2019.1692594

Savonitto, G., De La Fuente, G., Tordoni, E., Ciriaco, S., Srijemsi, M., Bacaro, G., Chiantore, M., i Falace, A. (2021). Addressing reproductive stochasticity and grazing impacts in the restoration of a canopy-forming brown alga by implementing mitigation solutions. *Aquatic Conservation: Marine and Freshwater Ecosystems*, *31*(7), 1611–1623. https://doi.org/10.1002/aqc.3555

Schlegel, R.W., i J. Smit, A. (2018). heatwaveR: A central algorithm for the detection of heatwaves and cold-spells. *Journal of Open Source Software*, *3*(27), 821. https://doi.org/10.21105/joss.00821

Scrosati, R. A., MacDonald, H. L., Córdova, C. A., i Casas, G. N. (2020). Length and Biomass Data for Atlantic and Pacific Seaweeds From Both Hemispheres. *Frontiers in Marine Science*, *7*, 592675. https://doi.org/10.3389/fmars.2020.592675

Sen Gupta, A., Thomsen, M., Benthuysen, J. A., Hobday, A. J., Oliver, E., Alexander, L. V., Burrows, M. T., Donat, M. G., Feng, M., Holbrook, N. J., Perkins-Kirkpatrick, S., Moore, P. J., Rodrigues, R. R., Scannell, H. A., Taschetto, A. S., Ummenhofer, C. C., Wernberg, T., i Smale, D. A. (2020). Drivers and impacts of the most extreme marine heatwaves events. *Scientific Reports*, *10*(1), 19359. https://doi.org/10.1038/s41598-020-75445-3

Shea, R., i Chopin, T. (2007). Effects of germanium dioxide, an inhibitor of diatom growth, on the microscopic laboratory cultivation stage of the kelp, *Laminaria saccharina*. *Journal of Applied Phycology*, *19*, 27:32.

Shiganova, T., i Malej, A. (2009). Native and non-native ctenophores in the Gulf of Trieste, Northern Adriatic Sea. *Journal of Plankton Research*, *31*(1), 61–71. https://doi.org/10.1093/plankt/fbn102

Smale, D. A., i Wernberg, T. (2009). Satellite-derived SST data as a proxy for water temperature in nearshore benthic ecology. *Marine Ecology Progress Series*, *387*, 27–37. https://doi.org/10.3354/meps08132

Smith, C. J., Verdura, J., Papadopoulou, N., Fraschetti, S., Cebrian, E., Fabbrizzi, E., Monserrat, M., Drake, M., Bianchelli, S., Danovaro, R., Malak, D. A., Ballesteros, E., Benjumea Tesouro, T., Boissery, P., D'Ambrosio, P., Galobart, C., Javel, F., Laurent, D., Orfanidis, S., i Mangialajo, L. (2023). A decision-support framework for the restoration of *Cystoseira sensu lato* forests. *Frontiers in Marine Science*, *10*, 1159262. https://doi.org/10.3389/FMARS.2023.1159262/BIBTEX

Smith, K. E., Burrows, M. T., Hobday, A. J., King, N. G., Moore, P. J., Gupta, A. Sen, Thomsen, M. S., Wernberg, T., i Smale, D. A. (2023). Biological Impacts of Marine Heatwaves. *Annual Review of Marine Science*, *15*(1), 119-145. https://doi.org/10.1146/annurev-marine-032122

Soltan, D., Verlaque, M., François Boudouresque, C., i Francour, P. (2001). Changes in macroalgal communities in the vicinity of a Mediterranean sewage outfall after the setting up of a treatment plant. *Marine Pollution Bulletin*, *42*(1), 59–71. https://doi.org/10.1016/S0025-326X(00)00116-8

Stagnol, D., Macé, M., Destombe, C., i Davoult, D. (2016). Allometric relationships for intertidal macroalgae species of commercial interest. *Journal of Applied Phycology*, *28*(6). https://doi.org/10.1007/s10811-016-0860-1

Starko, S., i Martone, P. T. (2016). An empirical test of 'universal' biomass scaling relationships in kelps: evidence of convergence with seed plants. *New Phytologist*, *212*(3), 719-729. https://doi.org/10.1111/nph.14120

Stobart, B., Mayfield, S., Mundy, C., Hobday, A. J., i Hartog, J. R. (2016). Comparison of *in situ* and satellite sea surface-temperature data from South Australia and Tasmania: How reliable are satellite data as a proxy for coastal temperatures in temperate southern Australia? *Marine and Freshwater Research*, *67*(5), 612–625. https://doi.org/10.1071/MF14340

Straub, S. C., Wernberg, T., Marzinelli, E. M., Vergés, A., Kelaher, B. P., i Coleman, M. A. (2022). Persistence of seaweed forests in the anthropocene will depend on warming and marine heatwave profiles. *Journal of Phycology*, *58*(1), 22–35. https://doi.org/10.1111/jpy.13222

Strickland, J. D. H., i Parsons., T. R. (1972). A practical handbook for seawater analysis. Second Edition. U *Fisheries Research Board of Canada. Ottowa, Canada.*

Susini, M. L., Mangialajo, L., Thibaut, T., i Meinesz, A. (2007). Development of a transplantation technique of *Cystoseira amentacea* var. *stricta* and *Cystoseira compressa*. *Biodiversity in Enclosed Seas and Artificial Marine Habitats*, *580*, 241–244. https://doi.org/10.1007/978-1-4020-6156-1_21

Tait, L. W., i Schiel, D. R. (2011). Dynamics of productivity in naturally structured macroalgal assemblages: Importance of canopy structure on light-use efficiency. *Marine Ecology Progress Series*, *421*, 97-107. https://doi.org/10.3354/meps08909

Tamburello, L., Chiarore, A., Fabbrizzi, E., Colletti, A., Franzitta, G., Grech, D., Rindi, F., Rizzo, L., Savinelli, B., & Fraschetti, S. (2022). Can we preserve and restore overlooked macroalgal forests? *Science of the Total Environment*, *806*(4), 150855. https://doi.org/10.1016/j.scitotenv.2021.150855

Tamburello, L., Papa, L., Guarnieri, G., Basconi, L., Zampardi, S., Scipione, M. B., Terlizzi, A., Zupo, V., i Fraschetti, S. (2019). Are we ready for scaling up restoration actions? An insight from Mediterranean macroalgal canopies. *PLoS ONE*, *14*(10). https://doi.org/10.1371/journal.pone.0224477

Thibaut, T., Blanfuné, A., Boudouresque, C. F., Cottalorda, J. M., Hereu, B., Susini, M. L., i Verlaque, M. (2016). Unexpected Temporal Stability of *Cystoseira* and *Sargassum* Forests in Port-Cros, one of the Oldest Mediterranean Marine National Parks. *Cryptogamie, Algologie*, *37*(1), 61-90. https://doi.org/10.7872/crya/v37.iss1.2016.61

Thibaut, T., Blanfuné, A., Boudouresque, C. F., i Verlaque, M. (2015). Decline and local extinction of Fucales in the French Riviera: The harbinger of future extinctions? *Mediterranean Marine Science*, *16*(1), 206-224. https://doi.org/10.12681/mms.1032

Thibaut, T., Blanfuné, A., Markovic, L., Verlaque, M., Boudouresque, C. F., Perret-Boudouresque, M., Maćic, V., i Bottin, L. (2014). Unexpected abundance and long-term relative stability of the brown alga *Cystoseira amentacea*, hitherto regarded as a threatened species, in the north-western Mediterranean Sea. *Marine Pollution Bulletin*, *89*(1–2), 305–323. https://doi.org/10.1016/j.marpolbul.2014.09.043

Thibaut, T., Pinedo, S., Torras, X., i Ballesteros, E. (2005). Long-term decline of the populations of Fucales (*Cystoseira* spp. and *Sargassum* spp.) in the Albères coast (France, North-western Mediterranean). *Marine Pollution Bulletin*, *50*(12), 1472–1489. https://doi.org/10.1016/j.marpolbul.2005.06.014

Thiriet, P. D., Di Franco, A., Cheminée, A., Guidetti, P., Bianchimani, O., Basthard-Bogain, S., Cottalorda, J. M., Arceo, H., Moranta, J., Lejeune, P., Francour, P., i Mangialajo, L. (2016). Abundance and diversity of crypto- and necto-benthiccoastal fish are higher in marine forests than in structurally less complex macroalgal assemblages. *PLoS ONE*, *11*(10), e0164121. https://doi.org/10.1371/journal.pone.0164121

UNEP (2019). Convention for the Protection of the Marine Environment and the Coastal Region of the Mediterranean and its Protocols. https://wedocs.unep.org/bitstream/handle/20.500.11822/31970/bcp2019_web_eng.pdf pristup: 01.04.2024.

Valdazo, J., Viera-Rodríguez, M. A., i Tuya, F. (2020). Seasonality in the canopy structure of the endangered brown macroalga *Cystoseira abies-marina* at Gran Canaria Island (Canary Islands, eastern Atlantic). *European Journal of Phycology*, *55*(3), 253-265. https://doi.org/10.1080/09670262.2019.1696989

Verdura, J., Rehues, L., Mangialajo, L., Fraschetti, S., Belattmania, Z., Bianchelli, S., Blanfuné, A., Sabour, B., Chiarore, A., Danovaro, R., Fabbrizzi, E., Giakoumi, S., Iveša, L., Katsanevakis, S., Kytinou, E., Nasto, I., Nikolaou, A., Orfanidis, S., Rilov, G., … i Cebrian, E. (2023). Distribution, health and threats to Mediterranean macroalgal forests: defining the baselines for their conservation and restoration. *Frontiers in Marine Science*, *10*, 1258842. https://doi.org/10.3389/fmars.2023.1258842

Verdura, J., Sales, M., Ballesteros, E., Cefalì, M. E., i Cebrian, E. (2018). Restoration of a canopy-forming alga based on recruitment enhancement: Methods and long-term success assessment. *Frontiers in Plant Science*, *9*, 1832. https://doi.org/10.3389/fpls.2018.01832

Verdura, J., Santamaría, J., Ballesteros, E., Smale, D. A., Cefalì, M. E., Golo, R., de Caralt, S., Vergés, A., i Cebrian, E. (2021). Local-scale climatic refugia offer sanctuary for a habitat-

forming species during a marine heatwave. *Journal of Ecology*, *109*(4), 1758–1773. https://doi.org/10.1111/1365-2745.13599

Vergés, A., Alcoverro, T., i Ballesteros, E. (2009). Role of fish herbivory in structuring the vertical distribution of canopy algae *Cystoseira* spp. in the Mediterranean Sea. *Marine Ecology Progress Series*, *375*, 1–11. https://doi.org/10.3354/meps07778

Vergés, A., Tomas, F., Cebrian, E., Ballesteros, E., Kizilkaya, Z., Dendrinos, P., Karamanlidis, A. A., Spiegel, D., i Sala, E. (2014). Tropical rabbitfish and the deforestation of a warming temperate sea. *Journal of Ecology*, *102*(6), 1518–1527. https://doi.org/10.1111/1365-2745.12324

Vijeće Europe (1979). Convention on the Conservation of European Wildlife and Natural Habitats. Appendix I – Strictly protected flora species. https://rm.coe.int/168097eb56 pristup: 01.04.2024.

Vijeće Europe (1992). Council Directive 92/43/EEC of 21 May 1992 on the conservation of natural habitats and of wild fauna and flora. https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:31992L0043 pristup: 01.04.2024.

Vilibić, I., Pranić, P., i Denamiel, C. (2023). North Adriatic Dense Water: lessons learned since the pioneering work of Mira Zore-Armanda 60 years ago. *Acta Adriatica*, *64*(1), 53-78. https://doi.org/10.32582/aa.64.1.11

Wernberg, T., Thomsen, M. S., Tuya, F., i Kendrick, G. A. (2011). Biogenic habitat structure of seaweeds change along a latitudinal gradient in ocean temperature. *Journal of Experimental Marine Biology and Ecology*, *400*(1–2), 264–271. https://doi.org/10.1016/j.jembe.2011.02.017

Wickham, S. B., Darimont, C. T., Reynolds, J. D., i Starzomski, B. M. (2019). Species-specific wet-dry mass calibrations for dominant Northeastern Pacific Ocean macroalgae and seagrass. *Aquatic Botany*, *152*, 27-31. https://doi.org/10.1016/j.aquabot.2018.09.006

Yeruham, E., Rilov, G., Shpigel, M., i Abelson, A. (2015). Collapse of the echinoid *Paracentrotus lividus* populations in the Eastern Mediterranean—result of climate change? *Scientific Reports*, *5*(1), 1–6. https://doi.org/10.1038/srep13479

Zavodnik, N., Iveša, L., i Travizi, A. (2002). Note on recolonisation of fucoid algae *Cystoseira* spp. and *Fucus virsoides* in the North Adriatic Sea. *Acta Adriatica*, *43*(1), 25–32.

# 9. PRILOZI

Tablica P1. Deskriptivna statistika morfometrijskih karakteristika (L_ktot, L_k, L_t i N_k) i biomase (W_w) za jedinke uzorkovane na šest lokacija (2021.-2023.).

| Karakteristika | prosjek | sd | medijan | min | maks | Lokacija |
|---|---|---|---|---|---|---|
| W_w | 5,23103448 | 3,09404075 | 4,38 | 0,64 | 12,91 | LA |
| L_ktot | 16,6965517 | 10,0907837 | 15,5 | 2 | 35,9 | LA |
| L_k | 9,74482759 | 3,5939022 | 10,4 | 2 | 15,4 | LA |
| L_t | 9,74482759 | 3,5939022 | 10,4 | 2 | 15,4 | LA |
| N_k | 3,79310345 | 2,93232368 | 3 | 1 | 11 | LA |
| W_w | 13,2397143 | 19,5964992 | 5,08 | 0,4 | 94,37 | FU |
| L_ktot | 12,112963 | 18,4708223 | 5,9 | 1,1 | 84,2 | FU |
| L_k | 3,11666667 | 2,10731327 | 2,8 | 1,1 | 9,5 | FU |
| L_t | 13,2171429 | 4,42363211 | 13,4 | 5 | 23 | FU |
| N_k | 5,68571429 | 4,60671778 | 4 | 1 | 19 | FU |
| W_w | 18,6444516 | 18,018833 | 14,44 | 1,04 | 82,64 | BU |
| L_ktot | 38,8254839 | 31,3763862 | 33 | 0,4 | 129,01 | BU |
| L_k | 9,49774194 | 4,94619295 | 9 | 0,4 | 21,2 | BU |
| L_t | 16,583871 | 5,92289888 | 15,5 | 6,6 | 33,5 | BU |
| N_k | 11,8709677 | 10,6167852 | 8 | 1 | 44 | BU |
| W_w | 18,3090909 | 7,87721836 | 19,18 | 4,67 | 29,08 | KA |
| L_ktot | 40,1636364 | 23,860858 | 38,6 | 8,6 | 83,5 | KA |
| L_k | 22,3272727 | 10,5558601 | 20 | 8,1 | 39 | KA |
| L_t | 28,2272727 | 9,54872671 | 24,6 | 15,5 | 44,4 | KA |
| N_k | 9,54545455 | 8,07915387 | 7 | 2 | 25 | KA |
| W_w | 10,4268056 | 10,3938297 | 7,14 | 0,82 | 59,67 | ŠĆ1 |
| L_ktot | 40,4834722 | 32,6737069 | 29,155 | 3 | 186,6 | ŠĆ1 |
| L_k | 10,5744444 | 3,79718201 | 10,45 | 2,02 | 21,6 | ŠĆ1 |
| L_t | 17,2713889 | 7,57057374 | 17 | 2,7 | 34,2 | ŠĆ1 |
| N_k | 8,70833333 | 7,01595265 | 7 | 1 | 37 | ŠĆ1 |

| | | | | | | |
|---|---|---|---|---|---|---|
| W_w | 26,6356757 | 24,0757405 | 20,56 | 4,17 | 121,2 | ŠĆ2 |
| L_ktot | 175,618919 | 151,867023 | 125,6 | 19,4 | 574,8 | ŠĆ2 |
| L_k | 28,8864865 | 15,7129487 | 27,5 | 11,5 | 84 | ŠĆ2 |
| L_t | 30,1345946 | 15,6495528 | 29 | 11,5 | 85,8 | ŠĆ2 |
| N_k | 26,3513514 | 20,0654709 | 22 | 1 | 81 | ŠĆ2 |

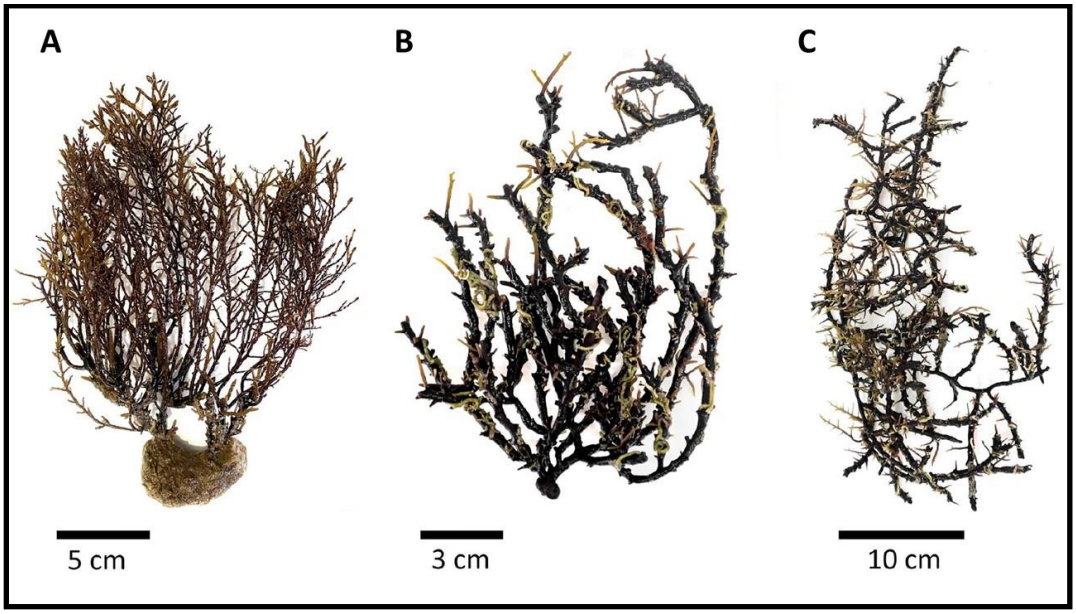


Slika P1. Jedinke vrste *Gongolaria barbata* iz lagune Šćuza. Epilitska jedinka pričvršćena za kamenčić (A), pleustofitska jedinka koja je zadržala bazalnu pločicu (B) i iznimno razgranata pleustofitska jedinka bez bazalne pločice (C).

Slika P2. Jedinka vrste *Gongolaria barbata* iz mediolitoralne lokvice na lokaciji Bijela uvala (A) i jedinka iz mediolitoralne lokvice na lokaciji Kamenjak (B).

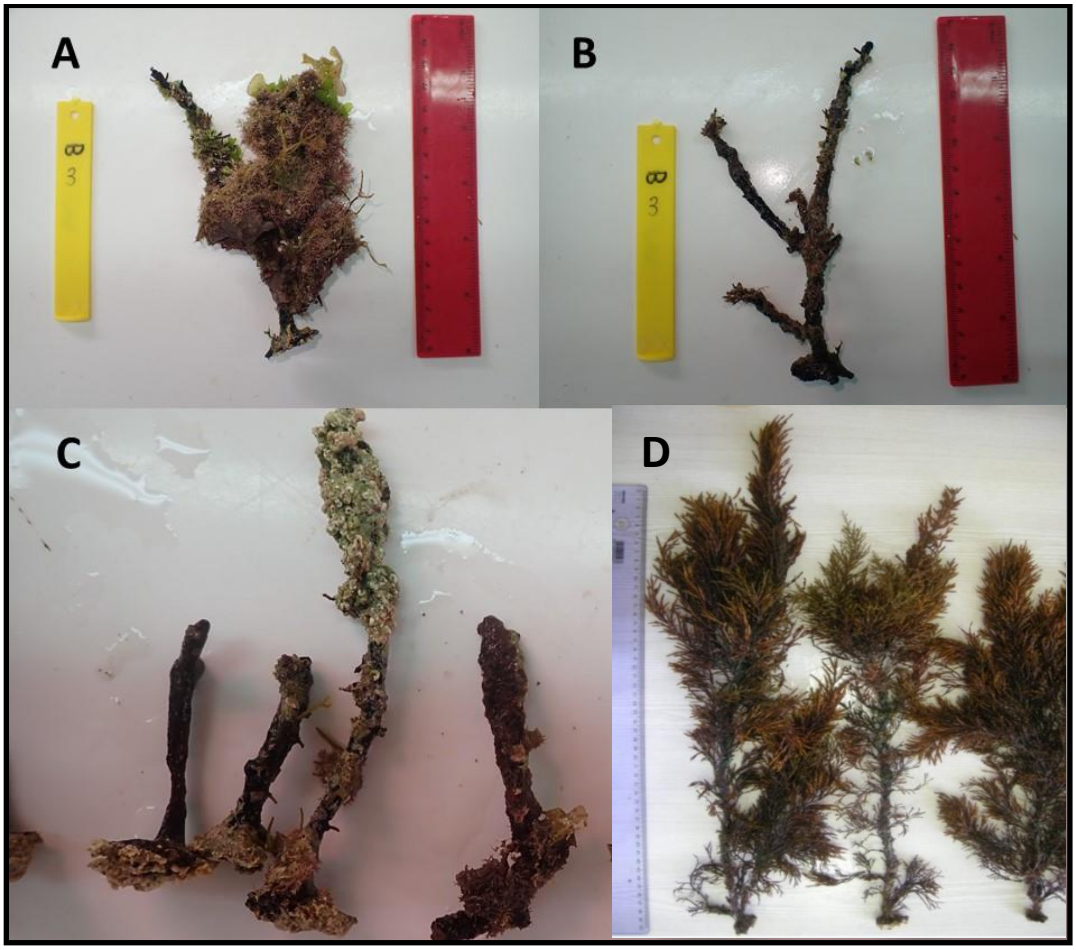


Slika P3. Jedinke iz plitkog infralitorala na lokaciji Lanterna. Jedinka prekrivena epibiontima (A), ista jedinka očišćena od epibionata (B), degradirane jedinke zbog utjecaja ježinaca (C) i zdrave jedinke iz 2009. godine (D).

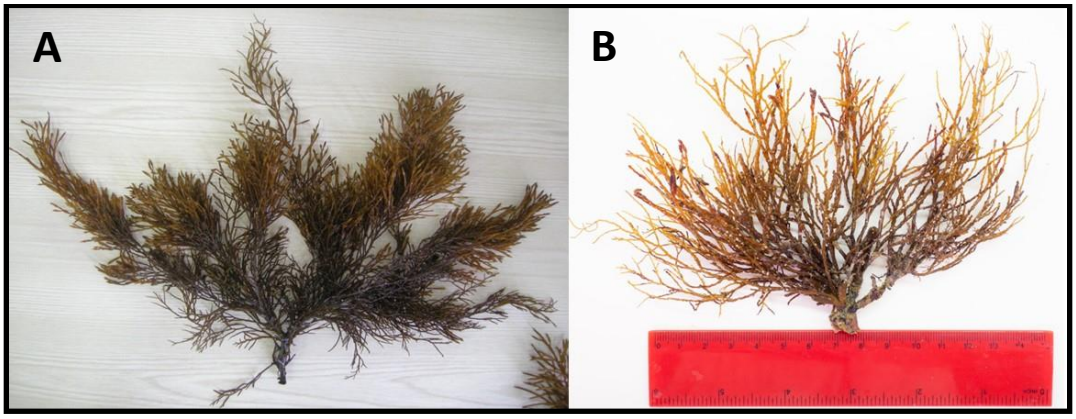


Slika P4. Jedinka iz plitkog infralitorala na lokaciji Funtana 2009. godine (A) i jedinka s iste lokacije 2023. godine (B).

Tablica P2. Linearni modeli s odgovarajućim AICc i $R^2$ vrijednostima za vrstu *Gongolaria barbata* na lokaciji Šćuza 1. Varijable: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), duljina talusa (L_t), broj kauloida (N_k) i biomasa (W_w). Sve varijable su log-transformirane. Najbolje rangirani modeli su na vrhu svake liste.

| **Model** | **AICc** | **$R^2$** | **Lokacija** |
|---|---|---|---|
| W_w ~ L_ktot + L_t + N_k | -98,792997 | 0,9189226 | ŠĆ1 |
| W_w ~ L_ktot + L_k + L_t | -98,785661 | 0,9189144 | ŠĆ1 |
| W_w ~ L_ktot + L_t | -98,084468 | 0,9167529 | ŠĆ1 |
| W_w ~ L_ktot + L_k + L_t + N_k | -96,949207 | 0,9182460 | ŠĆ1 |
| W_w ~ L_ktot | -85,199470 | 0,9002704 | ŠĆ1 |
| W_w ~ L_ktot + N_k | -83,165968 | 0,8975869 | ŠĆ1 |
| W_w ~ L_ktot + L_k | -83,084285 | 0,8974706 | ŠĆ1 |
| W_w ~ L_ktot + L_k + N_k | -80,927627 | 0,8960891 | ŠĆ1 |
| W_w ~ L_k + L_t + N_k | -75,266918 | 0,8875897 | ŠĆ1 |
| W_w ~ L_t + N_k | -54,518145 | 0,8475401 | ŠĆ1 |
| W_w ~ L_k + N_k | -54,106652 | 0,8466663 | ŠĆ1 |

| Model | AICc | $R^2$ | Lokacija |
|---|---|---|---|
| W_w ~ N_k | -1,919416 | 0,6829276 | ŠĆ1 |
| W_w ~ L_k + L_t | 30,141684 | 0,5059027 | ŠĆ1 |
| W_w ~ L_k | 37,882507 | 0,4488898 | ŠĆ1 |
| W_w ~ L_t | 43,292149 | 0,4058875 | ŠĆ1 |

Tablica P3. Linearni modeli s odgovarajućim AICc i $R^2$ vrijednostima za vrstu *Gongolaria barbata* na lokaciji Šćuza 2. Varijable: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), duljina talusa (L_t), broj kauloida (N_k) i mokra biomasa (W_w). Sve varijable su log-transformirane. Najbolje rangirani modeli su na vrhu svake liste.

| Model | AICc | $R^2$ | Lokacija |
|---|---|---|---|
| W_w ~ L_ktot + L_k | -57,393904 | 0,9118692 | ŠĆ2 |
| W_w ~ L_ktot + L_t | -57,162501 | 0,9113163 | ŠĆ2 |
| W_w ~ L_ktot | -56,569097 | 0,9092483 | ŠĆ2 |
| W_w ~ L_ktot + N_k | -55,829424 | 0,9080628 | ŠĆ2 |
| W_w ~ L_ktot + L_k + N_k | -55,013808 | 0,9095479 | ŠĆ2 |
| W_w ~ L_ktot + L_t + N_k | -54,908634 | 0,9092904 | ŠĆ2 |
| W_w ~ L_ktot + L_k + L_t | -54,878655 | 0,9092169 | ŠĆ2 |
| W_w ~ L_ktot + L_k + L_t + N_k | -52,345390 | 0,9067643 | ŠĆ2 |
| W_w ~ L_k + N_k | -38,724624 | 0,8540305 | ŠĆ2 |
| W_w ~ L_k + L_t + N_k | -36,308859 | 0,8500414 | ŠĆ2 |
| W_w ~ L_t + N_k | -35,988013 | 0,8428250 | ŠĆ2 |
| W_w ~ N_k | -21,416422 | 0,7653255 | ŠĆ2 |
| W_w ~ L_k | 9,693614 | 0,4559663 | ŠĆ2 |

| Model | AICc | $R^2$ | Lokacija |
|---|---|---|---|
| W_w ~ L_t | 11,583553 | 0,4274554 | ŠĆ2 |
| W_w ~ L_k + L_t | 12,067447 | 0,4239721 | ŠĆ2 |

Tablica P4. Linearni modeli s odgovarajućim AICc i $R^2$ vrijednostima za vrstu *Gongolaria barbata* na lokaciji Bijela uvala. Varijable: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), duljina talusa (L_t), broj kauloida (N_k) i mokra biomasa (W_w). Sve varijable su log-transformirane. Najbolje rangirani modeli su na vrhu svake liste.

| Model | AICc | $R^2$ | Lokacija |
|---|---|---|---|
| W_w ~ L_t + N_k | -17,88243942 | 0,8486283 | BU |
| W_w ~ L_ktot + L_t + N_k | -15,39917215 | 0,8438619 | BU |
| W_w ~ L_k + L_t + N_k | -15,27667669 | 0,8432437 | BU |
| W_w ~ L_ktot + L_k + L_t + N_k | -12,57490137 | 0,8380514 | BU |
| W_w ~ L_k + N_k | -6,05221931 | 0,7782927 | BU |
| W_w ~ L_ktot + L_k + N_k | -3,57911828 | 0,7713864 | BU |
| W_w ~ L_ktot + N_k | -2,21854035 | 0,7491073 | BU |
| W_w ~ L_ktot + L_k + L_t | -0,74151043 | 0,7494725 | BU |
| W_w ~ N_k | 0,03964161 | 0,7273355 | BU |
| W_w ~ L_ktot + L_t | 0,70656927 | 0,7242806 | BU |
| W_w ~ L_ktot | 5,22780795 | 0,6776615 | BU |
| W_w ~ L_ktot + L_k | 7,68703530 | 0,6546495 | BU |
| W_w ~ L_k + L_t | 16,79495034 | 0,5367052 | BU |
| W_w ~ L_k | 18,20313117 | 0,5101197 | BU |

| Model | AICc | $R^2$ | Lokacija |
|---|---|---|---|
| W_w ~ L_t | 20,00769234 | 0,4807567 | BU |

Tablica P5. Linearni modeli s odgovarajućim AICc i $R^2$ vrijednostima za vrstu *Gongolaria barbata* na lokaciji Funtana. Varijable: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), duljina talusa (L_t), broj kauloida (N_k) i mokra biomasa (W_w). Sve varijable su log-transformirane. Najbolje rangirani modeli su na vrhu svake liste.

| Model | AICc | $R^2$ | Lokacija |
|---|---|---|---|
| W_w ~ L_ktot | -17,872231 | 0,8953627 | FU |
| W_w ~ L_ktot + L_t | -15,960123 | 0,8892630 | FU |
| W_w ~ L_ktot + L_k | -15,940918 | 0,8891842 | FU |
| W_w ~ L_ktot + N_k | -15,733316 | 0,8883288 | FU |
| W_w ~ L_ktot + L_k + N_k | -14,327181 | 0,8892328 | FU |
| W_w ~ L_ktot + L_k + L_t | -14,064283 | 0,8881490 | FU |
| W_w ~ L_ktot + L_t + N_k | -13,371767 | 0,8852431 | FU |
| W_w ~ L_ktot + L_k + L_t + N_k | -11,808129 | 0,8864065 | FU |
| W_w ~ L_k + L_t + N_k | 4,820298 | 0,7748884 | FU |
| W_w ~ L_k + N_k | 8,865147 | 0,7222802 | FU |
| W_w ~ L_t + N_k | 15,030532 | 0,7679949 | FU |
| W_w ~ L_k + L_t | 20,984965 | 0,5649352 | FU |
| W_w ~ L_t | 28,340399 | 0,6579473 | FU |
| W_w ~ N_k | 30,152348 | 0,6397728 | FU |
| W_w ~ L_k | 31,539708 | 0,3476563 | FU |

Tablica P6. Linearni modeli s odgovarajućim AICc i $R^2$ vrijednostima za vrstu *Gongolaria barbata* na lokaciji Kamenjak. Varijable: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), duljina talusa (L_t), broj kauloida (N_k) i mokra biomasa (W_w). Sve varijable su log-transformirane. Najbolje rangirani modeli su na vrhu svake liste.

| **Model** | **AICc** | **$R^2$** | **Lokacija** |
|---|---|---|---|
| W_w ~ N_k | -5,10711836042 | 0,6603868 | KA |
| W_w ~ L_ktot + L_k | -3,05351824974 | 0,6420121 | KA |
| W_w ~ L_k + N_k | -1,97557150155 | 0,6051546 | KA |
| W_w ~ L_t + N_k | -1,79692576149 | 0,5986898 | KA |
| W_w ~ L_ktot + N_k | -1,48715137042 | 0,5872277 | KA |
| W_w ~ L_ktot | 0,00008916587 | 0,4597138 | KA |
| W_w ~ L_ktot + L_t | 1,14383463737 | 0,4756934 | KA |
| W_w ~ L_ktot + L_k + L_t | 2,13124717117 | 0,5928497 | KA |
| W_w ~ L_ktot + L_k + N_k | 2,13210812394 | 0,5928179 | KA |
| W_w ~ L_k + L_t + N_k | 3,25431800999 | 0,5490846 | KA |
| W_w ~ L_ktot + L_t + N_k | 3,36836377264 | 0,5443853 | KA |
| W_w ~ L_t | 4,05561539190 | 0,2188375 | KA |
| W_w ~ L_k | 5,30531440259 | 0,1248527 | KA |
| W_w ~ L_k + L_t | 6,88899661354 | 0,1160822 | KA |
| W_w ~ L_ktot + L_k + L_t + N_k | 9,43252878331 | 0,5263734 | KA |

Tablica P7. Linearni modeli s odgovarajućim AICc i $R^2$ vrijednostima za vrstu *Gongolaria barbata* na lokaciji Lanterna. Varijable: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), duljina talusa (L_t), broj kauloida (N_k) i mokra biomasa (W_w). Sve varijable su log-transformirane. Najbolje rangirani modeli su na vrhu svake liste.

| **Model** | **AICc** | **$R^2$** | **Lokacija** |
|---|---|---|---|
| W_w ~ L_ktot + L_k | -2,8179618 | 0,5505388 | LA |
| W_w ~ L_ktot + L_t | -2,8179618 | 0,5505388 | LA |
| W_w ~ N_k | -2,3820906 | 0,5382030 | LA |
| W_w ~ L_ktot + L_k + L_t | -2,1112951 | 0,5505388 | LA |
| W_w ~ L_ktot + N_k | -1,4921261 | 0,5295132 | LA |
| W_w ~ L_ktot | -1,2729835 | 0,5201995 | LA |
| W_w ~ L_k + N_k | -0,5764173 | 0,5144200 | LA |
| W_w ~ L_t + N_k | -0,5764173 | 0,5144200 | LA |
| W_w ~ L_ktot + L_k + N_k | -0,1215481 | 0,5327256 | LA |
| W_w ~ L_ktot + L_t + N_k | -0,1215481 | 0,5327256 | LA |
| W_w ~ L_k + L_t + N_k | 0,1302493 | 0,5144200 | LA |
| W_w ~ L_ktot + L_k + L_t + N_k | 0,8204809 | 0,5327256 | LA |
| W_w ~ L_k | 9,2136760 | 0,3111804 | LA |
| W_w ~ L_t | 9,2136760 | 0,3111804 | LA |
| W_w ~ L_k + L_t | 9,7121375 | 0,2856686 | LA |

Tablica P8 Linearni modeli s odgovarajućim AICc i $R^2$ vrijednostima za vrstu *Gongolaria barbata* na lokacijama Šćuza 1, Šćuza 2, Lanterna, Funtana, Bijela uvala i Kamenjak. Varijable: ukupna duljina kauloida (L_ktot), duljina kauloida (L_k), duljina talusa (L_t), broj kauloida (N_k) i mokra biomasa (W_w). Sve varijable su log-transformirane. Najbolje rangirani modeli su na vrhu svake liste. Lokacija je pri izradi modela korištena kao dodatni faktor.

| **Model** | **AICc** | **$R^2$** |
|---|---|---|
| W_w ~ L_ktot * Lokacija + N_k * Lokacija + L_t * Lokacija | -172,743570 | 0,8982677 |
| W_w ~ L_ktot * Lokacija + L_k * Lokacija + L_t * Lokacija | -154,397833 | 0,8880526 |
| W_w ~ L_ktot * Lokacija + L_t * Lokacija | -152,682652 | 0,8832504 |
| W_w ~ L_ktot * Lokacija + N_k * Lokacija | -147,770623 | 0,8804468 |
| W_w ~ L_ktot * Lokacija + L_k * Lokacija + N_k * Lokacija | -145,106280 | 0,8837366 |
| W_w ~ L_ktot * Lokacija + L_k* Lokacija + N_k * Lokacija + L_t * Lokacija | -138,736404 | 0,8727131 |
| W_w ~ L_ktot * Lokacija + L_k * Lokacija | -132,175046 | 0,8710916 |
| W_w ~ L_ktot * Lokacija | -132,165671 | 0,8661944 |
| W_w ~ L_k * Lokacija + N_k * Lokacija + L_t * Lokacija | -117,609555 | 0,8662797 |
| W_w ~ L_ktot+L_k+N_k+L_t + Lokacija | -112,814025 | 0,8513544 |
| W_w ~ L_ktot + L_k + L_t + Lokacija | -107,842907 | 0,8468686 |
| W_w ~ L_ktot + N_k + L_t + Lokacija | -107,021896 | 0,8462600 |
| W_w ~ L_ktot + N_k + Lokacija | -87,958482 | 0,8304770 |
| W_w ~ L_ktot + L_t + Lokacija | -87,709114 | 0,8302726 |

| Model | AICc | $R^2$ |
|---|---|---|
| W_w ~ L_k * Lokacija + N_k * Lokacija | -87,694433 | 0,8401902 |
| W_w ~ L_ktot + L_k + N_k + Lokacija | -85,966687 | 0,8297993 |
| W_w ~ N_k * Lokacija + L_t * Lokacija | -83,090113 | 0,8369952 |
| W_w ~ L_ktot + L_k + Lokacija | -81,637450 | 0,8252205 |
| W_w ~ L_ktot + Lokacija | -78,688741 | 0,8217263 |
| W_w ~ L_k + N_k + L_t + Lokacija | -76,806400 | 0,8220983 |
| W_w ~ L_k + N_k + Lokacija | -51,844958 | 0,7981650 |
| W_w ~ L_ktot + N_k + L_t | -44,061133 | 0,7858297 |
| W_w ~ L_ktot+L_k+N_k+L_t | -43,018487 | 0,7858883 |
| W_w ~ N_k + L_t + Lokacija | -37,988931 | 0,7870399 |
| W_w ~ L_k + N_k + L_t | -37,410989 | 0,7788375 |
| W_w ~ L_ktot + L_k + L_t | -27,236435 | 0,7676952 |
| W_w ~ L_ktot + N_k | -17,654125 | 0,7554121 |
| W_w ~ L_ktot + L_k + N_k | -15,987748 | 0,7547221 |
| W_w ~ L_k + N_k | -10,456372 | 0,7467577 |
| W_w ~ L_ktot + L_t | -8,663637 | 0,7445550 |
| W_w ~ N_k + L_t | -6,739492 | 0,7472772 |
| W_w ~ L_ktot + L_k | 2,323159 | 0,7306307 |
| W_w ~ L_ktot | 7,879278 | 0,7218719 |
| W_w ~ N_k * Lokacija | 13,286239 | 0,7355748 |

| Model | AICc | $R^2$ |
|---|---|---|
| W_w ~ N_k + Lokacija | 24,474489 | 0,7137264 |
| W_w ~ N_k | 44,226824 | 0,6780813 |
| W_w ~ L_k * Lokacija + L_t * Lokacija | 86,134702 | 0,6275210 |
| W_w ~ L_k + L_t + Lokacija | 90,671991 | 0,5982066 |
| W_w ~ L_k + L_t | 105,123512 | 0,5573836 |
| W_w ~ L_k * Lokacija | 109,342215 | 0,5702975 |
| W_w ~ L_k + Lokacija | 110,470586 | 0,5554185 |
| W_w ~ L_t * Lokacija | 111,091734 | 0,5832579 |
| W_w ~ L_t + Lokacija | 136,898861 | 0,5170795 |
| W_w ~ L_t | 140,750051 | 0,4956632 |
| W_w ~ L_k | 151,040046 | 0,4446048 |

Tablica P9. Linearni modeli s odgovarajućim AICc i $R^2$ vrijednostima za vrstu *Gongolaria barbata* prikupljenu u plitkom infralitoralu zapadne obale 2009. godine. Varijable: biomasa grana (Grane), duljina kauloida (L_k), duljina talusa (L_t), broj kauloida (N_k), broj jedinki (N_axes) i mokra biomasa (Tot_WW). Sve varijable su log-transformirane. Najbolje rangirani modeli su na vrhu liste. Ovi modeli si izrađeni na razini kvadrata.

| Model | AICc | $R^2$ |
|---|---|---|
| Tot_WW ~ L_ktot + Grane + N_k | -164,026064 | 0,9985057 |
| Tot_WW ~ L_ktot + Grane + N_k + N_axes | -163,654705 | 0,9985487 |
| Tot_WW ~ L_ktot + Grane + L_t + N_k | -163,599676 | 0,9985467 |
| Tot_WW ~ L_ktot + Grane + L_t + N_k + N_axes | -161,366338 | 0,9985245 |
| Tot_WW ~ L_ktot + Grane + L_t | -160,254525 | 0,9983540 |

| Model | AICc | $R^2$ |
|---|---|---|
| Tot_WW ~ L_ktot + Grane + N_axes | -160,179964 | 0,9983508 |
| Tot_WW ~ L_ktot + Grane | -159,134271 | 0,9982445 |
| Tot_WW ~ L_ktot + Grane + L_t + N_axes | -158,418136 | 0,9983402 |
| Tot_WW ~ Grane + N_k | -133,955651 | 0,9966519 |
| Tot_WW ~ Grane + N_k + N_axes | -132,455430 | 0,9966426 |
| Tot_WW ~ Grane + L_t + N_k | -132,227855 | 0,9966230 |
| Tot_WW ~ Grane + L_t + N_k + N_axes | -129,923349 | 0,9965536 |
| Tot_WW ~ Grane | -122,295083 | 0,9954568 |
| Tot_WW ~ Grane + L_t | -120,517618 | 0,9952746 |
| Tot_WW ~ Grane + N_axes | -120,157871 | 0,9952308 |
| Tot_WW ~ Grane + L_t + N_axes | -118,030943 | 0,9951401 |
| Tot_WW ~ L_ktot + L_t + N_k | -19,180221 | 0,9387079 |
| Tot_WW ~ L_ktot + N_k | -18,556439 | 0,9354565 |
| Tot_WW ~ L_ktot + L_t + N_k + N_axes | -17,614123 | 0,9386216 |
| Tot_WW ~ L_ktot + N_k + N_axes | -16,141825 | 0,9337418 |
| Tot_WW ~ L_ktot | -11,152516 | 0,9214736 |
| Tot_WW ~ L_ktot + L_t | -10,470976 | 0,9205872 |
| Tot_WW ~ L_ktot + L_t + N_axes | -9,992310 | 0,9224255 |
| Tot_WW ~ L_ktot + N_axes | -8,887383 | 0,9172963 |
| Tot_WW ~ L_t + N_k + N_axes | 21,257822 | 0,8271328 |
| Tot_WW ~ L_t + N_k | 21,377184 | 0,8203017 |

| Model | AICc | $R^2$ |
|---|---|---|
| Tot_WW ~ N_k | 29,580638 | 0,7768433 |
| Tot_WW ~ N_k + N_axes | 31,437974 | 0,7674168 |
| Tot_WW ~ L_t | 32,098525 | 0,7619607 |
| Tot_WW ~ L_t + N_axes | 32,627790 | 0,7602117 |
| Tot_WW ~ N_axes | 66,015367 | 0,4320132 |

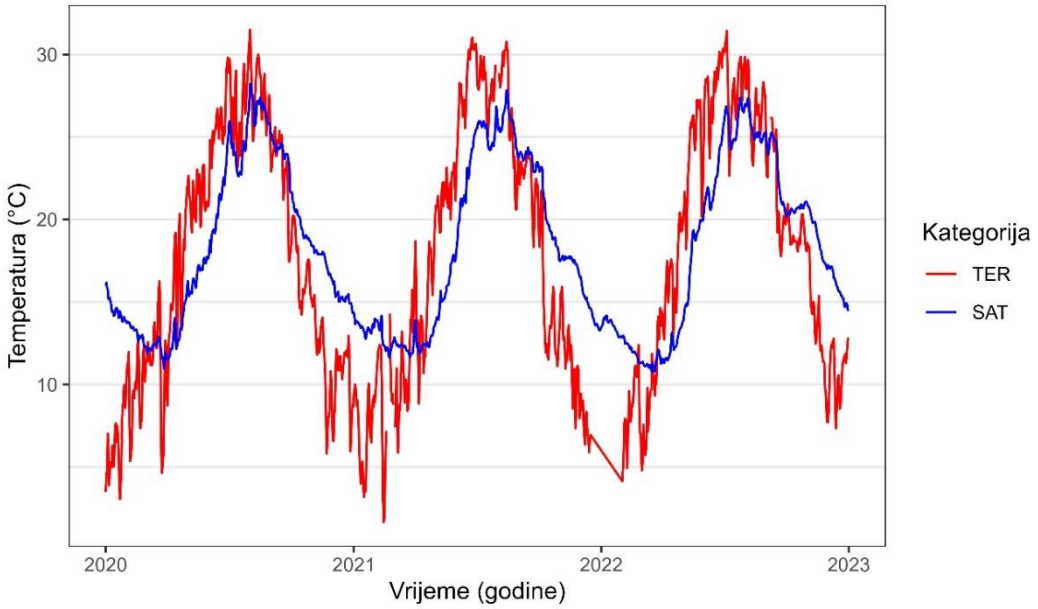


Slika P5. *In situ* dnevne srednje temperature mora u laguni Šćuza (crvena linija) i satelitske (plava linija) dnevne srednje temperature izvan lagune (plava linija), u razdoblju od 2020. do kraja 2022. godine.

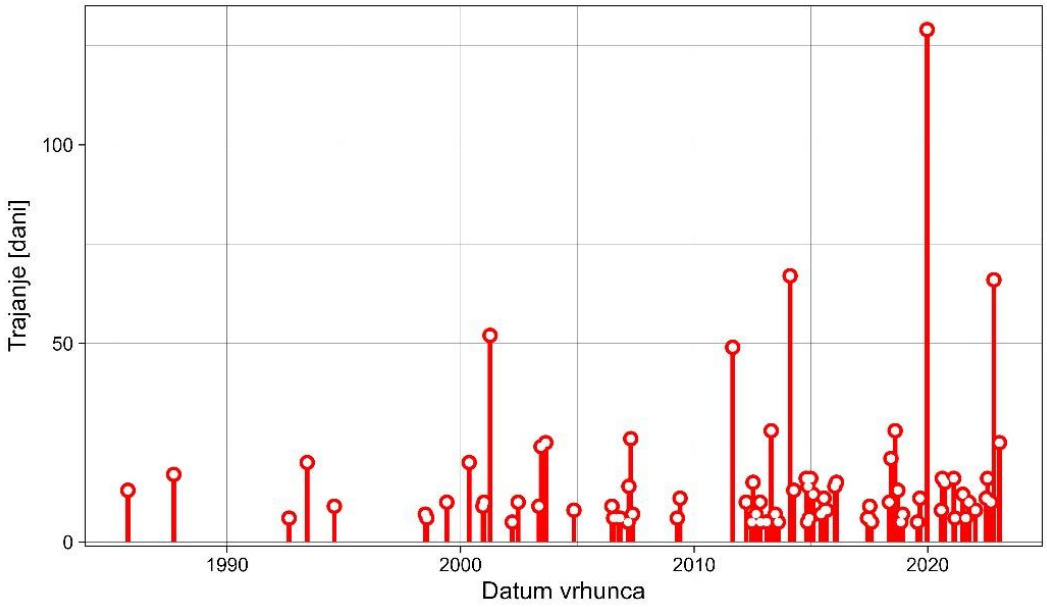


Slika P6. Trajanje i učestalost morskih toplinskih valova (MTV) u razdoblju od 1983. do 2023. godine (Podaci o temperaturi površinskog sloja (SST) dobiveni satelitom (OISST v.2) s ERDDAP poslužitelja) na južnoj istarskoj obali.

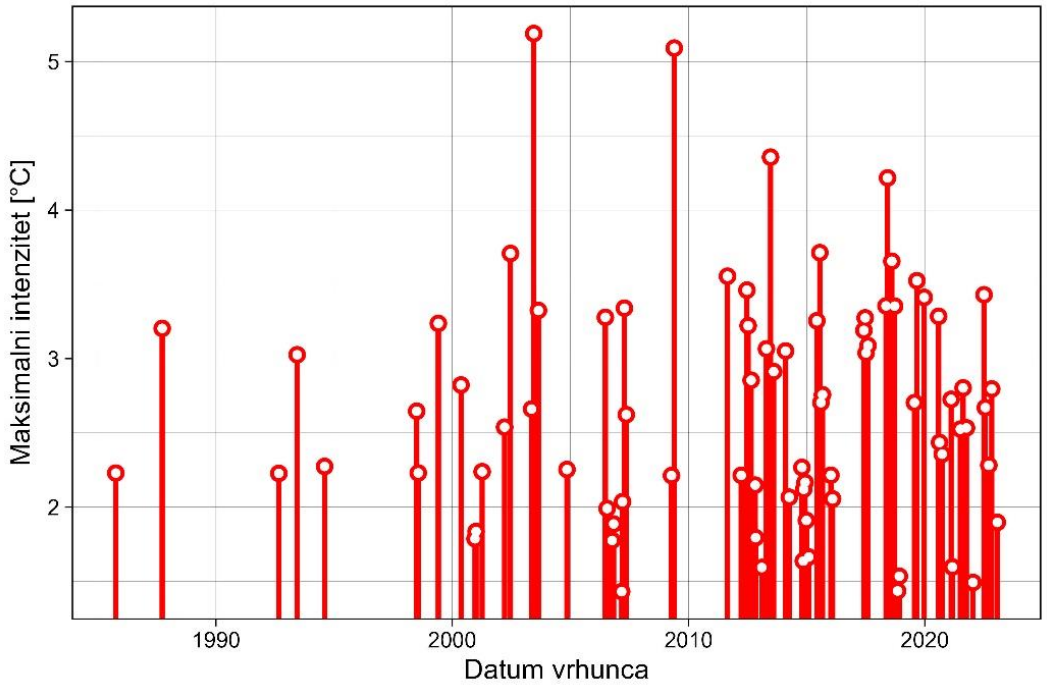


Slika P7. Intenzitet i učestalost morskih toplinskih valova (MTV) u razdoblju od 1983. do 2023. godine (Podaci o temperaturi površinskog sloja (SST) dobiveni satelitom (OISST v.2) s ERDDAP poslužitelja) na južnoj istarskoj obali.

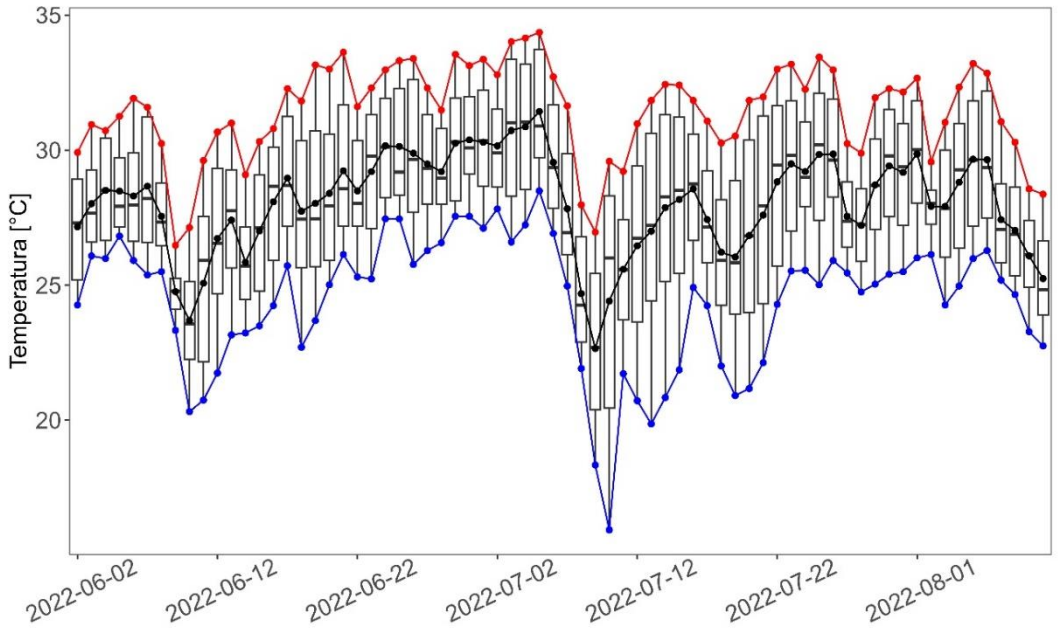


Slika P8. Dnevne varijacije temperature mora u razdoblju kada u laguni prevladavaju najviše temperature (2. lipnja 2022. – 10. kolovoza 2022.). Maksimalne temperature su prikazane crvenom bojom, minimalne plavom, dok su srednje dnevne temperature prikazane crnom bojom.

Tablica P10. Trajanje (dani) razdoblja kada je temperatura mora bila iznad praga od 28 °C u Šćuzi za godine 2020., 2021. i 2022.

| Trajanje | Početak | Vrhunac | Kraj | Temperatura | Godina |
|---|---|---|---|---|---|
| 9 | 2020-06-25 | 2020-06-28 | 2020-07-03 | 28 | 2020 |
| 42 | 2020-07-20 | 2020-07-31 | 2020-08-30 | 28 | 2020 |
| 45 | 2021-06-01 | 2021-07-01 | 2021-07-15 | 28 | 2021 |
| 31 | 2021-07-19 | 2021-07-30 | 2021-08-18 | 28 | 2021 |
| 19 | 2022-05-09 | 2022-05-22 | 2022-05-27 | 28 | 2022 |
| 70 | 2022-06-02 | 2022-07-05 | 2022-08-10 | 28 | 2022 |
| 18 | 2022-08-14 | 2022-08-28 | 2022-08-31 | 28 | 2022 |
| 5 | 2022-09-06 | 2022-09-07 | 2022-09-10 | 28 | 2022 |

Tablica P11. Trajanje (dani) razdoblja kada je temperatura mora bila iznad praga od 30 °C u Šćuzi za godine 2020., 2021. i 2022.

| Trajanje | Početak | Vrhunac | Kraj | Temperatura | Godina |
|---|---|---|---|---|---|
| 8 | 2020-06-26 | 2020-06-28 | 2020-07-03 | 30 | 2020 |
| 8 | 2020-07-27 | 2020-07-31 | 2020-08-03 | 30 | 2020 |
| 11 | 2020-08-07 | 2020-08-13 | 2020-08-17 | 30 | 2020 |
| 9 | 2021-06-02 | 2021-06-05 | 2021-06-10 | 30 | 2021 |
| 27 | 2021-06-16 | 2021-07-01 | 2021-07-12 | 30 | 2021 |
| 20 | 2021-07-28 | 2021-07-30 | 2021-08-16 | 30 | 2021 |
| 6 | 2022-05-20 | 2022-05-22 | 2022-05-25 | 30 | 2022 |
| 6 | 2022-06-03 | 2022-06-06 | 2022-06-08 | 30 | 2022 |
| 23 | 2022-06-15 | 2022-07-05 | 2022-07-07 | 30 | 2022 |
| 16 | 2022-07-12 | 2022-07-25 | 2022-07-27 | 30 | 2022 |
| 6 | 2022-08-03 | 2022-08-05 | 2022-08-08 | 30 | 2022 |

Tablica P12. Trajanje (dani) razdoblja kada je temperatura mora bila iznad praga od 32 °C u Šćuzi za godine 2020., 2021. i 2022.

| Trajanje | Početak | Vrhunac | Kraj | Temperatura | Godina |
|---|---|---|---|---|---|
| 6 | 2020-06-27 | 2020-06-28 | 2020-07-02 | 32 | 2020 |
| 17 | 2021-06-17 | 2021-07-01 | 2021-07-03 | 32 | 2021 |
| 18 | 2021-07-30 | 2021-07-30 | 2021-08-16 | 32 | 2021 |
| 14 | 2022-06-23 | 2022-07-05 | 2022-07-06 | 32 | 2022 |
| 5 | 2022-07-22 | 2022-07-25 | 2022-07-26 | 32 | 2022 |

Tablica P13. Trajanje (dani) razdoblja kada je temperatura mora bila iznad praga od 34 °C u Šćuzi za godine 2020., 2021. i 2022.

| Trajanje | Početak | Vrhunac | Kraj | Temperatura | Godina |
|---|---|---|---|---|---|
| 2 | 2020-07-31 | 2020-07-31 | 2020-08-01 | 34 | 2020 |
| 1 | 2021-02-21 | 2021-02-21 | 2021-02-21 | 34 | 2021 |
| 1 | 2021-06-25 | 2021-06-25 | 2021-06-25 | 34 | 2021 |
| 1 | 2021-07-01 | 2021-07-01 | 2021-07-01 | 34 | 2021 |

| | | | | | |
|---|---|---|---|---|---|
| 1 | 2021-07-30 | 2021-07-30 | 2021-07-30 | 34 | 2021 |
| 2 | 2021-08-14 | 2021-08-15 | 2021-08-15 | 34 | 2021 |
| 3 | 2022-07-03 | 2022-07-05 | 2022-07-05 | 34 | 2022 |

Tablica P14. Analiza odstupanja (Wald χ2 test) za svaki prilagođeni model korišten za ispitivanje utjecaja temperature na morfološke i fiziološke karakteristike vrste *Gongolaria barbata* te sažeti statistički podaci iz Tukey testa za parne usporedbe između različitih razina fiksnog faktora. „*“označava razinu značajnosti od 0,05, „**“ označava razinu značajnosti od 0,01, a „***“ označava razinu značajnosti od 0,001.

| **Utjecaj fiksnog čimbenika/temperatura** | | | | | **Tukey post-hoc test** | | |
|---|---|---|---|---|---|---|---|
| Test | Varijabla | χ2 | Df | p | Usporedba | z-vrijednost | p |
| LMM | Biomasa | 11,275 | 4 | 0,023 * | 28C - 18C | -1,342 | 0,665 |
| | | | | | 30C - 18C | -2,503 | 0,090 |
| | | | | | 32C - 18C | -1,972 | 0,280 |
| | | | | | 34C - 18C | -3,090 | 0,017 * |
| | | | | | 30C - 28C | -1,161 | 0,773 |
| | | | | | 32C - 28C | -0,630 | 0,970 |
| | | | | | 34C - 28C | -1,749 | 0,404 |
| | | | | | 32C - 30C | 0,531 | 0,984 |
| | | | | | 34C - 30C | -0,587 | 0,977 |
| | | | | | 34C - 32C | -1,118 | 0,797 |
| GLMM | Veličina | 13,993 | 4 | 0,003 ** | 28C - 18C | -0,860 | 0,911 |
| | | | | | 30C - 18C | -1,112 | 0,801 |
| | | | | | 32C - 18C | -1,068 | 0,823 |
| | | | | | 34C - 18C | -3,783 | 0,001 ** |
| | | | | | 30C - 28C | -0,252 | 0,999 |
| | | | | | 32C - 28C | -0,208 | 1,000 |
| | | | | | 34C - 28C | -2,924 | 0,028 * |
| | | | | | 32C - 30C | 0,044 | 1,000 |
| | | | | | 34C - 30C | -2,673 | 0,058 |
| | | | | | 34C - 32C | -2,717 | 0,052 |
| | | | | | 28C - 18C | 0,883 | 0,903 |

| | | | | | | | |
|---|---|---|---|---|---|---|---|
| | | | | | 30C - 18C | 0,777 | 0,937 |
| | | | | | 32C - 18C | -2,629 | 0,065 |
| | | | | | 34C - 18C | -7,040 | < 0,001 *** |
| | | | | | 30C - 28C | -0,107 | 1,000 |
| GLMM | *Fv/Fm* | 89,595 | 4 | < 2,2e-16 *** | 32C - 28C | -3,512 | 0,004 ** |
| | | | | | 34C - 28C | -7,919 | < 0,001 *** |
| | | | | | 32C - 30C | -3,406 | 0,006 ** |
| | | | | | 34C - 30C | -7,813 | < 0,001 *** |
| | | | | | 34C - 32C | -4,418 | < 0,001 *** |
| | | | | | 28C - 18C | 1,276 | 0,706 |
| | | | | | 30C - 18C | -0,635 | 0,969 |
| | | | | | 32C - 18C | -2,894 | 0,031 * |
| | | | | | 34C - 18C | -8,602 | <0,001 *** |
| | | | | | 30C - 28C | -1,911 | 0,311 |
| GLMM | *Y(II)* | 117,12 | 4 | < 2,2e-16 *** | 32C - 28C | -4,165 | <0,001 *** |
| | | | | | 34C - 28C | -9,825 | <0,001 *** |
| | | | | | 32C - 30C | -2,262 | 0,157 |
| | | | | | 34C - 30C | -7,994 | <0,001 *** |
| | | | | | 34C - 32C | -5,803 | <0,001 *** |

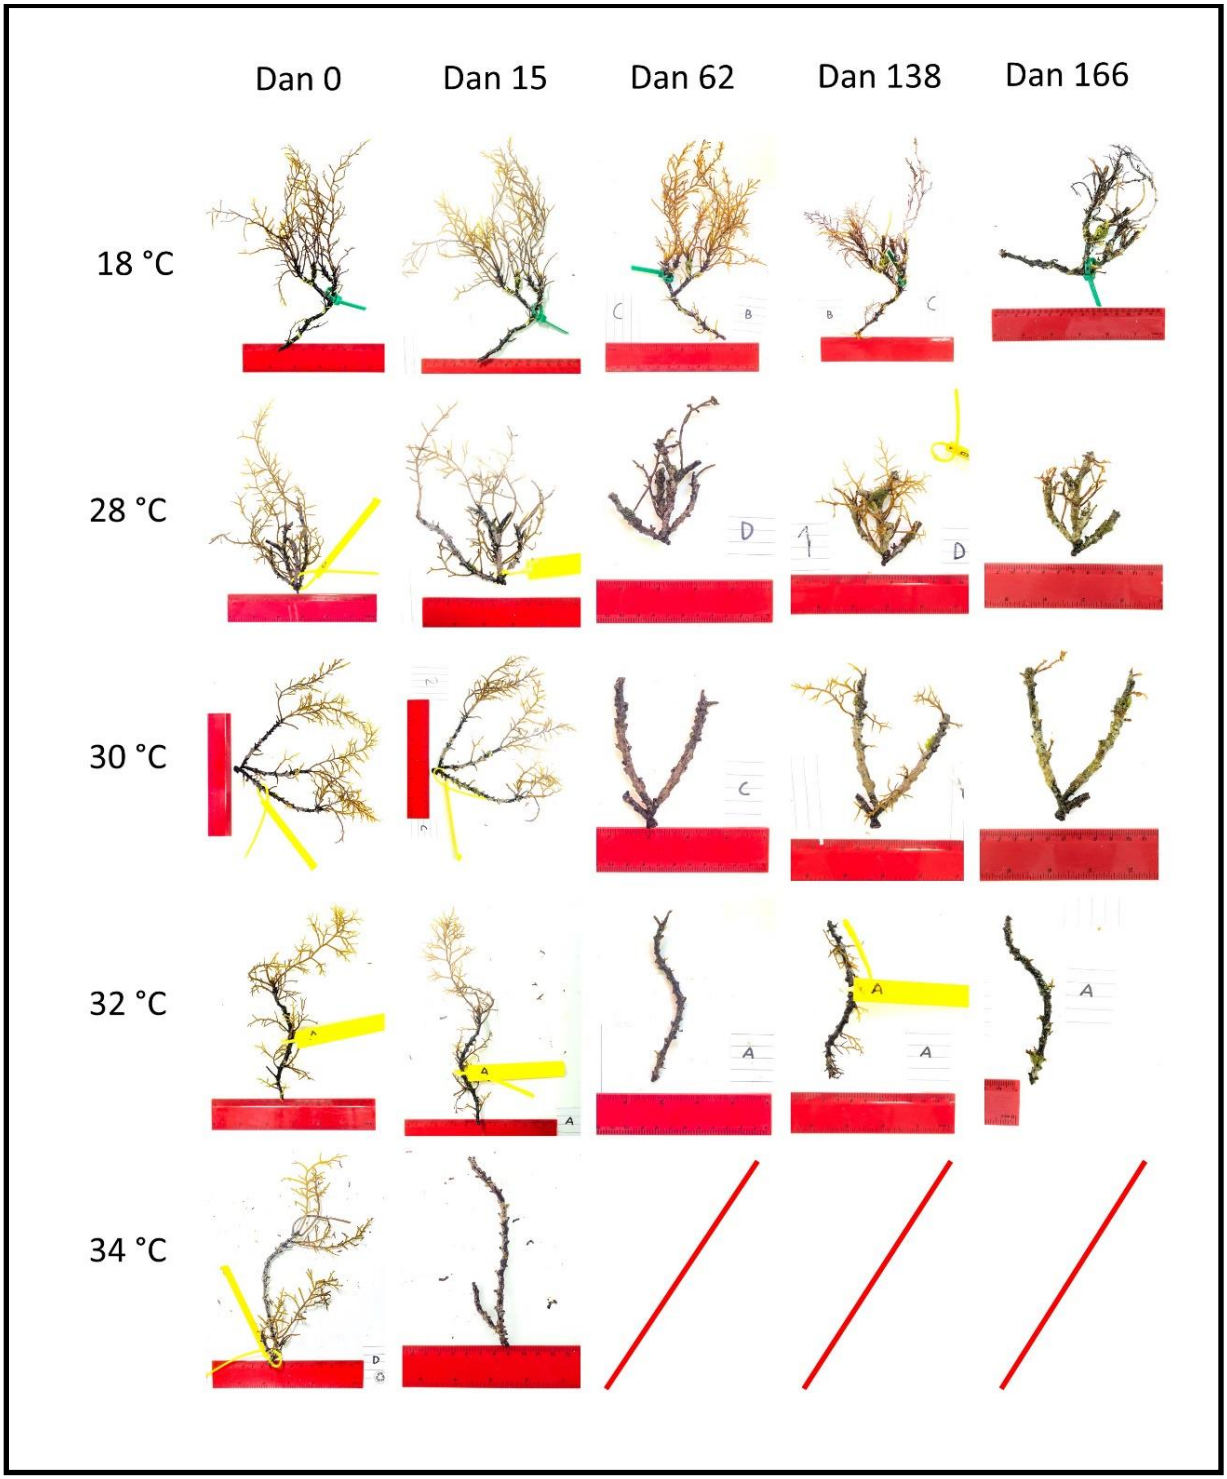


Slika P9. Fotografije odabranih jedinki iz eksperimenta termotolerancije 2022. godine, izloženih različitim temperaturnim tretmanima (28, 30, 32 i 34 °C) i promjene u izgledu talusa tijekom različitih mjernih intervala.

Tablica P15. Analiza odstupanja (Wald χ2 test) koja pokazuje značajnost utjecaja svjetlosti, vremena ili njihove interakcije na veličinu juvenilnih jedinki u ranoj *ex situ* fazi rasta.

| Faktori | Chisq | Df | Pr(>Chisq) | Značajnost |
|---|---|---|---|---|
| Svjetlost | 1,77594432 | 1 | 0,1826 | |
| Vrijeme | 34017,0547 | 6 | <2e-16 | *** |
| Svjetlost*Vrijeme | 277,439784 | 6 | <2e-16 | *** |

Tablica P16. Rezultati post-hoc Tukey testa za ranu fazu *ex situ* rasta. Uspoređuju se pojedine razine svjetlosti u vremenima od T1 do T7.

| Usporedba | procjena | SE | Df | t.omjer | p | Značajnost |
|---|---|---|---|---|---|---|
| VI T1 - NI T1 | -0,0223 | 0,0492 | 6,374 | -0,4545 | 0,6645 | |
| VI T2 - NI T2 | -0,0035 | 0,0494 | 6,5085 | -0,071 | 0,9455 | |
| VI T3 - NI T3 | 0,0945 | 0,0498 | 6,7077 | 1,8988 | 0,1012 | |
| VI T4 - NI T4 | 0,1755 | 0,0497 | 6,6379 | 3,5344 | 0,0104 | * |
| VI T5 - NI T5 | 0,1597 | 0,0501 | 6,8774 | 3,1879 | 0,0157 | * |
| VI T6 - NI T6 | 0,0248 | 0,051 | 7,3764 | 0,4857 | 0,6413 | |
| VI T7 - NI T7 | 0,1427 | 0,0532 | 8,7334 | 2,6828 | 0,0257 | * |

Tablica P17. Analiza odstupanja (Wald χ2 test) koja pokazuje značajnost utjecaja svjetlosti, vremena ili njihove interakcije na preživljavanje juvenilnih jedinki u ranoj *ex situ* fazi rasta.

| Faktori | Chisq | Df | Pr(>Chisq) | Značajnost |
|---|---|---|---|---|
| Svjetlost | 19,3096908 | 1 | < 0,001 | *** |
| Vrijeme | 728,081825 | 5 | < 0,001 | *** |
| Svjetlost*Vrijeme | 129,066532 | 5 | < 0,001 | *** |

Tablica P18. Rezultati post-hoc Tukey testa za *ex situ* preživljavanje. Uspoređuju se pojedine razine svjetlosti u vremenima od T2 do T7. Vrijeme T1 je isključeno zbog toga što je preživljavanje u početnoj točki 100%.

| Usporedba | procjena | SE | z.omjer | p | Značajnost |
|---|---|---|---|---|---|
| VI T2 - NI T2 | -0,0008 | 0,3664 | -0,0022 | 0,9982 | |
| VI T3 - NI T3 | -0,3826 | 0,3477 | -1,1005 | 0,2711 | |
| VI T4 - NI T4 | -0,4441 | 0,3384 | -1,3125 | 0,1893 | |

| | | | | | |
|---|---|---|---|---|---|
| VI T5 - NI T5 | -1,1235 | 0,3166 | -3,549 | 0,0004 | *** |
| VI T6 - NI T6 | -2,1314 | 0,3191 | -6,6798 | 2E-11 | *** |
| VI T7 - NI T7 | -2,5736 | 0,3415 | -7,5357 | 5E-14 | *** |

Tablica P19. Analiza odstupanja (Wald $\chi 2$ test) koja pokazuje značajnost utjecaja svjetlosti, vremena ili njihove interakcije na visinu juvenilnih jedinki u *in situ* fazi rasta.

| Faktori | Chisq | Df | Pr(>Chisq) | Značajnost |
|---|---|---|---|---|
| Svjetlost | 7.52026793 | 1 | 0.006101 | ** |
| Vrijeme | 3066.71646 | 10 | < 2.2e-16 | *** |
| Svjetlost*Vrijeme | 189.019314 | 10 | < 2.2e-16 | *** |

Tablica P20. Rezultati post-hoc Tukey testa za visinu jedinki *in situ*. Uspoređuju se pojedine razine svjetlosti u vremenima od T1 do T11.

| Usporedba | procjena | SE | Df | t.omjer | p | Značajnost |
|---|---|---|---|---|---|---|
| VI T1 - NI T1 | -0,0185 | 0,1004 | 8,3309 | -0,1843 | 0,8582 | |
| VI T2 - NI T2 | -0,1526 | 0,0993 | 7,9911 | -1,5359 | 0,1632 | |
| VI T3 - NI T3 | -0,102 | 0,1008 | 8,4566 | -1,0121 | 0,3396 | |
| VI T4 - NI T4 | -0,2257 | 0,1008 | 8,4619 | -2,2394 | 0,0537 | |
| VI T5 - NI T5 | -0,1882 | 0,0991 | 7,9213 | -1,8988 | 0,0945 | |
| VI T6 - NI T6 | -0,2781 | 0,1011 | 8,5697 | -2,751 | 0,0235 | * |
| VI T7 - NI T7 | -0,5088 | 0,1046 | 9,8314 | -4,863 | 0,0007 | *** |
| VI T8 - NI T8 | -0,6999 | 0,1025 | 9,0616 | -6,8269 | 7E-05 | *** |
| VI T9 - NI T9 | -0,4574 | 0,1073 | 10,879 | -4,2624 | 0,0014 | ** |
| VI T10 - NI T10 | -0,2376 | 0,1027 | 9,1375 | -2,3121 | 0,0457 | * |
| VI T11 - NI T11 | -0,1806 | 0,1076 | 11 | -1,6779 | 0,1215 | |

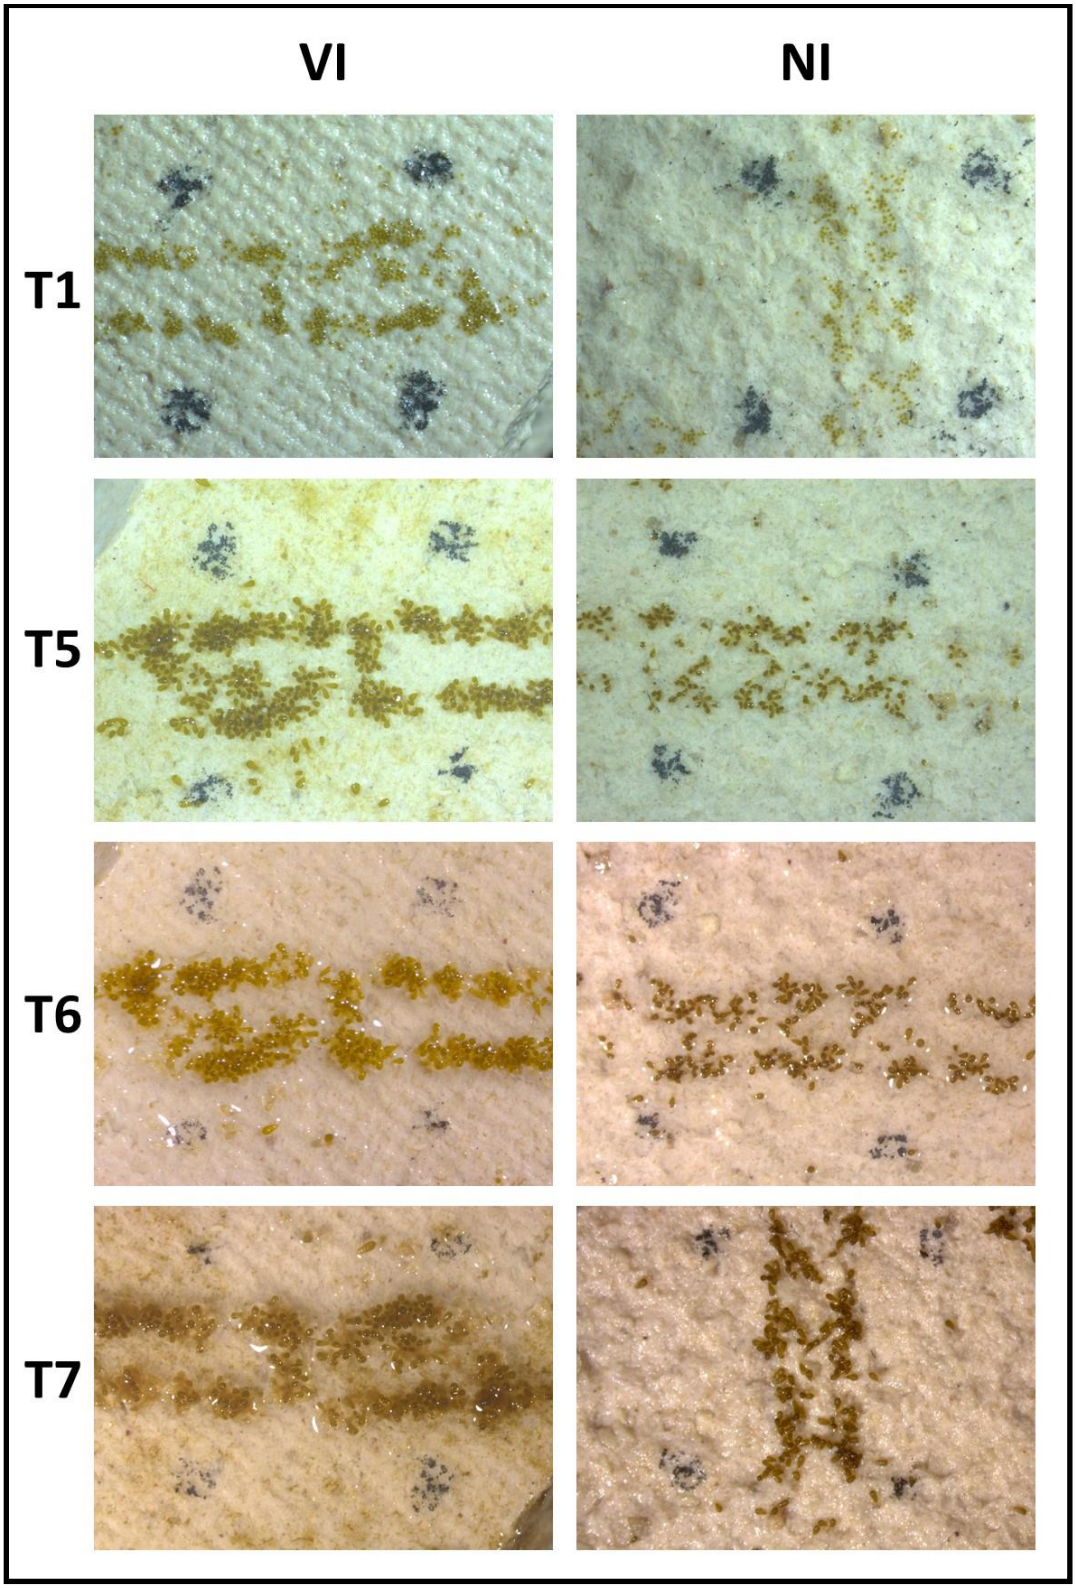


Slika P10. Izgled uzgojenih juvenilnih jedinki vrste *Gonolaria barbata* u *ex situ* uvjetima na odabranim glinenim pločicama za visoki i niski svjetlosni intenzitet i za četiri vremena mjerenja.

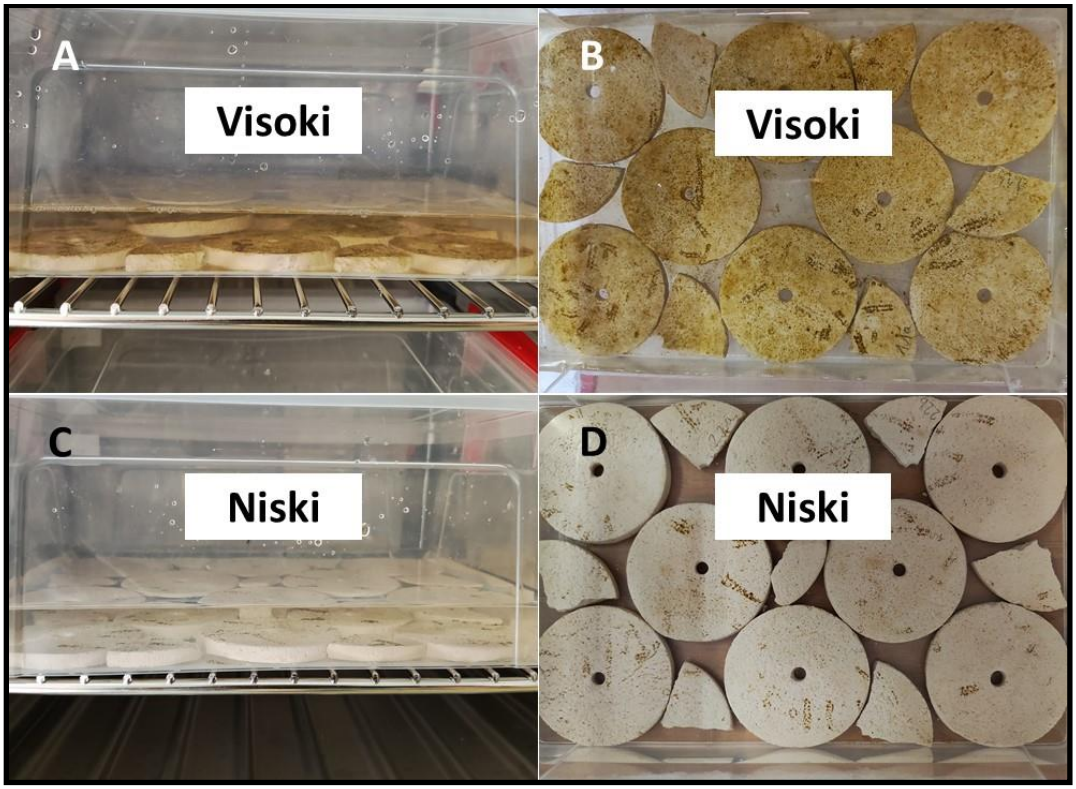


Slika P11. Kontaminacija na glinenim pločicama na kojima se nalaze juvenilne jedinke u *ex situ* eksperimentu. Razlika između tretmana na visokom i na niskom svjetlosnom intenzitetu.

Slika P12. Obraštaj (nitaste alge) na glinenim pločicama na kojima se nalaze juvenilne jedinke koje su privremeno pohranjene u otvoreni sustav optoka prije *in situ* „presađivanja“.

Slika P13. Temperatura vode prilikom privremenog pohranjivanja juvenilnih algi u protočni sustav bez filtracije.

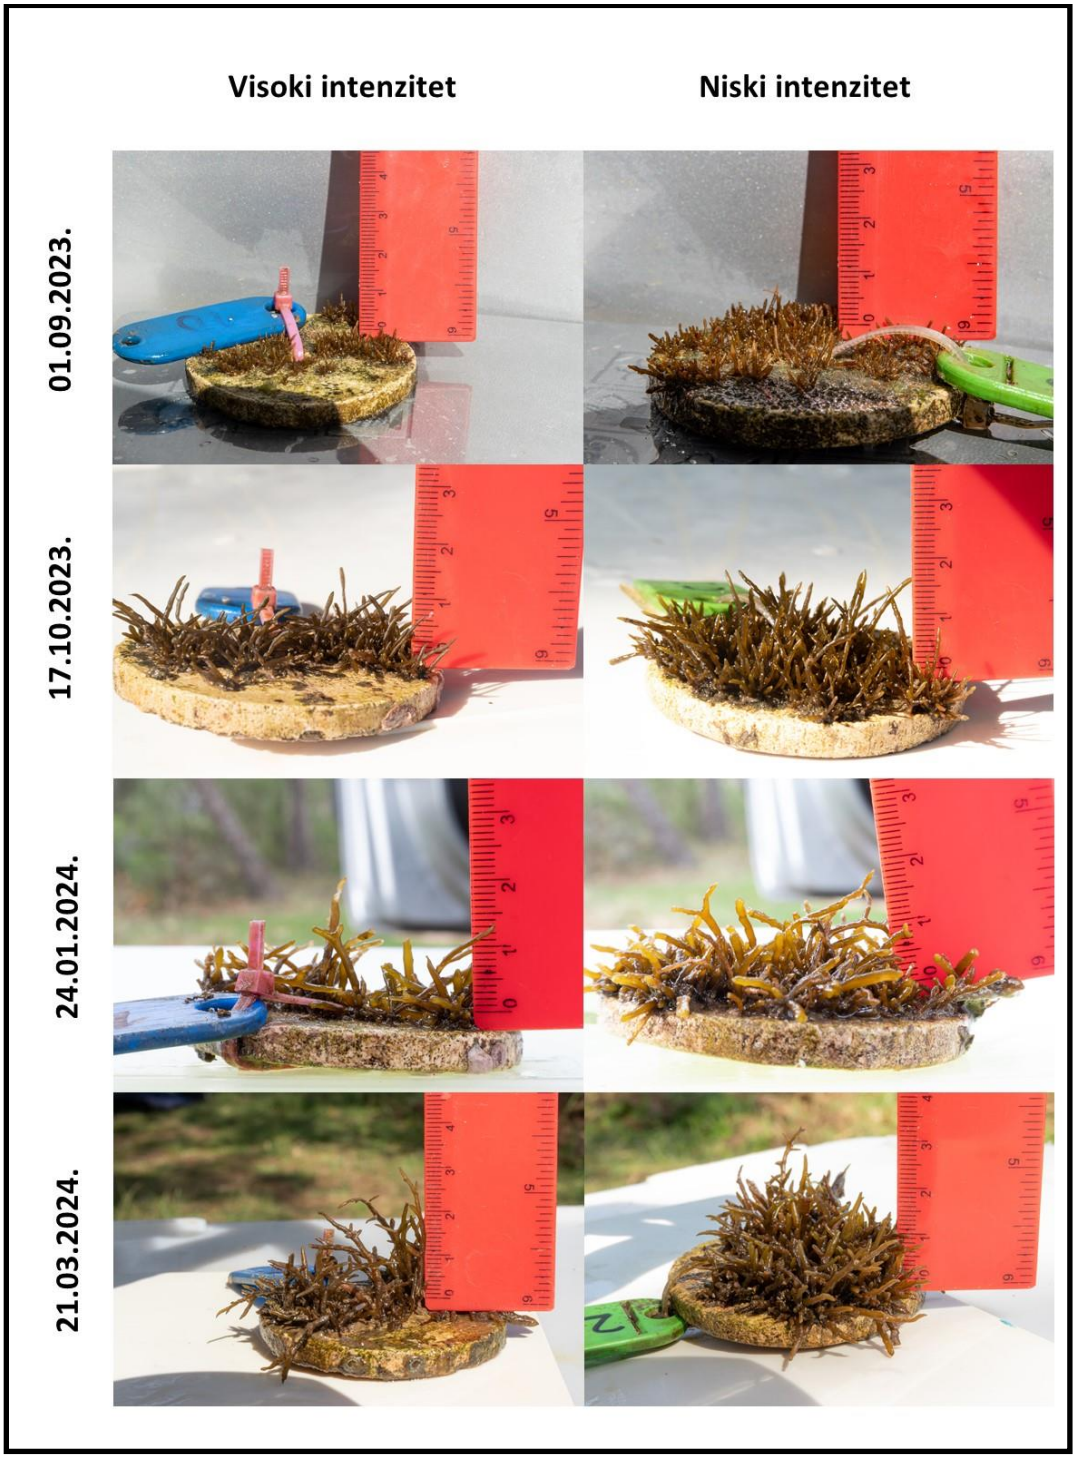


Slika P14. Izgled uzgojenih juvenilnih jedinki vrste *Gonolaria barbata* u laguni Šćuza u kavezu 1 – visoki intenzitet i kavezu 2 – niski intenzitet, u različitim vremenskim razdobljima.

# 10. POPIS KRATICA

CAP – kanonička analiza glavnih koordinata

L_ktot – ukupna duljina kauloida

L_k – duljina kauloida

L_t – duljina talusa

N_k – broj kauloida

W_w – mokra biomasa

Tot_WW – mokra biomasa na razini kvadrata

Grane – biomasa grana na razini kvadrata

N_axes – broj jedinki

Fi_k – promjer kauloida

Fi_bas – promjer bazalne pločice

$R^2$ – koeficijent determinacije

AICc – ispravljeni Akaike informacijski kriterij

MTV – morski toplinski valovi

LMM – linearni mješoviti modeli

GLMM – generalizirani linearni mješoviti modeli

PAM – „Pulse-Amplitude Modulation fluorometry“

*YII* – efektivni kvantni prinos

*Fv/Fm* – maksimalni kvantni prinos

SST – temperatura površine mora

PCA – analiza glavnih komponenata

$NH_4^+$ – amonijev ion

$NO_2^-$ – nitriti

$NO_3^-$ – nitrati

$PO_4^{3-}$ – fosfati

TIN – ukupni anorganski dušik

$SiO_4^{4-}$ – silikati

Chl *a* – klorofil a

UV – ultraljubičasto zračenje

# 11. ŽIVOTOPIS

Andrea Bilajac rođen je 28. siječnja 1995. u Puli. Osnovnu školu i prirodoslovno-matematičku gimnaziju završio je u Rovinju. Godine 2017. završio je preddiplomski studij Znanosti o moru na Sveučilištu Jurja Dobrile u Puli, dok je godine 2020. diplomirao na studiju Ekologije i zaštite prirode pri Biološkom odsjeku Prirodoslovno-matematičkog fakulteta na Sveučilištu u Zagrebu. Iste godine se zapošljava u Centru za istraživanje mora, Instituta Ruđer Bošković kao asistent u Laboratoriju za ekologiju bentosa, na projektu hrvatske zaklade za znanost „Odgovori smeđih algi roda *Cystoseira*, koje formiraju staništa, na lokalne i globalne stresore (HabCYS)“. Iste godine upisuje poslijediplomski interdisciplinarni doktorski studij Oceanologije na Geološkom odsjeku, Prirodoslovno-matematičkog fakulteta, Sveučilišta u Zagrebu, te izrađuje doktorski rad pod vodstvom mentorice dr. sc. Ljiljane Iveša. Koautor je tri znanstvena rada, glavni autor jednog znanstvenog rada, te glavni autor ili koautor na brojnim priopćenjima domaćih i međunarodnih znanstvenih skupova.

**Popis znanstvenih publikacija**

**Bilajac, A.**, Gljušćić, E., Smith, S., Najdek, M., i Iveša, L. (2024). Effects of extreme temperatures and recovery potential of *Gongolaria barbata* from a coastal lagoon in the northern Adriatic Sea: an ex situ approach. *Annals of Botany*, *134*(3), 415-426.

Gljušćić, E., **Bilajac, A.**, Smith, S. M., Najdek, M., i Iveša, L. (2023). First Restoration Experiment for Endemic *Fucus virsoides* on the Western Istrian Coast—Is It Feasible?. *Plants*, *12*(7), 1445.

Iveša, L., **Bilajac, A.**, Gljušćić, E., i Najdek, M. (2022). *Gongolaria barbata* forest in the shallow lagoon on the southern Istrian Coast (northern Adriatic Sea). *Botanica marina*, *65*(4), 255-268.

Iveša, L., Đakovac, T., **Bilajac, A.**, Gljušćić, E., i Devescovi, M. (2021). Increased ammonium levels occurring during benthic algal blooms are potentially toxic to fucalean algae. *Botanica marina*, *64*(4), 267-274.

**Glavni autor ili koautor na priopćenjima međunarodnih i domaćih znanstvenih skupova**

**Bilajac, A.,** Gljušćić, E., Smith, S. i Iveša, L. "Site-specific predictive models for estimating wet biomass of macroalga *Gongolaria barbata* from two sites". u 8th European Phycological Congress, Knjiga sažetaka, Federation of European phycological societies, 2023, str. 276.

Gljušćić, E., **Bilajac, A.,** Smith, S. i Iveša, L. "Epiphyte community in two prominent fucalean algae on the western istrian coast". u 8th European Phycological Congress, Knjiga sažetaka, Federation of European phycological societies, 2023, str. 282.

Iveša, L., **Bilajac, A.,** Gljušćić, E. i Smith, S. "The last remaining populations of *Gongolaria barbata* along the istrian coast (northern adriatic)". u 8th European Phycological Congress, Knjiga sažetaka, Federation of European Phycological Societies, 2023, str. 74.

Smith, S., **Bilajac, A.,** Gljušćić, E. i Iveša, L. "Adaptation to temperature extremes could improve marine forest restoration success: a case study for a unique, isolated *Gongolaria barbata* population in the northern adriatic sea". u 8th European Phycological Congress, Knjiga sažetaka, Federation of European Phycological Societies, 2023, str. 293–294.

Iveša, L., **Bilajac, A.,** Gljušćić, E. i Smith, S. "Effects of extreme temperature on fucalean forests in a shallow lagoon in the northern adriatic". 13th International Temperate Reefs Symposium, 2023.

Smith, S., Fućak, A., Gljušćić, E., **Bilajac, A.** i Iveša, L. "Habitat complexity influences survival of the vulnerablecanopy forming macroalgal species *Gongolaria barbata* in the northern adriatic sea". 13th International Temperate Reefs Symposium, 2023.

**Bilajac, A.,** Gljušćić, E. i Iveša, L. "Distribution, morphometric characteristics and epiphyte composition of *Gongolaria barbata* in the šćuza lagoon". u 6th Faculty of Science PhD Student Symposium, Knjiga sažetaka, Faculty of Science, University of Zagreb, Croatia, 2022, str. 116–117.

**Bilajac, A.,** Gljušćić, E., Najdek, M., i Iveša, L. "*Gongolaria barbata* forest in the shallow coastal lagoon on the southern istrian coast (northern adriatic sea)". u 14th Croatian Biological Congress, Knjiga sažetaka, Croatian Biological Society, 2022, str. 192–193.

**Bilajac, A.,** Gljušćić, E., Smith, S. i Iveša, L. "Kartiranje i relativna brojnost vrsta iz reda fucales u zoni mediolitorala i infralitorala zapadne obale istra". 3rd Conference with the topic Climate change and preservation of marine ecosystems of the Adriatic sea, 2022.

Gljušćić, E., **Bilajac, A.** i Iveša, L. "First restoration experiment for endemic *Fucus virsoides* on western istrian coast". u 14th Croatian Biological Congress, Knjiga sažetaka, Croatian Biological Society, 2022, str. 242–243.

Gljušćić, E., **Bilajac, A.** i Iveša, L. "Rediscovery of *Digenea simplex* (wulfen) c. agardh 1822 (rhodomelaceae, ceramiales) in the northern adriatic". u 6th Faculty of Science PhD Student Symposium, Knjiga sažetaka, Faculty of Science, University of Zagreb, Croatia, 2022, str. 159.

Gljušćić, E., **Bilajac, A.,** Smith, S. i Iveša, L. "Jadranski fukus (*Fucus virsoides* j. agardh) na obali istre: Prošlost, sadašnjost i (možda) budućnost". 3rd Conference with the topic Climate change and preservation of marine ecosystems of the Adriatic sea, 2022.

Iveša, L., **Bilajac, A.** i Gljušćić, E. "Refugia for fucalean species in the intertidal zone along the istrian coast (northern adriatic sea)". u 14th Croatian Biological Congress - Book of abstracts, Croatian Biological Society, 2022, str. 41–42.

Iveša, L., **Bilajac, A.,** Gljušćić, E. i Smith, S. "Dugoročne promjene u naseljima smeđih makroalgi reda fucales duž zapadne obale istre (sjeverni jadran)". 3rd Conference with the topic Climate change and preservation of marine ecosystems of the Adriatic sea, 2022.

**Bilajac, A.** "Pregled smeđih algi cistozira u sjevernom jadranu". 130. godina istraživanja mora u Rovinju, 2021.

Jaklin, A. i **Bilajac, A.** "Plemenita periska: Ima li nade?". 130. godina istraživanja mora u Rovinju, 2021.

# 12. INFORMACIJE O MENTORU


| | |
|---|---|
| Ime i prezime: | dr. sc. Ljiljana Iveša |
| Radno mjesto: | Znanstveni savjetnik |
| Adresa: | Institut Ruđer Bošković<br>Centar za istraživanje mora<br>Laboratorij za ekologiju bentosa<br>G. Paliaga 5, 52210 Rovinj, Hrvatska |
| Telefon: | +385 52 804 728 |
| E-mail: | ivesa@cim.irb.hr |
| Datum i mjesto rođenja: | 15. kolovoza 1972. godine, Pula |
| Matični broj znanstvenice: | 242352 |


**Podaci o školovanju/stručna sprema/akademski stupnjevi**

**2005.** Doktor prirodnih znanosti, Biologija, Biološki odsjek Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu.
Disertacija: „Dinamika populacija makrofitobentosa na hridinastim dnima uz zapadnu obalu Istre“. Voditelji: dr. sc. Massimo Devescovi, prof. dr. sc. Boris Antolić i prof. dr. sc. Antonieta Požar-Domac.
**2001.** Magistar prirodnih znanosti, Oceanologija, Geološki odsjek Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu.
Magistarski rad: „Analiza naselja tropske zelene alge *Caulerpa taxifolia* (Vahl.) C. Ag. (Malinska, otok Krk)“. Voditeljica: dr. sc. Nevenka Zavodnik.
**1996.** Diploma dodiplomskog studija, Biologija-Ekologija, Biološki odsjek Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu.
Diplomski rad: „Analiza naselja hridinskog ježinca (*Paracentrotus lividus* Lamarck 1861) uz obalu južne Istre“. Voditeljica: prof. dr. sc. Antonieta Požar-Domac.

**Kretanje u službi**

Od 1997. do 2024. zaposlena u Centru za istraživanje mora Instituta Ruđer Bošković.

| | |
|---|---|
| 2024. – danas | znanstveni savjetnik |
| 2018. – 2024. | viši znanstveni suradnik |
| 2007. – 2018. | znanstveni suradnik; reizbor na isto radno mjesto: 2013. godine |
| 2005. – 2007. | viši asistent |
| 2001. – 2005. | asistent |
| 1997. – 2001. | mlađi asistent |

**Stipendije**

**2007. – 2008.** Postdoktorsko usavršavanje, Sveučilište u Sydneyu, Sydney, Australija; Stipendija: Sydney Aquarium Conservation.
**1998.** Stručno usavršavanje Université de Nice – Sophia Antipolis, Nice, Francuska; Stipendija: Francuske vlade.

**Pozvana predavanja**

(i) Iveša Lj. 2024. Restoration of canopy forming seaweeds. Department of Biology, Chioggia, Italija
(ii) Iveša Lj. 2019. Long-term fluctuation of *Cystoseira* forests along the west Istrian Coast (northern Adriatic, Croatia). Breaking the Surface 2019. 13th International interdisciplinary field workshop of maritime robotics and applications. Biograd na Moru, Hrvatska.
(iii) Iveša Lj. 2017. Patterns of *Cystoseira* forests along the west Istrian coast (northern Adriatic Sea, Croatia). EuroMarine Workshop POSTCLIMA. Pisa, Italija.
(iv) Iveša Lj. 2015. Spatial variability of macroalgal assemblages along the western Istria coast (northern Adriatic, Croatia). Radionica unutar COST akcije. Porto, Portugal.

**Organizacijske/rukovoditeljske vještine**

- Voditeljica Laboratorija za ekologiju bentosa u Centru za istraživanje mora Instituta Ruđer Bošković od 2022.
- Iskustvo u vođenju znanstveno-istraživačkih projekata i stručnih studija
- Iskustvo u organizaciji nacionalnih i međunarodnih simpozija
- Organizacija i vođenje terenskog istraživanja

**Nastavne aktivnosti**

**Preddiplomska nastava**: Znanost o moru Sveučilišta Jurja Dobrile u Puli: Algologija: 2009- do danas; Praktična nastava iz biologije mora: 2009-2018; Ekologija morskih algi i invazivne vrste: 2009-2015 te Ekologija mora: 2009-2011.

**Poslijediplomska nastava**: na poslijediplomskom studiju Oceanologije, Prirodoslovno-matematičkog fakulteta (PMF): Fitobentos mora

U zvanju naslovnog docenta: 2009. – 2018.; u zvanju naslovnog izvanrednog profesora: 2018. – 2024; u zvanju naslovnog redovitog profesora: 2024. – danas.

Mentorstva
Sudjelovala u vođenju 2 doktorske disertacije, 4 diplomska rada te 9 završnih radova:
**Doktorske disertacije**:
Moira Buršić: „Struktura i sastav beskralješnjaka u naselju alge *Corallina officinalis* na području južne Istre“ obranjen 2020. na Prirodoslovno-matematičkom fakultetu, Sveučilišta u Zagrebu. 196 str. Voditelji: Lj. Iveša, B. Bruvo Mađarić
Claudio Battelli: „Struktura in dinamika makrobentoških združb alg v mediolitoralu slovenskega morja“ obranjen 2013. na Biotehnološkom fakultetu, Sveučilišta u Ljubljani. 146 str. Voditelj: P. Mozetič, suvoditelj: Lj. Iveša
U tijeku vodi dva doktoranda: Andrea Bilajac: od 2020.; Edi Gljušćić: od 2021.
**Diplomski radovi**:
Andrej Fućak: 2023. na Sveučilištu u Zagrebu; voditelj: Lj. Iveša
Edi Gljušćić: 2019. na Univerzi na Primorskem, Kopar; voditelj: L. Lipej, suvoditelj: Lj. Iveša
Iva Kučinar: 2016. na Sveučilištu u Zagrebu; voditelji: P. Kružić i Lj. Iveša
Ana Čelig: 2010. na Sveučilištu u Zagrebu; voditelj: Lj. Iveša
**Završni radovi**:
Ena Radić Manestar: 2024. na Sveučilištu Jurja Dobrile u Puli; voditelj: Lj. Iveša

Andrej Fućak: 2020. na Sveučilištu Jurja Dobrile u Puli; voditelj: Lj. Iveša, suvoditelj: N. Iveša
Stefano Erman: 2018. na Sveučilištu Jurja Dobrile u Puli; voditelji: M. Devescovi, Lj. Iveša
Edi Gljušćić: 2016. na Sveučilištu Jurja Dobrile u Puli; voditelj: Lj. Iveša
Doris Valec: 2016. na Sveučilištu Jurja Dobrile u Puli; voditelji: M. Devescovi, Lj. Iveša
Nikolina Premate: 2015. na Sveučilištu Jurja Dobrile u Puli; voditelj: Lj. Iveša
Iva Kučinar: 2014. na Sveučilištu Jurja Dobrile u Puli; voditelj: Lj. Iveša
Martina Kolić: 2013. na Sveučilištu Jurja Dobrile u Puli; voditelj: Lj. Iveša
Ariana Stojnić: 2009. na Sveučilištu u Trstu; suvoditelj: Lj. Iveša

**Studentska praksa**:

2024. Vittoria Ferrari, Università Politecnica delle Marche, Ancona, Italija. Voditelj: Lj. Iveša
2021. Mojca Pungerčar, Univerza na Primorskem, Kopar, Slovenija. Voditelj: Lj. Iveša
2016. Kathryn Morrissey, Sveučilište u Ghentu, Belgija. Voditelj: Lj. Iveša

**Funkcije i članstva**

Članstva i funkcije u nacionalnim i međunarodnim institucijama i znanstvenim tijelima:
Član algološke sekcije British Phycological Society (BPS), International Phycological Society (IPS) i Hrvatskog Botaničkog Društva (HBoD).

**Domaće nagrade za znanstveni rad**

Godišnja nagrada za znanstveni rad IRB-a: 2018 i 2020. godine

**Sudjelovanje u znanstveno-istraživačkim projektima** (zadnjih 5 godina)

**2024.-2027.** Chemico-physical and multispectral Data fusion for Adriatic sea monitoring by autonomous vessel, BRIGANTINE. Voditeljica za IRB: M. Smodlaka Tanković; suradnik na projektu
**2024.-2027.** Coordinated and Adaptive Monitoring of Biodiversity change across Mediterranean rocky ecosystems, CAMBioMed. Voditelj za IRB: Lj. Iveša
**2023.-2025.** Rješenja za obnovu šuma smeđih morskih makroalgi. Hrvatsko-slovenski znanstveno-istraživački projekt. Voditelj: Lj. Iveša
**2021 - 2023.** Usluga kartiranja obalnih i pridnenih morskih staništa u obalnom moru RH i pridnenih morskih staništa u hrvatskom epikontinentalnom pojasu u sklopu OPKK projekta Kartiranje obalnih i pridnenih morskih staništa na području Jadranskog mora pod nacionalnom jurisdikcijom. Grupa 1 i 2. Zajednica ponuditelja. Naručitelj: MINGOR. Voditelj: A. Žuljević; suradnik na projektu
**2020.-2023.** CoAStal and marine waters integrated monitoring systems for ecosystems proteCtion AnD management. CASCADE. Interreg Italy-Croatia CBC Programme 2014-2020. Voditelj: D. Marić Pfannkuchen; suradnik na projektu
**2020.-2024.**
Odgovori smeđih algi roda *Cystoseira*, koje formiraju staništa, na lokalne i globalne stresore. HrZZ projekt IP-2019-04-6984. Voditelj: Lj. Iveša

Ukupno objavljen 41 znanstveni rad. Aktivno sudjelovala kao autor na 26 međunarodnih i domaćih konferencija; kao koautor na 27 međunarodnih i domaćih konferencija.