Temperaturna obilježja i toplinsko opterećenje Dubrovnika

Boras, Marijana

Master's thesis / Diplomski rad

2021

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:188652

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Marijana Boras

TEMPERATURNA OBILJEŽJA I TOPLINSKO OPTEREĆENJE DUBROVNIKA

Diplomski rad

Zagreb, 2021.

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

DIPLOMSKI SVEUČILIŠNI STUDIJ FIZIKA-GEOFIZIKA

SMJER: METEOROLOGIJA I FIZIČKA OCEANOGRAFIJA

Marijana Boras

Diplomski rad

Temperaturna obilježja i toplinsko opterećenje Dubrovnika

Voditeljica diplomskog rada: izv. prof. dr. sc. Ivana Herceg Bulić

Zagreb, 2021.

Zahvale

Ovaj rad napravljen je u sklopu projekta HRZZ UIP-2017-05-6396 „Klimatske promjene i varijabilnost u Hrvatskoj“ (CroClimGoGreen). Zahvaljujem svojoj mentorici izv. prof. dr. sc. Ivani Herceg Bulić na svoj pomoći i entuzijazmu tijekom izrade ovog rada. Mateju Žgeli zahvaljujem na pomoći pri obradi satelitskih snimaka i smilucija modela MUKLIMO_3 u GIS-u i GEE-u.

Zahvaljujem svim kolegama i prijateljima na velikodušnoj pomoći, ohrabrivanju i zajedničkom učenju tijekom studija, kao i na mnogim zabavnim trenucima uz koje je sve bilo lakše i ljepše.

Najviše zahvaljujem svojoj obitelji koja je uvijek bila tu za mene i poticala me na učenje. Hvala vam što ste uvijek znali pronaći prave riječi utjehe i ohrabrenja kada su se pojavile poteškoće. I najviše od svega hvala vam što uvijek vjerujete u mene.

Sažetak

Klimatske promjene predstavljaju sve veći problem u suvremenom svijetu, a njihov utjecaj na urbane sredine iznimno je važan s mnogih aspekata (npr. ekološkog, socijalnog, ekonomskog, zdravstvenog). Više od polovice svjetske populacije živi u gradovima koji doprinose emisiji stakleničkih plinova, a time i klimatskim promjenama. S druge strane, stanovništvo gradova je pod utjecajem klimatskih uvjeta koji čine urbanu klimu. Gradovi pokazuju specifične meteorološke i klimatološke karakteristike zbog čega se sve više proučava urbana klima. U ovom radu napravljena je analiza temperaturnih obilježja i toplinskog opterećenja grada Dubrovnika na temelju izmjerenih podataka o temperaturi u razdoblju 1961.-2019. na meteorološkoj postaji Dubrovnik te na temelju satelitskih snimaka satelita LANDSAT5 i analize klimatskih indeksa dobivenih simulacijama modela MUKLIMO_3. U radu su proučavani trendovi srednjih dnevnih, maksimalnih dnevnih, minimalnih dnevnih i sezonskih temperatura pomoću dvije nezavisne metode, Mann-Kendall testa i metode linearne regresije. Rezultati pokazuju uzlazan trend za sve promatrane temperature. Istim metodama ispitani su i trendovi klimatskih indeksa (studeni dani, ljetni dani, tropske noći) koji su u skladu s pozitivnim temperaturnim trendom i također ukazuju na povećanje toplinskog opterećenja grada Dubrovnika u promatranom razdoblju. Prema Köppenovoj klasifikaciji klime pokazano je da u 30-godišnjim razdobljima za godine 1961.-1990. nije došlo do promjene tipa klime u Dubrovniku te da prevladava sredozemna klima sa suhim i vrućim ljetom (Csa). Rezultati satelitskih snimaka prosječnih ljetnih površinskih temperatura u razdoblju 2001.-2010. pokazuju da se urbanizirane površine više zagrijavaju od prirodnih površina s vegetacijom. Rezultati klimatskih indeksa (ljetni i vrući dani, tople i ljetne večeri, tople i tropske noći) dobiveni simulacijama modela MUKLIMO_3 također pokazuju da se urbanizirane površine više zagrijavaju od prirodnih površina te da to zagrijavanje ovisi o gustoći izgrađenosti.

Ključne riječi: toplinsko opterećenje, urbana klima, metoda linearne regresije, Mann-Kendall test, Köppenova klasifikacija klime, klimatski indeksi, model MUKLIMO_3, satelit LANDSAT5

Temperature characteristics and heat load of Dubrovnik

Abstract

In modern world problem of climate change is raising. More than half of world's population is living in cities, which contribute green house gass emission causing global climate changes. Urban areas show particulary meteorological and climatological characteristics, that's why urban climate is getting more considered. In this work temperature characteristics and heat load of Dubrovnik is analyzed by using observed temperature data from local station in Dubrovnik in period 1961.-2019., satellite data from LANDSAT5 satellite were also used for analysis and analysis of climate indices obtained from simulations of MUKLIMO_3 model. Trends of mean daily, maximum daily, minimum daily and seasonal temperatures were analyzed using two independent methods, Mann-Kendall test and method of linear regression. Results are showing positive trends for all analyzed temperatures. Using same methods, trends of climate indices (frost days, summer days and tropical nights) were also analyzed and have showed raise of temperature and heat load in the city of Dubrovnik in the observed period. Analysis of Köppen climate clasification showed that in Dubrovnik there were no changes of climate type in 30-year periods for years in 1961.-1990., climate type of Dubrovnik is hot-summer Mediterranean climate. Results of satellite data of mean summer land surface temperatures in period 2001.-2010. showed that urban surfaces are heated more than natural surfaces with vegetation. Results of climate indices (summer and hot days, warm and summer evenings, warm and tropical nights) obtained by simulations of MUKLIMO_3 model also showed that urban surfaces are heated more than natural surfaces with vegetation and less dense built areas.

Keywords: heat load, urban climate, linear regression method, Mann-Kendall test, Köppen climate clasification, climate indices, MUKLIMO_3 model, satellite LANDSAT5

Popis kratica

T_{20} – temperatura zraka izmjerena u 20 h prema srednjoeuropskom ljetnom vremenu (UTC+01)

T_{22} – temperatura zraka izmjerena u 22 h prema srednjoeuropskom ljetnom vremenu (UTC+01)

T_n – minimalna dnevna temperatura

T_x – maksimalna dnevna temperatura

cmaks – maksimalna vrijednost parametra u kutu kuboida pri primjeni kuboidne metode

cmin – minimalna vrijednost parametra u kutu kuboida pri primjeni kuboidne metode

Csa - sredozemna klima sa suhim i vrućim ljetom

DHMZ - Državni-hidrometeorološki zavod

DJF – prosinac, siječanj, veljača (eng. *December, January, February*)

ETCCDI – eng. *Expert Team on Climate Change Detection and Indices*

GEE – online platforma za analizu geoprostornih podataka (eng. *Google Earth Engine*)

GIS - geografsko informacijski sustav (eng. *Geographic Information System*)

IPCC – eng. *Intergovernmental Panel on Climate Change*

JJA – lipanj, srpanj, kolovoz (eng. *June, July, August*)

LST - površinska temperatura (eng. *land surface temperature*)

LULC - klasifikacija zemljišnog pokrova/korištenja zemljišta (eng. *Land Use/Land Cover*)

MAM – ožujak, travanj, svibanj (eng. *March, April, May*)

MK - Mann-Kendall test

MUKLIMO_3 – eng. *Microscale Urban Climate Model in three dimensions*

SON – rujan, listopad, studeni (eng. *September, October, November*)

temp. – temperatura

UHI – urbani toplinski otok (eng. *Urban Heat Island*)

Sadržaj

1. Uvod 1

1.1Klimatske promjene 1

1.2 Urbana klima 3

1.3 Klimatska obilježja Dubrovnika 4

1.4 Motivacija i cilj istraživanja 5

2. Podaci i metode 7

2.1 Izmjereni podaci 7

2.2 Analiza trendova 8

2.3 Klimatski indeksi 11

2.4 Köppenova klasifikacija klime 12

2.5 MODEL MUKLIMO_3 13

2.6 Obrada podataka 18

3. Rezultati i diskusija 20

3.1. Temperaturna obilježja Dubrovnika – izmjereni podaci 20

3.2 Toplinsko opterećenje Dubrovnika – satelitski podaci i simulacije modelom MUKLIMO_3 36

4. Zaključak 49

Dodatak A 51

Literatura 52

1. Uvod

1.1Klimatske promjene

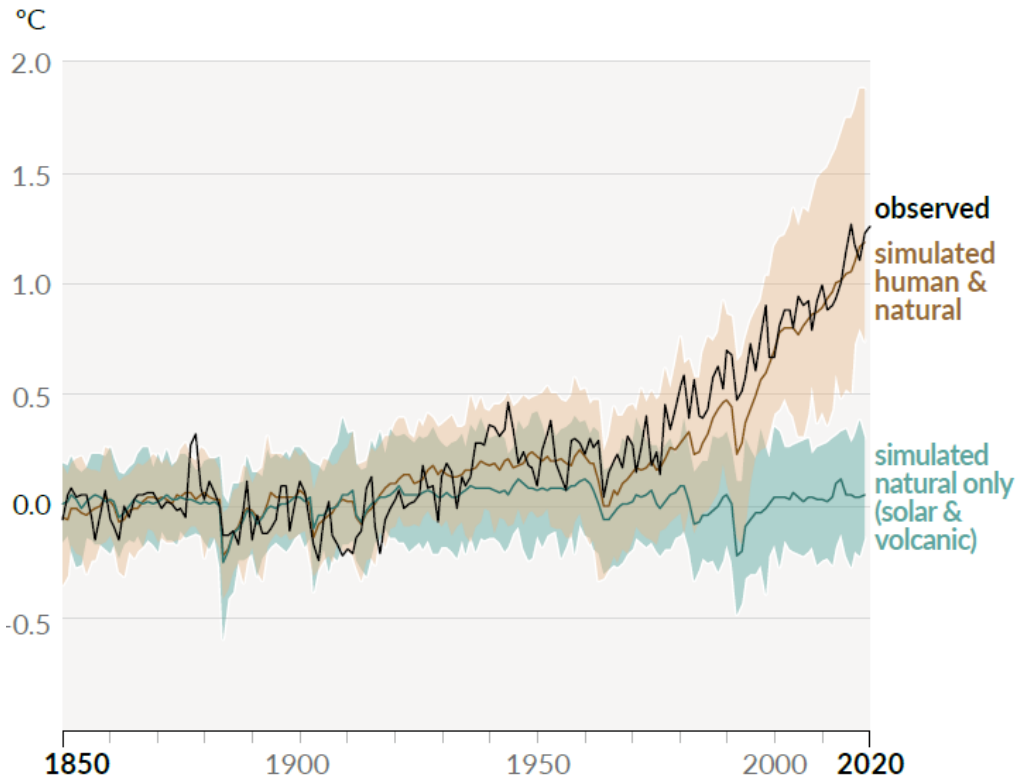
Pojam klimatske promjene sve je prisutniji u suvremenom svijetu. Razlog tome nisu samo dugogodišnja znanstvena istraživanja i rezultati koji govore o porastu temperature i koncentracije ugljikovog dioksida i drugih stakleničkih plinova. Predviđa se da će frekvencija i intenzitet ektremnih vremenskih pojava porasti (Meehl i sur., 2007). Sve učestalija pojava ekstremnih događaja koji se već bilježe (poput toplinskih valova, suše i intenzivne oborine), najčešće se u javnosti tumači kao posljedica klimatskih promjena.

Prema rječniku IPCC-ja (eng. *Intergovernmental Panel on Climate Change*, IPCC) definicija klimatskih promjena je: „Klimatske promjene označavaju promjene u stanju klime koje se mogu prepoznati u promjenama srednjih i/ili varijabilnih svojstava te mogu potrajati neko vrijeme, desetljećima ili duže.“ (Matthews, 2018). Klimatske promjene događaju se pod utjecajem raznih prirodnih forsiranja te su zabilježene na različitim vremenskim i prostornim skalama, od nekoliko godina do nekoliko tisuća godina, ovakva obilježja ukazuju na postojanje prirodne klimatske varijabilnosti (Beniston, 1998). Neke od posljedica prirodne klimatske varijabilnosti su izmjene ledenih doba otkrivene istraživanjem zapisa u Antarktičkom ledu (Beniston, 1998). Prirodna forsiranja koja dovode do fluktuacija klime mogu biti unutar klimatskog sustava, tj. unutarnja forsiranja (primjerice uzajamno povratni proces albeda leda, El niño - Južna osilacija, Pacifička dekadna oscilacija,...), i mogu biti vanjska, izvan klimatskog sustava, poput promjena u Sunčevoj aktivnosti, vulkanskoj aktivnosti,...

Iako klimatski sustav Zemlje ima prirodne modove varijabilnosti u kojima dolazi do prirodnog mijenjanja klime, porast srednje globalne temperature koji se bilježi od druge polovice 19. stoljeća ukazuje na porast srednje globalne temperature za koji je u najnovijem izvještaju IPCC-ja (IPCC, 2021) ustanovljeno da je takav porast gotovo sigurno posljedica antropogenog utjecaja. Prema istom izvještaju nedvojbeno je da je antropogeno djelovanje dovelo do porasta koncentracije stakleničkih plinova u

razdoblju od otprilike 1750. do danas (IPCC, 2021). Porast koncentracije stakleničkih plinova uzrokuje pojačavanje efekta staklenika zbog čega se Zemlja sve više zagrijava i postaje sve toplija, taj proces naziva se globalno zatopljenje.

Trend porasta srednje globalne površinske temperature u odnosu na srednjak za razdoblje 1850.-1900. iznosi 1.0 °C (vjerojatnije u rasponu 0.8°C-1.2°C) prema specijalnom izvješću *Global warming of 1.5°C* (IPCC, 2018). Analizom kraćih razdoblja u novijoj povijesti uočava se sve veći trend, tj. globalna srednja temperatura ubrzano raste.



Slika 1.1: Promjene u srednjoj globalnoj površinskoj temperaturi (godišnje usrednjene) na temelju izmjerenih podataka, numeričkih simulacija s uključenim antropogenim utjecajima i prirodnom klimatskom varijabilnošću te numeričkih simulacija samo s prirodnom klimatskom varijabilnošću (preuzeto iz IPCC, 2021).

Ekstremni vremenski događaji nerijetko ostavljaju vrlo negativne posljedice na prirodu i okoliš, ali sve više utječu i na ljudsko zdravlje i život. Iz tog razloga je tema klimatskih promjena i borba protiv globalnog zatopljenja postala svakodnevni izazov za cjelokupno društvo.

1.2 Urbana klima

Proučavanjem međudjelovanja gradova i atmosfere bavi se urbana klimatologija (Oke i sur., 2017). Glavna karakteristika gradova jest da su na tim područjima izvorne prirodne površine uglavnom promijenjene i prenamijenjene u površine napravljene od umjetnih materijala (asfalt, beton,...). Pielke i sur. (2002) navodi da promjene u korištenju zemljišta (eng. *land-use*) kroz površinski energetski budžet također utječu na regionalne i globalne klimatske promjene, a ne samo na promjene u kružnom ciklusu ugljikovog dioksida. Urbanizacijom dolazi do promjene svojstava površina uslijed čega su moguće višestruke negativne posljedice. Primjerice, površine koje su nepropusne uslijed intenzivnih oborina povećavaju rizik od poplava, osim toga, urbanizirane se površine najčešće više zagrijavaju od prirodnih čime se toplinsko opterećenje povećava što negativno utječe na kvalitetu života stanovništva (Masson i sur., 2020).

Za klimu u urbanim područjima može se izdvojiti nekoliko različitih karakteristika (Masson i sur., 2020), primjerice, temperatura zraka u gradovima je viša od temperature zraka u ruralnim neurbaniziranim dijelovima, posebice noću i tijekom anticiklonalnih vremenskih uvjeta, a isto vrijedi i za površinsku temperaturu. Osim razlike u temperaturi, gradovi utječu i na karakteristike vjetra. Naime, aerodinamički promatrano, urbane površine su hrapave što uzrokuje usporavanje vjetra zbog djelovanja sile trenja (Klaić i sur., 2002). Posebice prilikom snažnih i umjerenih vjetrova kada osim usporavanja dolazi i do blagog zakretanja u smjeru gradijenta tlaka, a u slučajevima divergencije i konvergencije može doći i do vertikalnog gibanja. Efekt povišene temperature zraka u gradovima u odnosu na okolinu poznat je pod terminom urbani toplinski otok (eng. *Urban Heat Island*, UHI). Ovaj efekt u uvjetima slabijeg vjetra izaziva cirkulaciju sličnog mehanizma kao što je obalna cirkulacija ili cirkulacija obronka, gdje zrak iz okolnog područja struji prema gradu što u nekim slučajevima može dovesti i do recirkulacije onečišćenja. Osim navedenog, gradovi utječu i na kvalitetu zraka, naoblaku i oborinu. Proučavanje urbane klime i njenih uzroka je vrlo kompleksno jer su gradovi vrlo složeni sustavi, njihov složen trodimenzionalni oblik utječe na smanjenje radijacijskog ohlađivanja i povećano pohranjivanje topline, a ovo se povećanje događa zbog velike količine površina koje su u kontaktu s atmosferom. Te su površine pretežito napravljene od materijala koji upijaju toplinu i zadržavaju je,

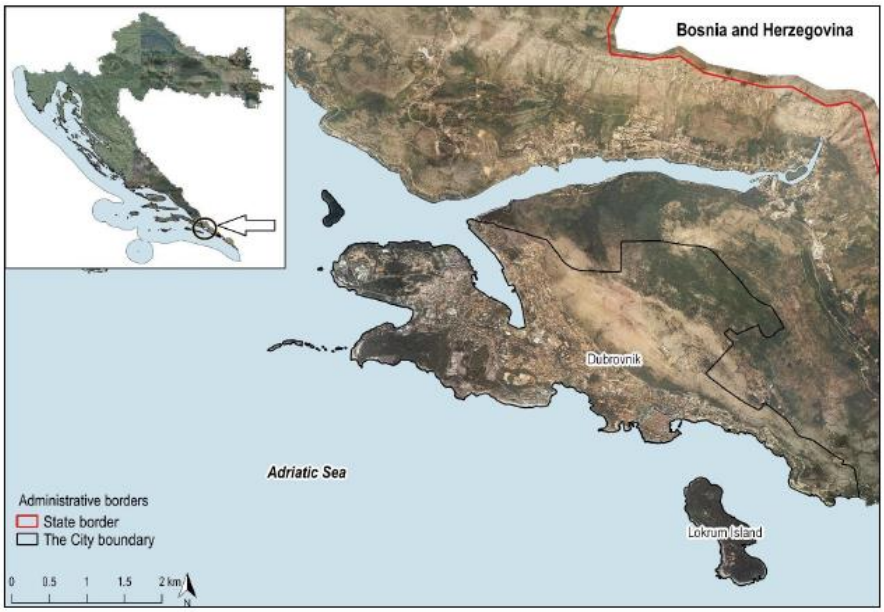
a temperatura tih materijala ovisi o njihovim svojstvima (radijacijskim, termalnim, aerodinamičkim i vlažnosti). Zbog velike zastupljenosti takvih matrerijala u urbanim sredinama, tamo je temperatura veća od temperature ruralnih dijelova (Masson i sur., 2020).

Gradovi emitiraju velike količine stakleničkih plinova, ipak, Balling, Cerveny i Idso (2001) navode da te koncentracije neznatno pridonose nastanku UHI-ja te da je povećanje temperature u urbaniziranim dijelovima ponajviše uzrokovano sušnijim tlima i apsorpcijom sunčevog zračenja u materijalima od kojeg su urbanizirane površine najčešće napravljene. Iako velike količine stakleničkih plinova koje emitiraju gradovi ne sudjeluju značajno u nastanku UHI-ja, one pridonose globalnim klimatskim promjenama kojima su izloženi i sami gradovi, a očituju se kroz povećanje temperature, sve češće pojave ekstremnih vremenskih događaja (toplinski valovi, olujna nevremena,...), promjene u režimu oborina, itd. (Masson i sur., 2020). Iz svega navedenog, pokazuje se da su potrebna daljnja istraživanja urbanih klima i traženja rješenja za ublažavanje toplinskog opterećenja gradova i prilagodbu na urbane klimatske uvjete.

1.3 Klimatska obilježja Dubrovnika

Grad Dubrovnik nalazi se u južnom dijelu Republike Hrvatske (42°38'53''N, 18°5'32''E) na obali Jadranskog mora te se iznad grada nalazi planina Srđ. Ovaj položaj je geografski zanimljiv jer je na relativno malom području moguće proučavati razne utjecaje na klimu grada (npr. utjecaj mora, utjecaj planinske prepreke). Geografski položaj Dubrovnika prikazan je na slici 1.2.

Prema Köppenovoj klasifikaciji, klima u Dubrovniku odgovara mediteranskom tipu klime sa suhim i vrućim ljetima (Csa). U razdoblju 1971.-2000. maksimalna dnevna temperatura bila je najveća u srpnju i kolovozu (35.5°C i 36.7°C), dok je minimalna dnevna temperatura u tim mjesecima iznosila 14.1°C. Maksimalne dnevne temperature u proljeće i jesen su prelazile 23°C, dok je u zimskim mjesecima, siječnju i veljači, srednja dnevna temperatura bila oko 9°C, a snijeg je bio vrlo rijetka pojava. Prema godišnjoj ruži vjetrova, najjači vjetar u Dubrovniku je bura koja puše sa sjeveroistoka (planinska prepreka Srđ) te postiže brzine veće od 5.4 m/s (Zaninović i sur., 2008).



Slika 1.2.: Geografski položaj grada Dubrovnika (preuzeto iz Climate Change Adaptation Plan for the City of Dubrovnik, 2019.).

1.4 Motivacija i cilj istraživanja

Prema UN-ovom izvješću iz 2016. godine procijenjeno je da u urbaniziranim područjima živi više od polovice svjetskog stanovništva te da će do 2030. taj postotak porasti na 60 (UN, 2016). Iz ovih podataka vidljivo je da je velik broj ljudi izravno izložen utjecaju urbane klime stoga je važno nastaviti istraživati ovo područje. S obzirom da svaki grad ima drugačije morfološke, geografske i druge osobine te da još uvijek nisu pronađena jedinstvena rješenja za smanjenje toplinske opterećenosti gradova potreban je individualan pristup. U ovom radu proučavat će se grad Dubrovnik.

Grad Dubrovnik odabran je zbog svojeg zanimljivog geografskog položaja i turističkog značaja. Jadransko more, na obalama kojeg je smješten Dubrovnik, nalazi se u Sredozemnom moru pa Dubrovnik pripada mediteranskim gradovima. Mediteransko područje prepoznato je kao vruća točka (eng. *hot spot*), tj. područje koje je jako osjetljivo i brzo reagira na klimatske promjene te su učinci klimatskih promjena na okoliš i djelatnosti ovdje izraziti (Giorgi, 2006). S obzirom da je turizam u Dubrovniku jedna od glavnih gospodarskih grana i da je turizam, kao gospodarska grana izrazito osjetljiv na klimatske promjene (Jopp, DeLacy i Mair, 2010) te da je Dubrovnik

mediteranski grad prepoznata je važnost analize njegovih temperaturnih obilježja i toplinske opterećenosti.

Cilj ovog istraživanja je na temelju izmjerenih podataka o temperaturi u razdoblju 1961.-2019. ispitati i proučiti promjene u temperaturnim obilježjima Dubrovnika. Također, osim opaženih podataka, u ovom istraživanju ispitat će se i toplinsko opterećenje pomoću simulacija modelom MUKLIMO_3 (eng. *Microscale Urban Climate Model in three dimensions*). Na temelju tih simulacija izračunat će se klimatski indeksi koji će poslužiti za procjenu toplinskog opterećenja grada ovisno o obilježjima površine, tj, ispitat će se koji dijelovi grada se jače zagrijavaju (tj. postoje li razlike između urbaniziranih i prirodnih površina) kao i utjecaj gustoće izgrađenosti.

Cilj ovog rada je i upoznavanje s radom modela MUKLIMO_3 kako bi se u budućnosti istraživanja urbanih klima mogla proširiti na traženje konkretih rješenja za ublažavanje toplinskog opterećenja.

2. Podaci i metode

2.1 Izmjereni podaci

U ovom diplomskom radu korišteni su i analizirani podaci Državno-hidrometeorološkog zavoda (DHMZ) o temperaturi izmjerenoj na mjernoj postaji u Dubrovniku u razdoblju 1.1.1961.-31.12.2019. Pri izradi ovog rada korišteni su podaci dnevnih minimalnih i maksimalnih temperatura te dnevni podaci terminskih vrijednosti temperature u 07, 14 i 21 h. U promatranom razdoblju, 1.1.1961.-31.12. 2019., podaci terminskih vrijednosti temperature (u 07, 14 i 21 h) za 1978. godinu nisu cjeloviti te zbog toga nisu mogli biti uzeti u obzir pri analizi. Pri analizi dnevnih minimalnih i dnevnih maksimalnih temperatura za pojedine sezone (zima, proljeće, ljeto, jesen) u obzir nisu uzeti podaci u razdoblju 22.3.1978.-13.5.1979. jer nisu bili dostupni.

Srednje dnevne temperature računate su prema relaciji:

$$\bar{t} = \frac{t_{07} + t_{14} + 2t_{21}}{4},$$

pri čemu je $\bar{t}$ srednja dnevna temperatura, t_{07}, t_{14} *i* t_{21} su terminske vrijednosti dnevne temperature u 07, 14 i 21 h. Godišnje srednje dnevne temperature su srednje dnevne temperature usrednjene za svaku godinu. Srednje sezonske srednje dnevne temperature su srednje dnevne temperature usrednjenje za određenu sezonu za svaku godinu. Na isti način je napravljena i analiza za srednje sezonske maksimalne i minimalne dnevne temperature. Analize srednjih sezonskih vrijednosti temperatura napravljene su za sve 4 godišnje sezone: proljeće (MAM, eng. *March April May*), ljeto (JJA, eng. *June July August*), jesen (SON, eng. *September October November*) i zimu (DJF, eng. *December January February*). Kako bi za svaku sezonu bio podjednak broj godina uključenih u analizu, analize su napravljene za godine u razdoblju 1961.-2018. Sva obrada izmjerenih podataka i grafički prikazi napravljeni su u programskom jeziku *Python*.

2.2 Analiza trendova

Kako bi se izmjereni podaci bolje istražili, nakon grafičkog prikaza izmjerenih vrijednosti temperature u pravokutnom koordinatnom sustavu, napravljene su dvije nezavisne analize trendova korištenjem metode linearne regresije i korištenjem Mann-Kendall (MK) testa.

Prema dobivenim grafičkim prikazima pretpostavljena je linearna ovisnost između nezavisne varijable vremena te zavisne varijable temperature. Za dobivanje pravca, tj. trenda koji opisuje pretpostavljenu linearnu ovisnost korištena je metoda linearne regresije. Za određivanje pravca regresije koji najbolje odgovara izmjerenim podacima korištena je metoda najmanjih kvadrata. Linearni trendovi korišteni su u svrhu boljeg razumijevanja dinamike promjene temperatura u promatranim razdobljima, primjerice, dolazi li do ubrzanog ili usporenog povećanja ili smanjenja temperature. Nezavisno od metode linearne regresije, na promatrane vremenske nizove podataka primjenjen je i MK test, kojim se provjerilo postoje li u promatranim nizovima podataka statistički značajni trendovi.

Cjelokupna analiza trendova, kao i grafički prikazi, napravljena je u programskom jeziku *Python* korištenjem paketa *matplotlib, matplotlib.pyplot, numpy.linalg* i *pymannkendall*.

2.2.1. Metoda linearne regresije

Metoda linearne regresije pretpostavlja linearnu ovisnost između parova mjerenja (x_i, y_i) , tj. nezavisne i zavisne varijable, koja se može aproksimirati jednadžbom pravca

$$y(x) = ax + b\,.$$

Dobiveni pravac ne može se provući kroz sve točke mjerenja jer pri mjerenju dolazi do raznih pogrešaka (standardna devijacija σ_i) što uzrokuje fluktuacije izmjerenih vrijednosti u odnosu na liniju pravca (trenda, fita). Kako bi razlika između izmjerenih vrijednosti y_i i vrijednosti dobivenih linearnom regresijom $y(x)$ bila minimalna, koristi se metoda najmanjih kvadrata. Razlika, tj. odstupanje od izmjerene vrijednosti definira se izrazom

$$\Delta y_i = y_i - y(x_i) = y_i - ax_i - b.$$

Prema metodi najmanjih kvadrata najvjerojatniji pravac regresije je onaj čija je suma kvadrata odstupanja najmanja

$$\chi^2 = \sum_{i=1}^{n} \left(\frac{\Delta y_i}{\sigma_i}\right)^2 = \sum_{i=1}^{n} \left(\frac{y_i - ax_i - b}{\sigma_i}\right)^2 = min.$$

Iz prethodnog uvjeta metode najmanjih kvadrata slijedi da parcijalne derivacije trebaju biti jednake nuli

$$\frac{\partial \chi^2}{\partial a} = 0$$

$$\frac{\partial \chi^2}{\partial b} = 0.$$

U ovom radu pretpostavljeno je da su standardne devijacije izmjerenih veličina, tj. preciznost uređaja, za svako mjerenje jednaki $\sigma = \sigma_i$. Stoga je izvodom dobiven izraz za koeficijent pravca regresije

$$a = \frac{n \sum x_i \, y_i - (\sum x_i)(\sum y_i)}{n \sum {x_i}^2 - (\sum x_i)^2},$$

a za odsječak na ordinati dobiven je izraz

$$b = \frac{1}{n} \left(\sum y_i - a \sum x_i \right) \quad \text{(Bevington, 2003).}$$

Dobiveni izrazi korišteni su u programskom dijelu ovog rada pri računanju i crtanju trendova.

2.2.1. Mann-Kendall test

U ovom radu za procjenu signifikantnosti trendova u nizovima temperaturnih podataka primijenjen je neparametarski Mann-Kendall (MK) test (Mann, 1945; Kendall, 1975). Ovaj test je vrlo pogodan za upotrebu jer nije nužno da podaci odgovaraju određenoj raspodjeli, moguće je da neki podaci u nizu nedostaju ili da neke

vrijednosti više odudaraju od ostalih, ovakav pristup je moguć jer Mann-Kendall test ne koristi vrijednosti podataka, već relativne razlike između njih (Gilbert, 1987). Zbog navedenih prednosti, MK test se često primjenjuje za određivanje signifikantnosti trendova (Su, Jiang i Jin, 2006; Zhang i sur., 2009; Westra, Alexander i Zwiers, 2013; Graczyk i sur., 2017; Meshram i sur., 2020).

Prema Yue, Pilon i Cavadias (2002), statistika S Mann-Kendall testa opisana je izrazom

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^{n} sgn(x_j - x_i),$$

pri čemu je n duljina promatranog niza, x_i *i* x_j vrijednosti redoslijednih podataka. Za funkciju $sgn(x_j - x_i)$ vrijedi

$$sgn(x_j - x_i) = \begin{Bmatrix} 1\,, x_j > x_i \\ 0, x_j = x_i \\ -1, x_j < x_i \end{Bmatrix}.$$

Za nizove duljine $n \geq 8$, srednja vrijednost i varijanca su

$$E(S) = 0$$

$$Var(S) = \frac{n(n-1)(2n+5) - \sum_{i=1}^{n} t_i i(i-1)(2i+5)}{18},$$

t_i je broj podataka za i-ti dio (Mann, 1945; Kendall, 1975).

MK statistika Z_{mk} se kod većih nizova ($n > 10$) dobiva korištenjem relacije

$$Z_{mk} = \begin{Bmatrix} \frac{S_x - 1}{\sigma} \;\; za\; S_x > 0 \\ \frac{S_x + 1}{\sigma} \; za\; S_x < 0 \\ 0\; za\; S_x = 0 \end{Bmatrix},$$

pomoću Z_{mk} ispituje se koja se hipoteza može prihvatiti, prema nultoj hipotezi H_0 trend u promatranom nizu podataka ne postoji, dok prema alternativnoj hipotezi H_a u podacima postoji signifikantan trend za odabrani nivo značajnosti. Negativne vrijednosti Z_{mk} upućuju na silazan trend, dok pozitivne vrijednosti Z_{mk} upućuju na

uzlazni trend. Usporedbom $|Z_{mk}|$ i $Z_{1-\frac{\alpha}{2}}$, pri čemu je α odabrani nivo značajnosti (u ovom slučaju 5%), ako je $|Z_{mk}| > Z_{1-\frac{\alpha}{2}}$ na odabranom nivou značajnosti hipoteza H_0 se odbacuje i prihvaća se hipoteza H_a, tj. u promatranim podacima postoji signifikantan trend. Do istog zaključka dolazi se i ako je *p*-vrijednost manja od nivoa značajnosti α. Vrijednosti $Z_{1-\frac{\alpha}{2}}$ *i* α mogu se dobiti iz standardne normalne distribucije (Aamir i Hassan, 2020).

2.3 Klimatski indeksi

Kako bi se pronašao standardizirani način praćenja trendova ekstremnih vremenskih događaja (primjerice toplinskih valova i vrlo hladnih dana) koji će biti globalno usporedivi, tijekom 1990-ih godina organizirane su međunarodne radionice s ciljem definiranja klimatskih indeksa pomoću kojih će se praćenjem dnevnih vrijednosti ekstremnih temperatura i oborine moći pratiti vremenske i prostorne godišnje promjene u pojavljivanju ekstremnih događaja (Zhang i sur., 2011).

U ovom su radu analizirani klimatski indeksi ekstrema Climdex. Oni su skup indeksa standardiziranih prema preporukama stručnjaka okupljenih u CCI/WCRP/JCOMM Expert Team on Climate Change Detection and Indices (ETCCDI) te se računaju na temelju dnevnih podataka maksimalne i minimalne temperature te oborine. Korištenjem izmjerenih podataka dobivenih od DHMZ-a izračunata su i analizirana tri temperaturna klimatska indeksa: godišnji broj studenih dana, godišnji broj ljetnih dana i godišnji broj tropskih noći. Godišnji broj studenih dana računa se brojanjem dana u godini kada je minimalna dnevna temperatura bila manja od 0°C ($T_n < 0°C$), godišnji broj ljetnih dana računa se brojanjem dana u godini kada je maksimalna dnevna temperatura bila veća od 25°C ($T_x > 25°C$) dok se godišnji broj tropskih noći računa brojanjem dana u godini kada je minimalna dnevna temperatura veća od 20°C ($T_n > 20°C$). Pri analizi simulacija modela MUKLIMO_3 analizirat će se klimatski indeksi objašnjeni u potpoglavlju 2.5.

2.4 Köppenova klasifikacija klime

Njemački znanstvenik Vladimir Köppen napravio je prvu svjetsku kvantitativnu klasifikaciju klime, koju je kasnije dopunio Rudolf Geiger (Kottek i sur., 2006) stoga se ova klasifikacija često naziva i Köppen-Geigerova klasifikacija klime. Köppen-Geigerova klasifikacija klime često se koristi i u novijim radovima (Rubel i sur., 2017; Skalak i sur., 2018; Rahimi i sur., 2020; He i sur., 2021).

Klasifikacija klima prema Köppenu određuje se prema statistički dobivenim godišnjim i mjesečnim vrijednostima temperature i oborine (Šegota i Filipčić, 1996). Po zanimanju je Köppen bio biljni fiziolog te je uvidio da je pokazatelj mnogih klimatskih elemenata vegetacija na temelju čega je klimu podijelio u 5 glavnih klimatskih grupa (zona) prema vegetaciji ekvatorijalnih zona (A), sušnih zona (B), toplih zona (C), snježnih zona (D) i polarnih zona (E), pri klasifikaciji se nekim zonama još dodaje drugo slovo koje označava oborinu i treće slovo koje označava temperaturu zraka (Kottek i sur., 2006).

U ovom radu slijedila se Köppenova klasifikacija klime prema opisu koji navodi Peel i sur. (2007), a koji je primjenjen i u mnogim drugim istraživanjima (Beck i sur., 2018; Zhang i sur., 2019; Lu i sur., 2020). Za potrebe ovog rada, opisat će se kriteriji za klimatski tip sredozemna klima sa suhim i vrućim ljetom (Csa), detaljniji opis kriterija za sve klimatske tipove može se pronaći u Peel i sur. (2007). Kriteriji potrebni za određivanje sredozemne klime sa suhim i vrućim ljetom su za određivanje prvog slova kratice klime (slovo C) da temperatura najtoplijeg mjeseca u razdoblju mora biti veća od 10° C i da temperatura najhladnijeg mjeseca mora biti veća od 0°C i manja od 18° C. Za određivanje drugog slova u kratici (slovo *s*) potrebni kriteriji su da je oborina u najsušnijem ljetnom mjesecu manja od 40 mm i da je oborina u najsušnijem ljetnom mjesecu barem tri puta manja od oborine u najkišnijem zimskom mjesecu. Za određivanje trećeg slova u kratici klimatskog tipa (slovo *a*) uvjet je da je temperatura najtoplijeg mjeseca veća ili jednaka 22 °C. Ova klasifikacija je u ovom radu napravljena s ciljem provjere je li usporedno s promjenom temperaturnih obilježja Dubrovnika došlo i do promjene u klasifikaciji njegove klime.

2.5 MODEL MUKLIMO_3

Kako bi se istražilo toplinsko opterećenje na razini cijelog grada Dubrovnika te utjecaj podloge na njegovu prostornu raspodjelu, napravljene su simulacije atmosferskih uvjeta u Dubrovniku za razdoblje 2001.-2010. pomoću modela *Microscale Urban Climate Model in three dimensions* (MUKLIMO_3).

MUKLIMO_3 je nehidrostatički model (Žuvela-Aloise i sur., 2014) u kojem se rješavanjem Navier-Stokesovih jednadžbi te prognostičkih jednadžbi za temperaturu i vlažnost s uzimanjem u obzir toplinskih kapaciteta tla i mogućnosti pohranjivanja vlage u tlu te sofisticiranim vegetacijskim modelom simuliraju atmosferska temperaturna polja u urbanom okruženju s posebnim naglaskom na međudjelovanje između atmosfere i građevina (Früh i sur., 2010). Za pokretanje simulacija modela MUKLIMO_3 potrebno je postaviti početne i rubne uvjete. Najprije se u modelu na temelju izmjerenih podataka temperature, relativne vlažnosti i brzine vjetra s lokalne meteorološke postaje dobiva vremenski promjenjiv 1D profil navedenih meteoroloških parametara koji se potom koristi za početne i rubne uvjete 3D simulacija (Žuvela-Aloise i sur., 2014).

Kako bi se istražio utjecaj klimatskih promjena na toplinsko opterećenje urbanih područja potrebno je analizirati simulacije urbanih sredina kroz duža vremenska razdoblja (npr. 30-godišnja klimatološka razdoblja). S obzirom da je računanje velikog broja simulacija računarski vrlo zahtjevno, u ovakvim istraživanjima koristi se kuboidna metoda (Früh i sur., 2010).

Za analizu toplinskog opterećnja grada Dubrovnika u ovom radu analizirat će se klimatski indeksi dobiveni primjenom kuboidne metode na dobivene rezultate simulacija modelom MUKLIMO_3. Izračunat će se i analizirati sljedeći klimatski indeksi: ljetni dani (maksimalna dnevna temperatura $T_x \geq 25°C$), vrući dani (maksimalna dnevna temperatura $T_x \geq 30°C$), tople večeri (temperatura u 20 h prema srednjoeuropskom ljetnom vremenu $T_{20} \geq 20°C$), ljetne večeri (temperatura u 22 h prema srednjoeuropskom ljetnom vremenu $T_{22} \geq 20°C$), tople noći (minimalna dnevna temperatura $T_n \geq 17°C$) i tropske noći (minimalna dnevna temperatura $T_n \geq 20°C$).

2.5.1 Kuboidna metoda

Kuboidna metoda koristi se kako bi se izbjegli dugotrajni i računalno zahtjevni procesi simulacija dugačkih vremenskih nizova (npr. 30-godišnjih klimatoloških razdoblja) pri analizi utjecaja klimatskih promjena na urbane sredine modelom MUKLIMO_3 (Früh i sur., 2010). Metoda se temelji na pretpostavci da su atmosferski parametri koji najviše određuju toplinsko opterećenje urbanih sredina srednja dnevna prizemna temperatura zraka (T), prizemna relativna vlažnost (rh) i brzina vjetra pri tlu (v) (Žuvela-Aloise i sur., 2014).

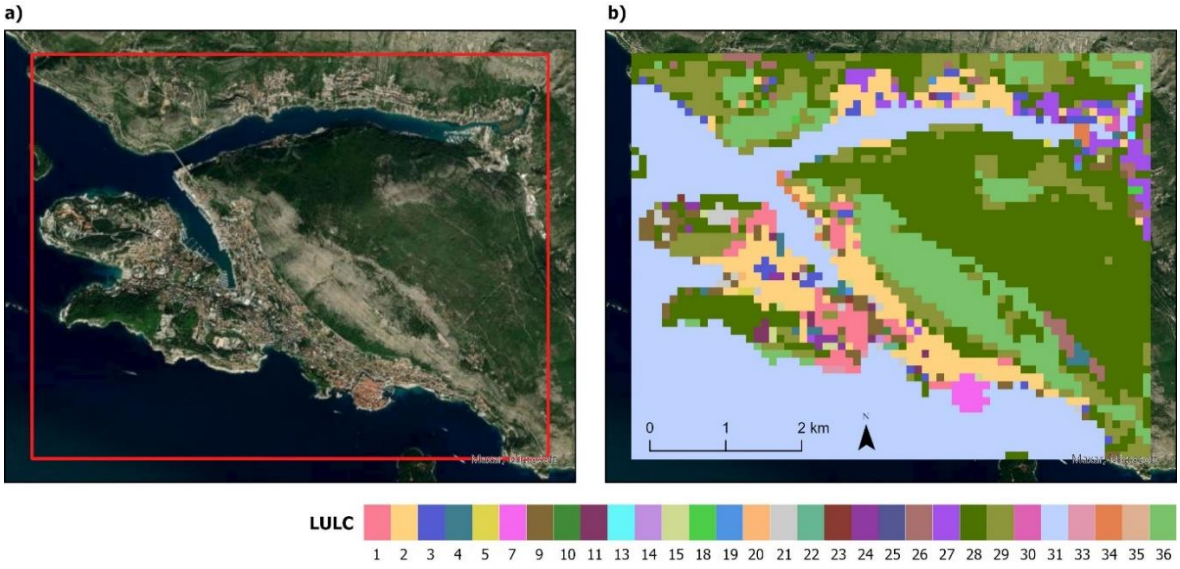
Navedena tri parametra se u kuboidnoj metodi postavljaju na tri dimenzije kuboida, pri čemu su granice tih dimenzija određene maksimalnim i minimalnim vrijednostima atmosferskih parametara procijenjenim prema vrijednostima u kojima može doći do toplinskog opterećenja u promatranoj urbanoj sredini. Time se dobivaju uvjeti za osam kutova kuboida, 8 kombinacija minimalnih i maksimalnih vrijednosti (T, rh, v), prema kojima se rade simulacije idealiziranih dnevnih ciklusa modelom MUKLIMO_3 za svaki kut *i* za dva prevladavajuća smjera vjetra (Früh i sur., 2010).

Nakon što se izračuna 8 simluacija dnevnih ciklusa u trajanju od 24 sata za kutove kuboida, za dobivanje atmosferskih uvjeta za određeni dan provodi se trilinearna interpolacija dobivenih simuliranih polja tako da se najprije svakoj od simulacija pridruži odgovarajući težinski faktor te na kraju otežani srednjak tih 8 simulacija predstavlja uvjete specifičnog dana. Težinski faktori se računaju za svaki dan posebno na temelju podataka dugačkog vremenskog niza s lokalne postaje ili podataka iz simulacija modela veće skale te na temelju podataka koje predstavljaju kutovi kuboida (cmax i cmin). Trilineranom interpolacijom nastaju interpolirana polja koja predstavljaju vrijednosti temperature, vjetra i vlažnosti, pomoću dobivenih parametara moguće je računati određene klimatske indekse, npr. iz interpoliranog polja temperature može se dobiti prostorna raspodjela ljetnih dana i vrućih dana (Žuvela-Aloise i sur., 2014). Prikaz računanja težinskih faktora nalazi se u dodatku A.

2.5.2 Postavke modela

Domena modela postavljena je na područje grada Dubrovnika i pokriva površinu veličine 6.8 km x 5.2 km, s ekvidistantnom mrežom rezolucije 100 m. Za pokretanje modela korišteni su podaci klasifikacije zemljišnog pokrova/korištenja zemljišta (Land Use/Land Cover, LULC), meteorološki podaci s lokalne postaje u Dubrovniku i topografija terena. Na slici 2.1 nalazi se prikaz domene modela i LULC klasifikacija domene. Domena je definirana pomoću 30 različitih klasa, a svakoj ćeliji domene dodijeljena je odgovarajuća klasa.

Na slici 2.1a) satelitski je prikazano dubrovačko područje i domena modela MUKLIMO_3, a na slici 2.1b) prikazana je LULC klasifikacija domene. Slika 2.2 prikazuje detaljan opis LULC klasa.



Slika 2.1 a) Satelitski prikaz dubrovačkog područja, crveni okvir prikazuje područje domene modela MUKLIMO_3. **b)** Prikaz LULC klasifikacije domene.



Slika 2.2: Detaljan opis LULC klasa.

U Tablici 1. prikazani su udjeli pojedine LULC klase u ukupnoj površini domene. Iz tablice se vidi da najveći udio površine domene zauzimaju vode (u ovom slučaju more, 32.86%), šume (27.52%) i površine s oskudnom vegetacijom/stijene (10.01%). More prekriva najveći dio domene, dok šume prevladavaju na istočnom dijelu domene, a površina s oskudnom vegetacijom/stijenama prevladava u središnjem dijelu domene, tj. iznad grada. Od klasa neprirodnog porijekla najveći udio površine zauzimaju nekontinuirane guste urbane površine (7.18%) i kontinuirane urbane površine (2.21%) koje prevladavaju na središnjem i sjevernom dijelu domene, uz obale mora.

Tablica 1. Udjeli pojedinih LULC klasa u ukupnoj površini domene, od najvećeg do najmanjeg.

LULC klasa (opis klase)	BROJ ĆELIJA	UDIO u ukupnoj površini [%]
31 (vode)	1162	32.86
28 (šume)	973	27.52
36 (oskudna vegetacija/stijene)	354	10.01
29 (nepoljoprivredne biljne asocijacije)	353	9.98
2 (guste urbane površine)	254	7.18
1 (kontinuirane urbane površine)	78	2.21
9 (poslovni prostori)	68	1.92
27 (poljoprivredne površine)	67	1.89
3 (urbane površine srednje gustoće)	42	1.19
26 (poljoprivredne površine)	39	1.10
21 (parkovi, zelene površine)	26	0.74
7 (stara gradska jezgra)	19	0.54
4 (urbana površina male gustoće)	18	0.51
11 (javne ustanove)	15	0.42
15 (parkirališta, garaže)	11	0.31
24(sadržaji za sport i rekreaciju bez gradnje)	11	0.31
34 (luke s pripadajućim zemljištem)	11	0.31
5 (urbane površine vrlo male gustoće)	6	0.17
18 (rudokopi, odlagališta otpada)	4	0.11
33 (stjenovite obale)	4	0.11
14 (prometnice s pripadajućim zemljištem)	3	0.08
19 (gradilišta)	3	0.08
30 (močvare)	3	0.08
10 (trgovački centri)	2	0.06
20 (zemljišta bez trenutne namjene)	2	0.06
22 (groblja)	2	0.06
23 (sadržaji za sport i rekreaciju s gradnjom)	2	0.06
25 (livade i pašnjaci)	2	0.06
13 (energetska i vodnogosp. infrastruktura)	1	0.03
35 (erodirane površine s vegetacijom)	1	0.03
UKUPNO	3536	100.00

Za primjenu kubodine metode za ulazne podatke korišteni su podaci s meteorološke postaje Dubrovnik u razdoblju 1981.-2010. (temperatura zraka, relativna vlažnost i brzina vjetra). S obzirom da nas zanima toplinsko opterećenje grada, kao donja granica za temperaturu uzeto je $T_{min} = 15°C$, tako da je trilinearna interpolacija napravljena za sve dane u promatranom razdoblju u kojima je temperatura veća od T_{min}. Simulacije su napravljene za dva prevladavajuća smjera vjetra, u ovom slučaju je to sjeveroistočni i jugozapadni te je dobiven set podataka za cijelo razdoblje. Iz dobivenih interpoliranih temperaturnih polja izračunati su prosječni godišnji klimatski indeksi za razdoblje 2001.-2010. Ovo razdoblje je odabrano kako bi simulacije bile što realniji prikaz referentne LULC klasifikacije domene koja je napravljena prema morfološkim karakteristikama grada Dubrovnika iz 2012. godine.

2.6 Obrada podataka

Rezultati modela MUKLIMO_3 obrađeni su i vizualno prikazani pomoću geografsko informacijskog sustava (eng. *geographic information system,* GIS) i programskog jezika *Python*. Korištenjem GIS-a vizualno su na prostoru domene prikazani prosječni godišnji brojevi dana pojedinog klimatskog indeksa dobivenog za razdoblje 2001.-2010. na rezoluciji od 100 m. Osim prostorne, napravljena je i analiza klimatskih indeksa prema klasama kako bi se bolje proučile karakteristike toplinske opterećenosti pojedinih klasa, a za to je korišten programski jezik *Python*, tj. pripadajući paket *matplotlib*. Za prikaz prosječne ljetne površinske temperature (eng. *land surface temperature*, LST) u razdoblju 2001.-2010. na promatranoj domeni korištene su sve dostupne snimke satelita LANDSAT5 za sezone JJA u tom razdoblju. Ljetna prosječna površinska temperatura je prikazana jer se ljeti bilježe najviše temperature pa se tada očekuje i najveća toplinska opterećenost grada. Za obradu satelitskih snimki koristila se online dostupna platforma Google Earth Engine (GEE) pomoću koje su se obradile satelitske snimke LST-ja te su rezultati vizualno prikazani korištenjem GIS-a. GEE je online platforma za analizu geoprostornih podataka koja se temelji na pohrani podataka na vlastiti *oblak* te omogućava analizu slika upotrebom različitih funkcija unutar *JavaScript* programskog jezika (Gorelick i sur., 2017) koji je korišten za kreiranje koda u ovom radu. Dobivena je raspodjela prosječnog LST-ja na

rezoluciji 100 m i prikazana je na istoj domeni kao i za model MUKLIMO_3 kako bi rezultati bili međusobno usporedivi.

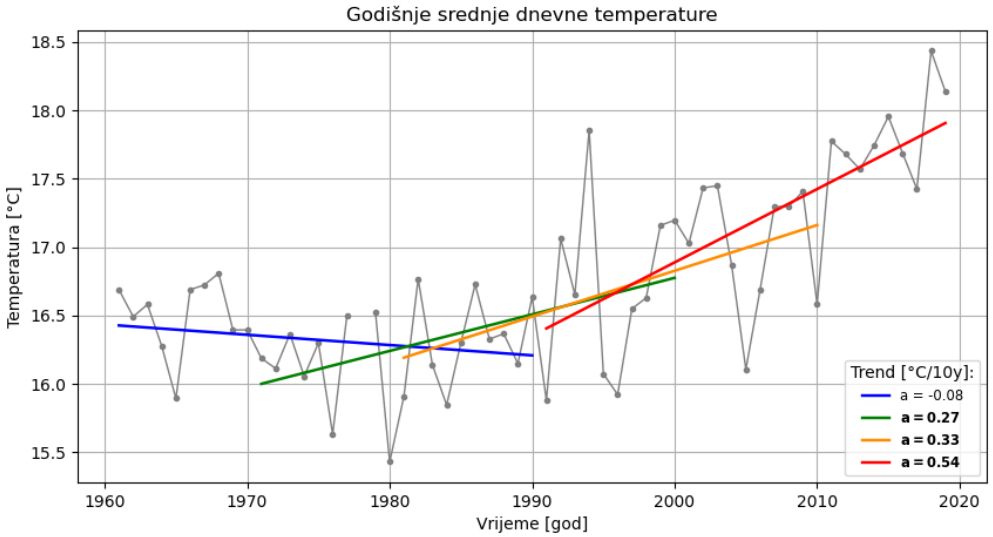
3. Rezultati i diskusija

3.1. Temperaturna obilježja Dubrovnika – izmjereni podaci

Za analizu temperaturnih obilježja Dubrovnika najprije su analizirani podaci o temperaturi izmjerenoj na meteorološkoj postaji Dubrovnik u razdoblju 1961.-2019.

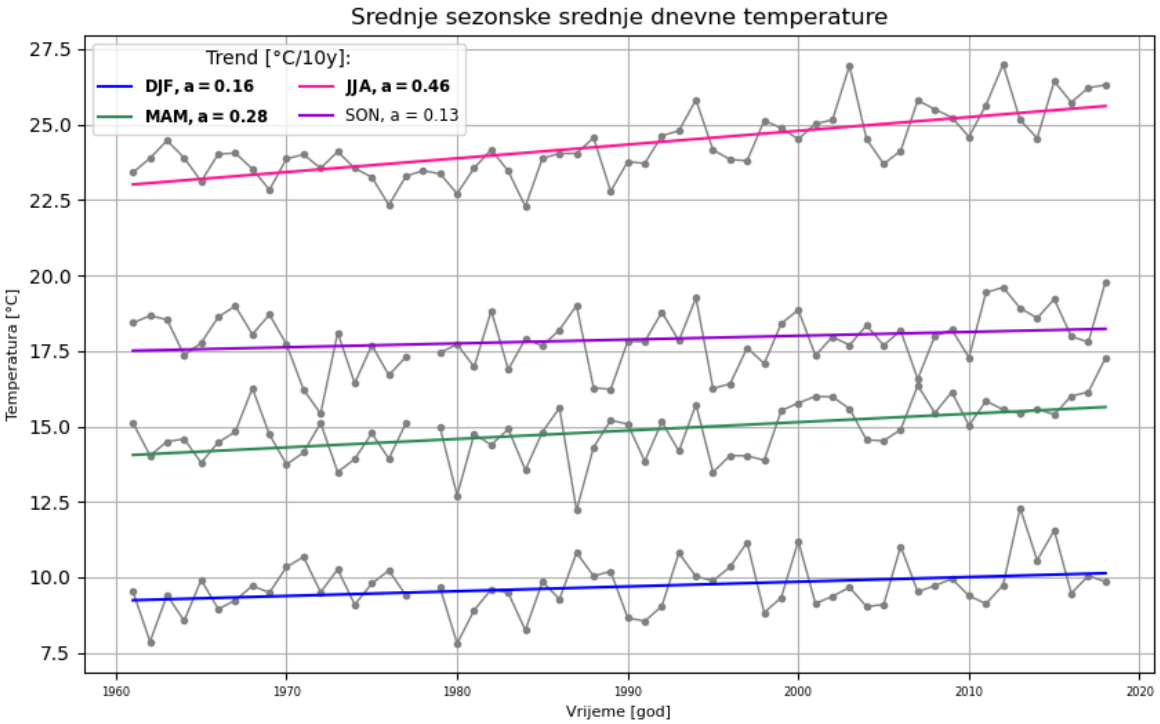
3.1.1. Promjene temperature zraka u Dubrovniku

Godišnje srednje dnevne temperature u razdoblju 1961.-2019. prikazane su na slici 3.1. U promatranom razdoblju uočava se osciliranje temperature, ali može se primjetiti porast u prikazanom vremenskom razdoblju. Radi detaljnije analize uočenog porasta temperature, metodom linearne regresije izračunati su i grafički prikazani trendovi 30-godišnjih klimatoloških razdoblja. Za prvo promatrano razdoblje, 1961.-1990., dobiven je blagi silazni trend godišnje srednje dnevne temperature što ukazuje na smanjenje temperature u ovom razdoblju. Međutim, uporabom MK testa dobiveno je da u ovom vremenskom nizu podataka nema statistički značajnog trenda. U vremenskim nizovima podataka u daljnjim razdobljima (1971.-2000., 1981.-2010., 1991.-2019.) MK testom je dobiveno da postoje statistički značajni trendovi ($p_{(1971.-2000.)} = 0.008$, $p_{(1981.-2010.)} = 0.003$, $p_{(1991.-2019.)} = 3.991e^{-5}$). Metodom linearne regresije osim za prvo promatrano razdoblje (1961.-1990.) dobiveni su uzlazni trendovi koji pokazuju da se godišnja srednja dnevna temperatura u Dubrovniku u posljednjih 50-ak godina povećala. Prema dobivenim rezultatima iznosa trendova vidljivo je da se i brzina porasta godišnje srednje dnevne temperature povećava. U razdoblju 1971.-2000. porast temperature iznosio je 0,27 $℃\ (10y)^{-1}$, u idućem razdoblju, porast iznosi 0,33 $°C\ (10y)^{-1}$, dok je u posljednjem promatranom razdoblju, 1991.-2019. zabilježen veliki porast od 0,54 $℃\ (10y)^{-1}$. Ovi rezultati ukazuju da temperatura u Dubrovnku ubrzano raste.



Slika 3.1. : Godišnje srednje dnevne temperature za meteorološku postaju Dubrovnik s analizom trendova 30-godišnjih klimatoloških razdoblja. S lijeva na desno redom počevši od razdoblja 1961.-1990. (plava boja), 1971.-2000. (zelena boja), 1981.-2010. (narančasta boja) i 1991.-2019. (crvena boja). U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

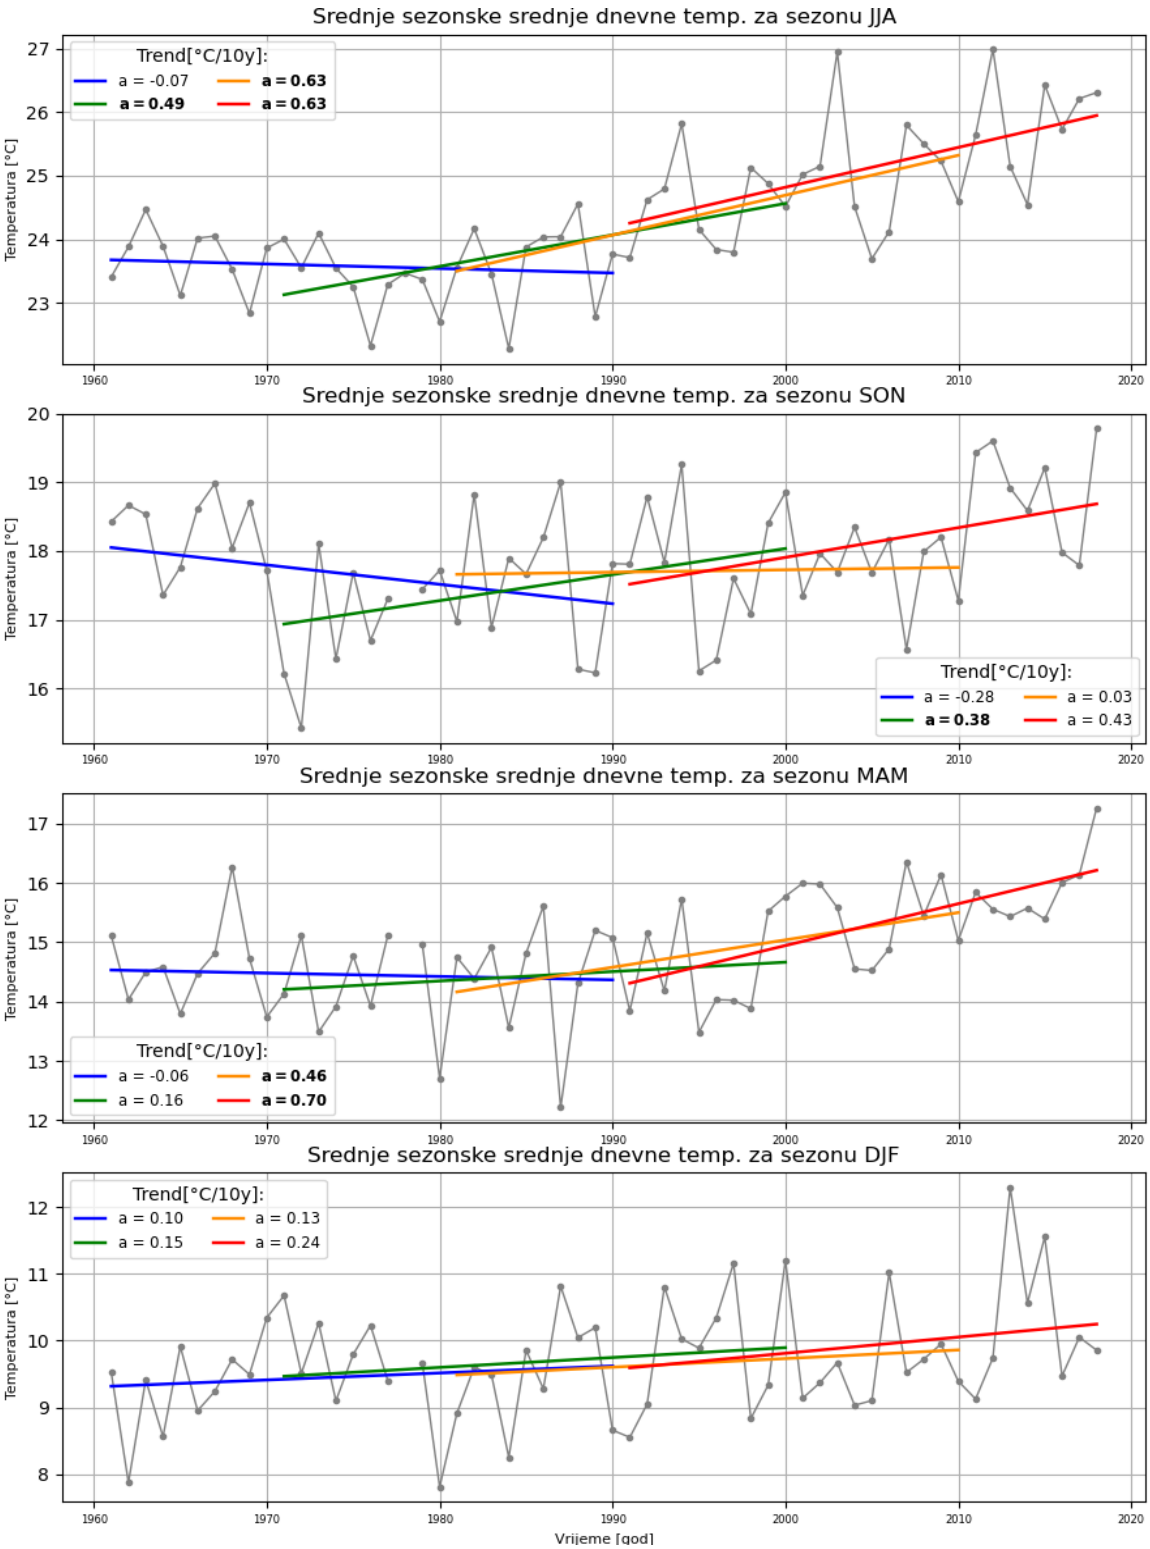
Na slici 3.2 prikazane su srednje sezonske vrijednosti srednjih dnevnih temperatura izračunate za svaku godinu te je za svaku od sezona napravljena analiza trenda. Osim za sezonu SON, u podacima za ostale sezone MK test je pokazao da postoje statistički značajni trendovi ($p_{DJF} = 0.041, p_{MAM} = 6.389e^{-5}, p_{JJA} = 1.622e^{-8}, p_{SON} = 0.088$). Iznosi trendova dobiveni metodom linearne regresije su pozitivni, stoga se može reći da dolazi do porasta srednjih dnevnih temperatura u svakoj sezoni. Prema iznosima trendova vidljivo je da se najveći porast, iznosa $0.46\,℃\,(10y)^{-1}$, bilježi u ljetnoj sezoni JJA kada se i očekuju najveće srednje dnevne temperature u godini. Najblaži trend porasta dobiven je za sezonu DJF, $0.16\,℃\,(10y)^{-1}$, dok je za sezonu MAM izračunati trend $0.28\,℃\,(10y)^{-1}$. Iz ovih rezultata vidljivo je da su srednje dnevne temperature zimi u Dubrovniku u blagom porastu dok u proljeće i ljeto više rastu.



Slika 3.2: Srednje sezonske srednje dnevne temperature za meteorološku postaju Dubrovnik s trendom za razdoblje 1961.-2018. U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

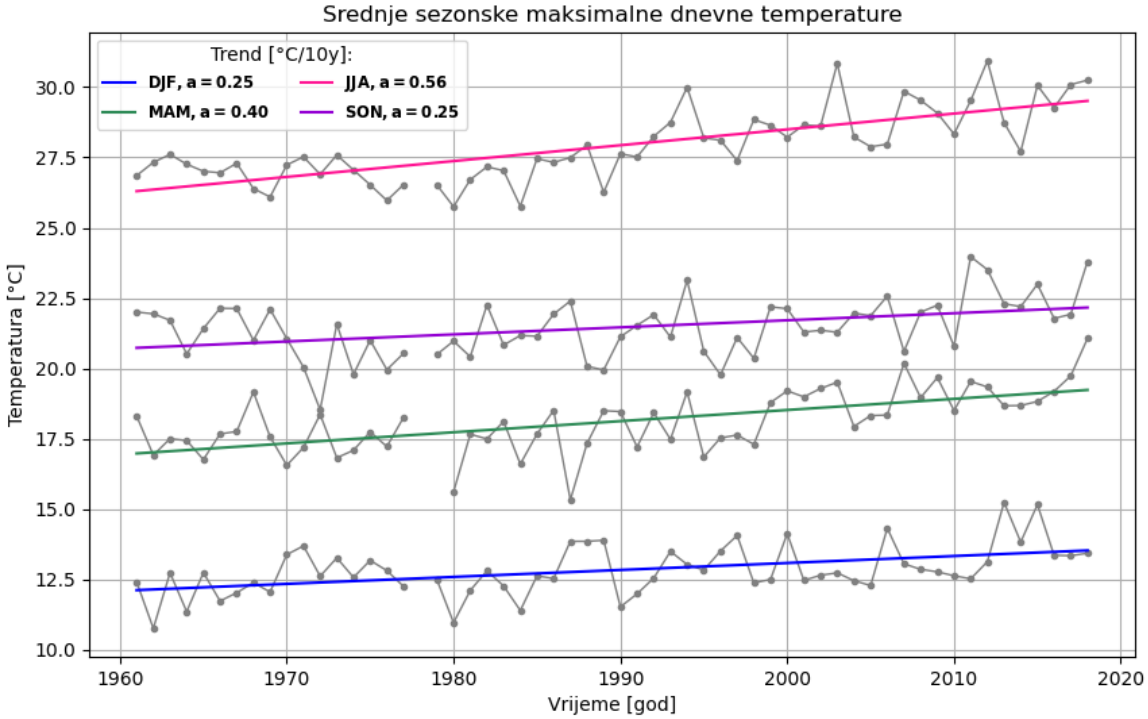
Detaljnija analiza trendova za svaku od sezona nalazi se na slici 3.3. gdje je analiza trendova po 30-godišnjim razdobljima prikazana za svaku sezonu zasebno. Na prethodnoj slici (slika 3.2) pokazano je da srednje dnevne temperature najbrže rastu u sezoni JJA. U ovoj sezoni prema MK testu u vremenskom nizu podataka za razdoblje 1961.-1990., nema statistički značajnog trenda, dok u vremenskim nizovima ostalih razdoblja postoji statistički značajan trend ($p_{(1961.-1990.)} = 0.775, p_{(1971.-2000.)} = 0.002, p_{(1981.-2010.)} = 0.001, p_{(1991.-2018.)} = 0.004$). Detaljnijim proučavanjem dinamike porasta temperatura u sezoni JJA po 30-godišnjim razdobljima, metodom linearne regresije dobiveno je da se porast srednjih dnevnih temperatura ubrzava (slika 3.3). U posljednjem razmatranom razdoblju, 1991.-2018., porast je iznosio $0.63\ ℃\ (10y)^{-1}$, jednako kao i u razdoblju 1981.-2010., dok je u razdoblju 1971.-2000. bio također pozitivan, ali manjeg iznosa $0.49\ ℃\ (10y)^{-1}$. Prema tome, ljetne srednje dnevne temperature ubrzano rastu. U sezoni SON, statistički značajan trend dobiven je samo za razdoblje 1971.-2000. ($p_{(1961.-1990.)} = 0.187, p_{(1971.-2000.)} =$

$0.038, p_{(1981.-2010.)} = 0.748, p_{(1991.-2018.)} = 0.050$). Unatoč tome, taj trend je prema metodi linearne regresije pozitivan i pokazuje da su i u sezoni SON temperature u razdoblju 1971.-2000. rasle. Za sezonu MAM statistički značajni trendovi prema MK testu dobiveni su u razdobljima 1981.-2010. i 1991.-2018. ($p_{(1961.-1990.)} = 0.858, p_{(1971.-2000.)} = 0.284, p_{(1981.-2010.)} = 0.027, p_{(1991.-2018.)} = 0.002$). Iznos trenda prema metodi linearne regresije u razdoblju 1981.-2010. iznosi 0.46 $℃(10y^{-1})$, manji je od iznosa trenda u razdoblju 1991.-2018. koji iznosi 0.70 $℃(10y^{-1})$. Stoga se, kao i za sezonu JJA, ovdje također bilježi porast trenda u vremenu koji ukazuje da se porast proljetnih temperatura ubrzava. Za sezonu DJF, MK testom nisu pronađeni statistički značajni trendovi u promatranim vremenskim nizovima podataka ($p_{(1961.-1990.)} = 0.592, p_{(1971.-2000.)} = 0.372, p_{(1981.-2010.)} = 0.392, p_{(1991.-2018.)} = 0.161$), iako su metodom linearne regresije dobiveni pozitivni iznosi trendova koji upućuju na ubrzani porast temperature. Iz analize srednjih sezonskih srednjih dnevnih temperatura po sezonama može se zaključiti da se porast temperatura u sezonama MAM i JJA ubrzava, dok za nizove podataka u sezonama SON (osim u razdoblju 1971.-2000.) i DJF prema MK testu nisu pronađeni statistički signifikantni trendovi na nivou značajnosti $\alpha = 0.05$, premda je metodom linearne regresije dobiveno da dolazi do ubrzavanja rasta temperature.



Slika 3.3: Srednje sezonske srednje dnevne temperature za meteorološku postaju Dubrovnik s trendovima 30-godišnjih klimatoloških razdoblja. S lijeva na desno redom počevši od razdoblja 1961.-1990. (plava boja), 1971.-2000. (zelena boja), 1981.-2010. (narančasta boja) i 1991.-2018. (crvena boja). U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

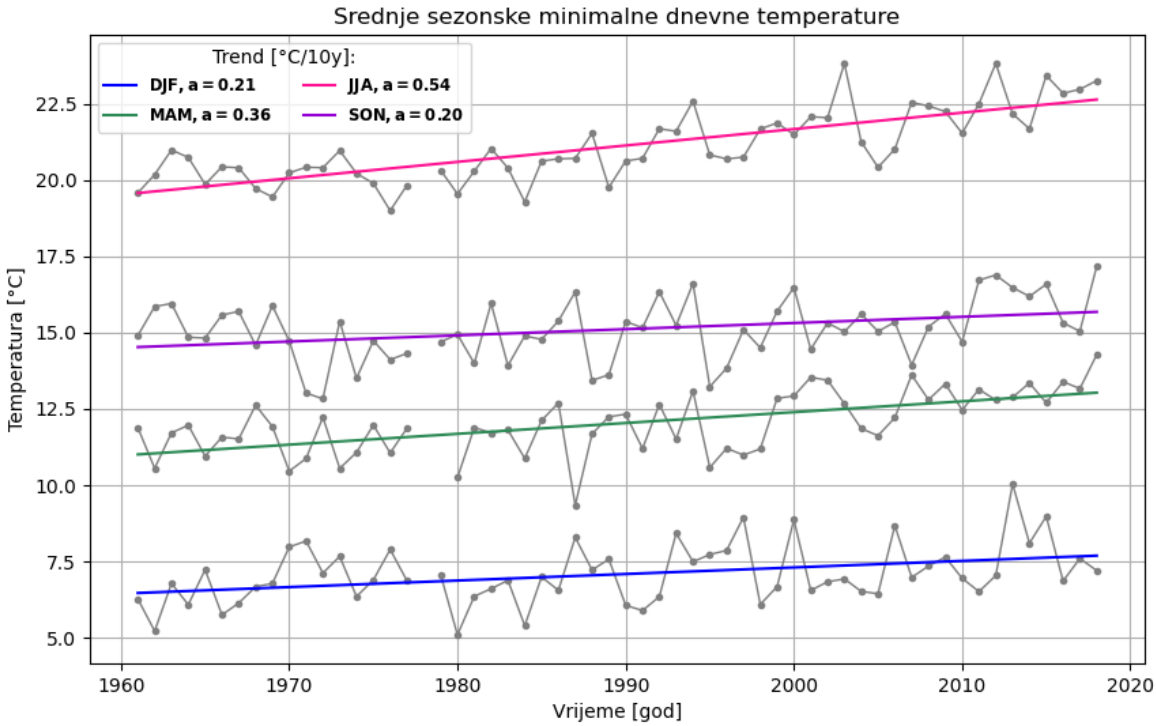
Na slici 3.4 prikazane su srednje sezonske maksimalne dnevne temperature. Za svaku sezonu provjereno je MK testom postoji li u promatranom vremenskom nizu podataka statistički signifikantan trend te je za svaku sezonu dobiveno da postoji takav trend $(p_{DJF} = 0.001, p_{MAM} = 2.673e^{-7}, p_{JJA} = 4.056e^{-10}, p_{SON} = 0.004)$. Prema metodi linearne regresije u promatranom razdoblju za svaku od sezona zabilježen je pozitivan trend maksimalnih dnevnih temperatura, tj. njihov porast. Iz ovog grafičkog prikaza vidljivo je da je najveći trend porasta 0.56 $℃\ (10y)^{-1}$ zabilježen za sezonu JJA. Nakon toga slijedi trend za sezonu MAM s iznosom od 0.40 $℃\ (10y)^{-1}$, a sezone SON i DJF imaju trendove istog iznosa od 0.25 $℃\ (10y)^{-1}$. Ovdje je važno uočiti kako upravo ljetne maksimalne temperature koje su i inače najvećeg iznosa pokazuju najveći porast.



Slika 3.4: Srednje sezonske maksimalne dnevne temperature za meteorološku postaju Dubrovnik s trendom za razdoblje 1961.-2018. U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

Srednje sezonske minimalne dnevne temperature prikazane su na slici 3.5. Za svaku od sezona u promatranom nizu MK testom pronađen je statistički signifikantan trend $(p_{DJF} = 0.006, p_{MAM} = 1.235e^{-6}, p_{JJA} = 8.77e^{-11}, p_{SON} = 0.013)$ te su metodom linearne regresije dobiveni pozitivni trendovi. U cjelokupnom promatranom razdoblju u svim je sezonama vidljivo da se srednje sezonske dnevne minimalne temperature

povećavaju. Kao i u prethodnom slučaju na slici 3.4, zabilježen je najveći trend porasta 0.54 $℃\ (10y)^{-1}$ u sezoni JJA, zatim slijedi sezona MAM s trendom od 0.36 $℃\ (10y)^{-1}$ te sezone SON i DJF s opet podjednakim iznosima trendova (0.20 $℃\ (10y)^{-1}$, tj. 0.21 $°C\ (10y)^{-1}$).

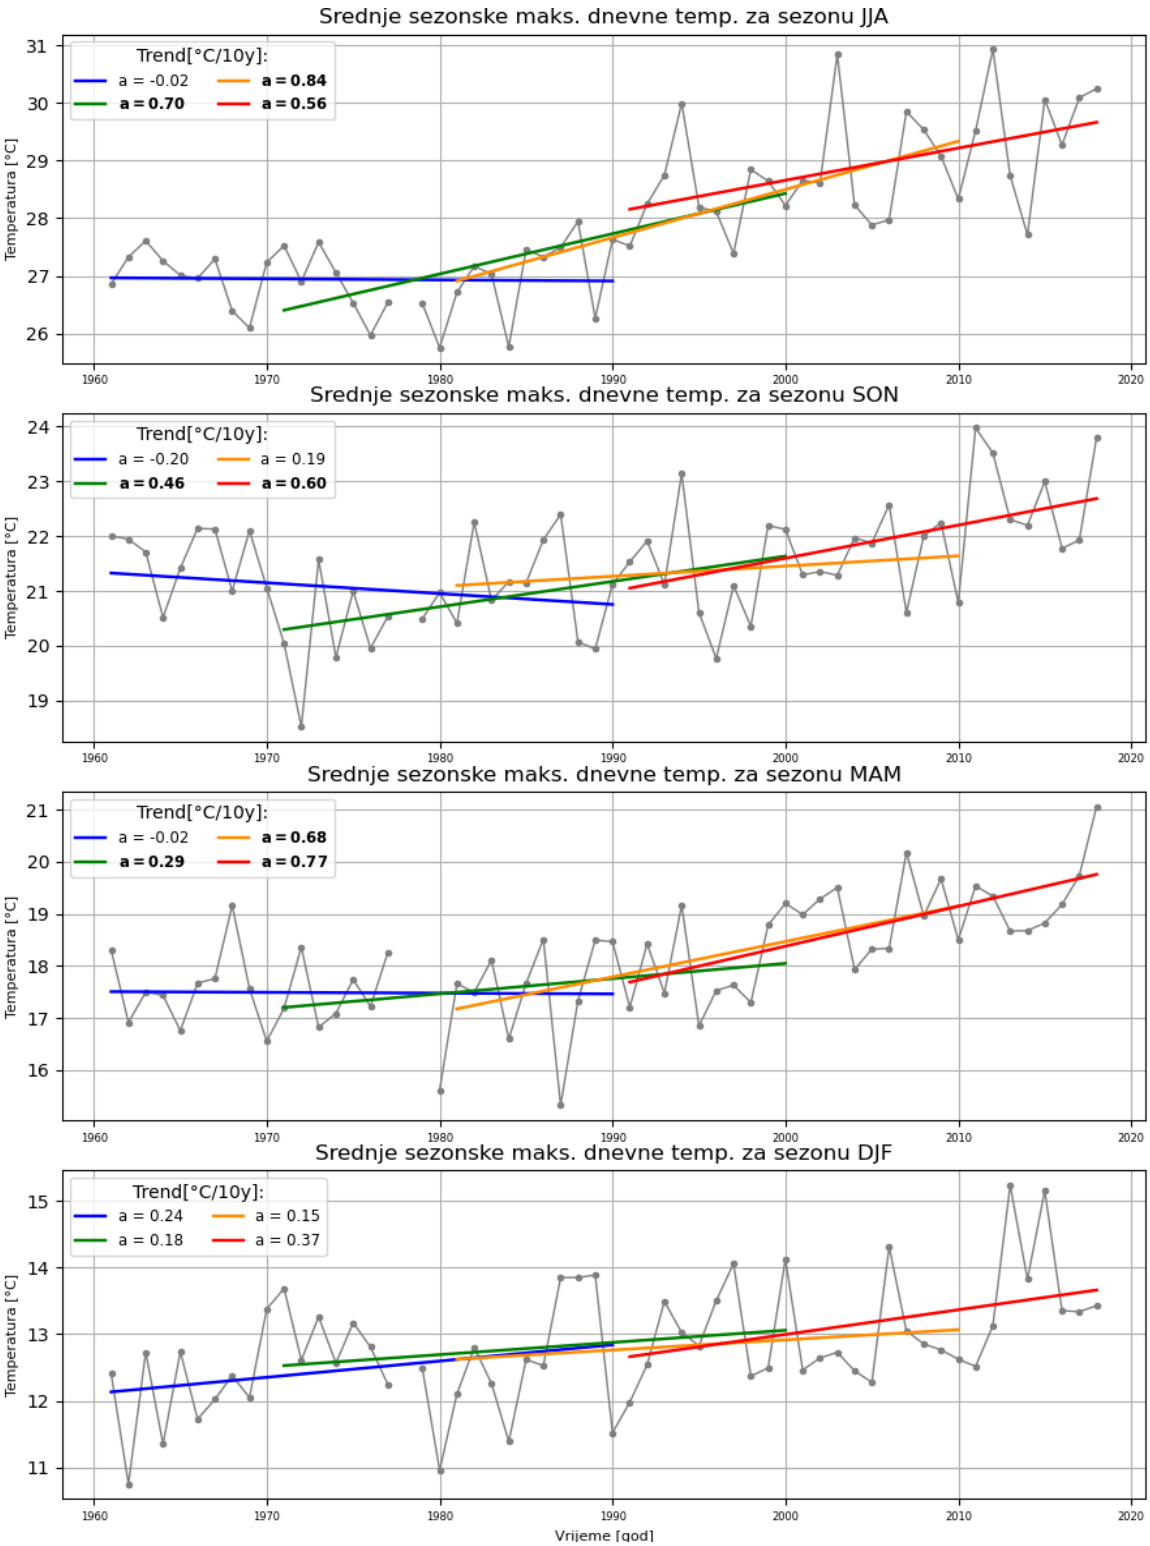


Slika 3.5: Srednje sezonske minimalne dnevne temperature za meteorološku postaju Dubrovnik s trendom za cjelokupno promatrano razdoblje, 1961.-2018. U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

Usporedbom rezultata prikazanih na slikama 3.4 i 3.5 uočavaju se slične karakteristike između srednjih sezonskih maksimalnih i minimalnih dnevnih temperatura. U oba slučaja u promatranom razdoblju došlo je do porasta temperatura u svim sezonama. Ipak, prema izračunatim iznosima trendova za svaku od sezona, vidljivo je da se maksimalne dnevne temperature povećavaju nešto brže od minimalnih dnevnih temperatura. Nadalje, najveći trend porasta promatranih temperatura zabilježen je za sezonu JJA što ukazuje da se ljeti i maksimalne i minimalne temperature u posljednjih 50-ak godina brže povećavaju nego u ostalim sezonama.

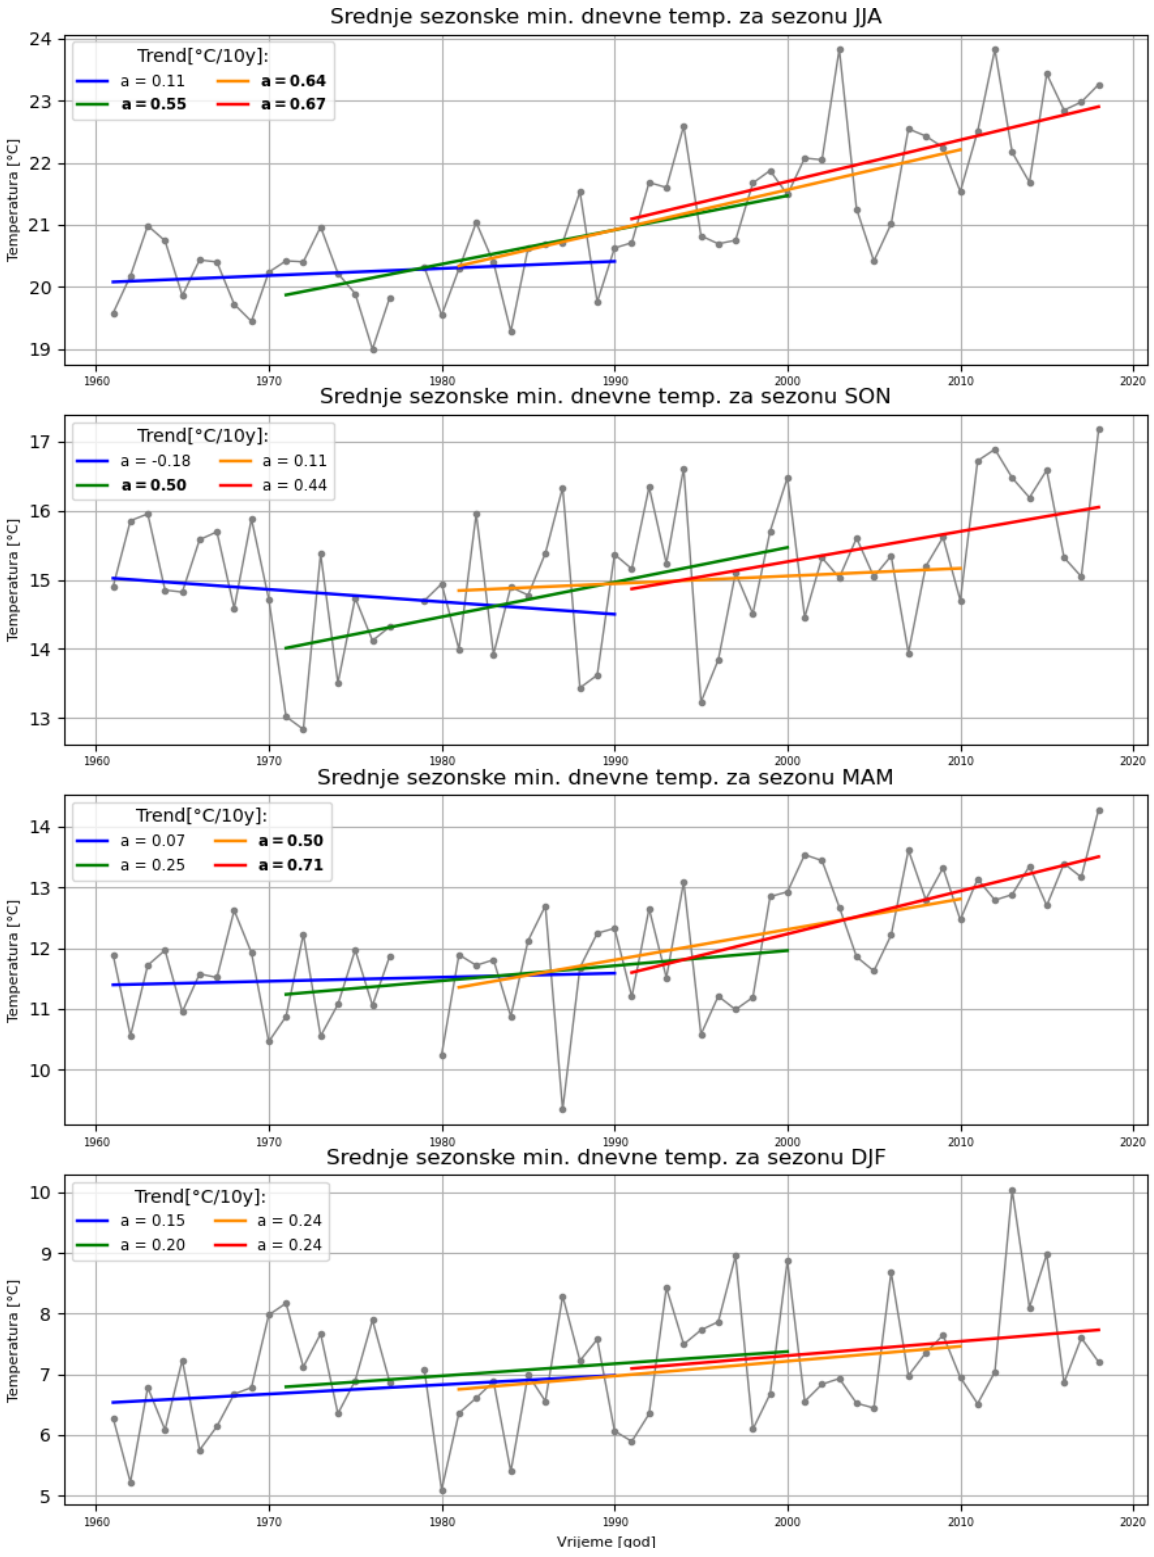
Na slici 3.6 prikazane su srednje sezonske maksimalne dnevne temperature za svaku sezonu zasebno te je napravljena analiza trendova po 30-godišnjim razdobljima.

Za sezonu JJA dobiveno je MK testom da u nizu podataka u razdoblju 1961.-1990. nema statistički signifikantnog trenda ($p_{(1961.-1990.)} = 1.0$), dok u podacima ostalih razdoblja ima ($p_{(1971.-2000.)} = 0.000, p_{(1981.-2010.)} = 3.486e^{-5}, p_{(1991.-2018.)} = 0.017$). Iz dobivenih vrijednosti trendova metodom linearne regresije pokazuje se da se u prva tri promatrana razdoblja bilježi povećanje trenda, tj. porast temperature je ubrzan. Međutim, u posljednjem razdoblju, 1991.-2018., trend je pozitivan ($0.56\ ℃\ 10y^{-1}$), ali je ublažen u odnosu na trendove u prethodnim razdobljima. Za sezonu SON značajni trendovi su dobiveni za razdoblje 1971.-2000. ($p_{(1971.-2000.)} = 0.038$) i 1991.-2018. ($p_{(1991.-2018.)} = 0.014$). U oba navedena razdoblja prema metodi linearne regresije trend je pozitivan, bilježi se povećanje maksimalne dnevne temperature, s time da je iznos trenda veći u posljednjem razmatranom razdoblju što ukazuje na ubrzani porast jesenskih maksimalnih temperatura. U prikazu rezultata za sezonu MAM, za svako razdoblje kronološkim redom, bilježi se porast iznosa trenda što ukazuje da i proljetne temperature ubrzano rastu. U podacima svih vremenskih nizova za sezonu MAM, MK testom je dobiveno da postoji statistički značajan trend ($p_{(1971.-2000.)} = 0.044, p_{(1981.-2010.)} = 0.002, p_{(1991.-2018.)} = 0.000$), izuzev trenda za razdoblje 1961.-1990. ($p_{(1961.-1990.)} = 0.817$) dok je u nizovima sezone DJF dobiveno da prema MK testu nema statistički značajnih trendova niti u jednom od razmatranih razdoblja $\left(p_{(1961.-1990.)} = 0.212, p_{(1971.-2000.)} = 0.239, p_{(1981.-2010.)} = 0.239, p_{(1991.-2018.)} = 0.061\right)$, premda su metodom linearne regresije dobiveni pozitivni iznosi trendova koji ukazuju na porast temperature.



Slika 3.6: Srednje sezonske maksimalne dnevne temperature za meteorološku postaju Dubrovnik s analizom trendova 30-godišnjih klimatoloških razdoblja. S lijeva na desno redom počevši od razdoblja 1961.-1990. (plava boja), 1971.-2000. (zelena boja), 1981.-2010. (narančasta boja) i 1991.-2018. (crvena boja). U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

Slika 3.7 prikazuje srednje sezonske minimalne dnevne temperature za svaku sezonu zasebno s pripadnom analizom trendova po 30-godišnjim razdobljima. Osim za razdoblje 1961.-1990., MK testom dobiveno je da u promatranim vremenskim nizovima postoji statistički signifikantan trend ($p_{(1961.-1990.)} = 0.475, p_{(1971.-2000.)} = 0.000, p_{(1981.-2010.)} = 0.000, p_{(1991.-2018.)} = 0.002$). Za razliku od maksimalnih dnevnih temperatura u sezoni JJA, prema iznosima trendova dobivenih metodom linearne regresije minimalne dnevne temperature rastu sve brže, iznos trenda povećava se u pozitivnom smjeru za svako novo promatrano razdoblje, tako je za razdoblje 1991.-2018. iznos izračunatog trenda najveći ($0.67\ ℃\ (10y)^{-1}$). Za sezonu SON dobiveno je da statistički značajan trend postoji samo u razdoblju 1971.-2000. $\left(p_{(1961.-1990.)} = 0.284, p_{(1971.-2000.)} = 0.015, p_{(1981.-2010.)} = 0.617, p_{(1991.-2018.)} = 0.066\right)$, koji je prema rezultatima linearne regresije pozitivan i ukazuje na porast minimalnih dnevnih temperatura u tom razdoblju. Slična obilježja kao i kod maksimalnih dnevnih temperatura pokazuju rezultati za sezonu MAM. Pri tome u podacima za prva dva razdoblja, 1961.-1990. i 1971.-2000., uporabom MK testa, nema statistički signifikantnih trendova $\left(p_{(1961.-1990.)} = 0.580, p_{(1971.-2000.)} = 0.072, p_{(1981.-2010.)} = 0.022, p_{(1991.-2018.)} = 0.002\right)$. Na slici su vidljivi uzlazni trendovi u posljednja dva promatrana razdoblja dobiveni metodom linearne regresije te se uočava povećanje iznosa trenda u vremenu što kao i kod maksimalnih temperatura pokazuje da se minimalne temperature u sezoni MAM sve brže povećavaju. Za promatrane nizove temperature u sezoni DJF, kao i pri analizi za maksimalne dnevne temperature, prema MK testu nema statistički značajnih trendova $\left(p_{(1961.-1990.)} = 0.354, p_{(1971.-2000.)} = 0.335, p_{(1981.-2010.)} = 0.164, p_{(1991.-2018.)} = 0.213\right)$, iako su metodom linearne regresije dobivene pozitivne vrijednosti trendova koje ukazuju na porast temperatura u promatranim razdobljima, kao i na ubrzavanje rasta minimalnih DJF sezonskih temperatura.

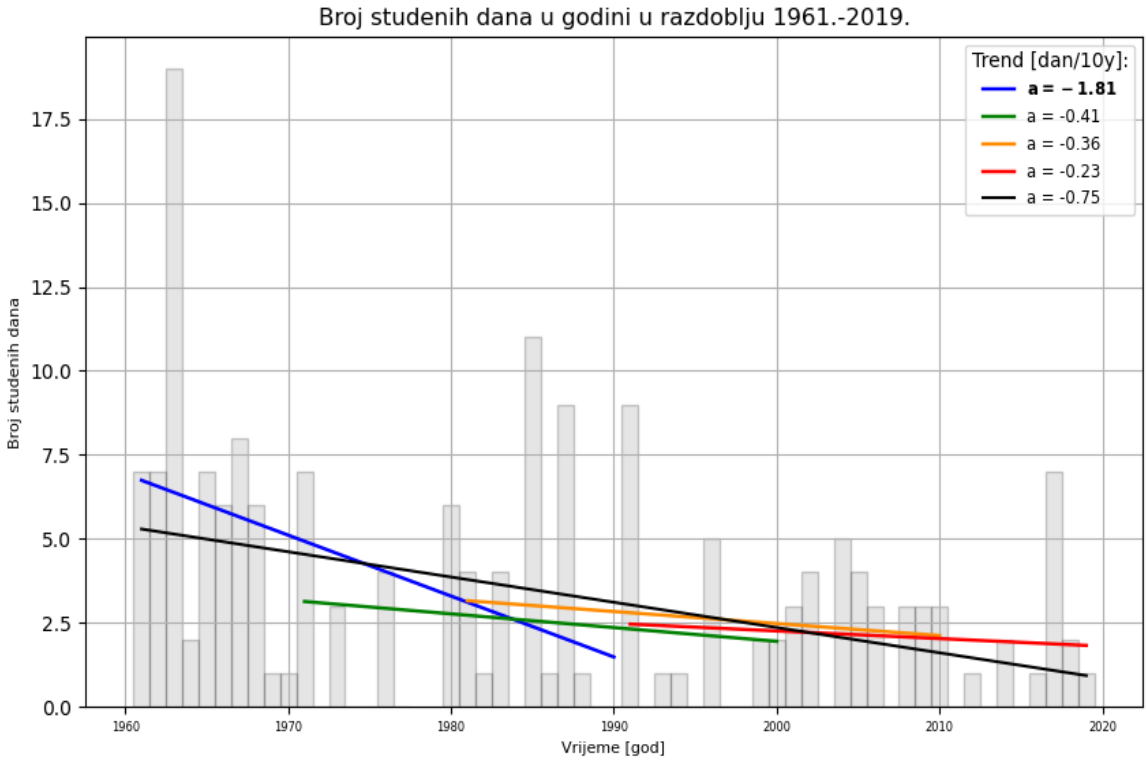


Slika 3.7: Srednje sezonske minimalne dnevne temperature za meteorološku postaju Dubrovnik s trendovima 30-godišnjih klimatoloških razdoblja. S lijeva na desno redom počevši od razdoblja 1961.-1990. (plava boja), 1971.-2000. (zelena boja), 1981.-2010. (narančasta boja) i 1991.-2018. (crvena boja). U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

Prema prethodnim rezultatima može se primjetiti da je u više slučajeva unatoč tome što je metodom linearne regresije dobiveni koeficijent smjera pravca regresije (trenda) različit od nule za isti niz podataka prema MK testu dobiveno je da ne postoji signifikantan trend. Pri tumačenju ovih rezultata u obzir treba uzeti da se moć MK testa povećava s duljinom promatranog uzorka (niza), povećanjem apsolutne vrijednosti trenda te da se povećanjem varijabilnosti uzorka moć testa smanjuje (Yue, Pilon i Cavadias, 2002) što se vidi i u rezultatima ovog rada. Primjerice, analizirajući trendove sezonskih vrijednosti minimalne i maksimalne temperature u razdoblju 1961.-2018. dobiveno je da u tim nizovima prema MK testu postoje signifikantni trendovi te su i prema metodi linearne regresije izračunati koeficijenti smjera pravca regresije različiti od nule. No, pri detaljnijoj analizi svake sezone zasebno, kada su se duljine nizova smanjile na 30-godišnja razdoblja, u više je slučajeva dobiveno da prema MK testu ne postoji signifikantan trend u promatranom nizu, dok je metodom linearne regresije dobiven trend nagiba različitog od nule.

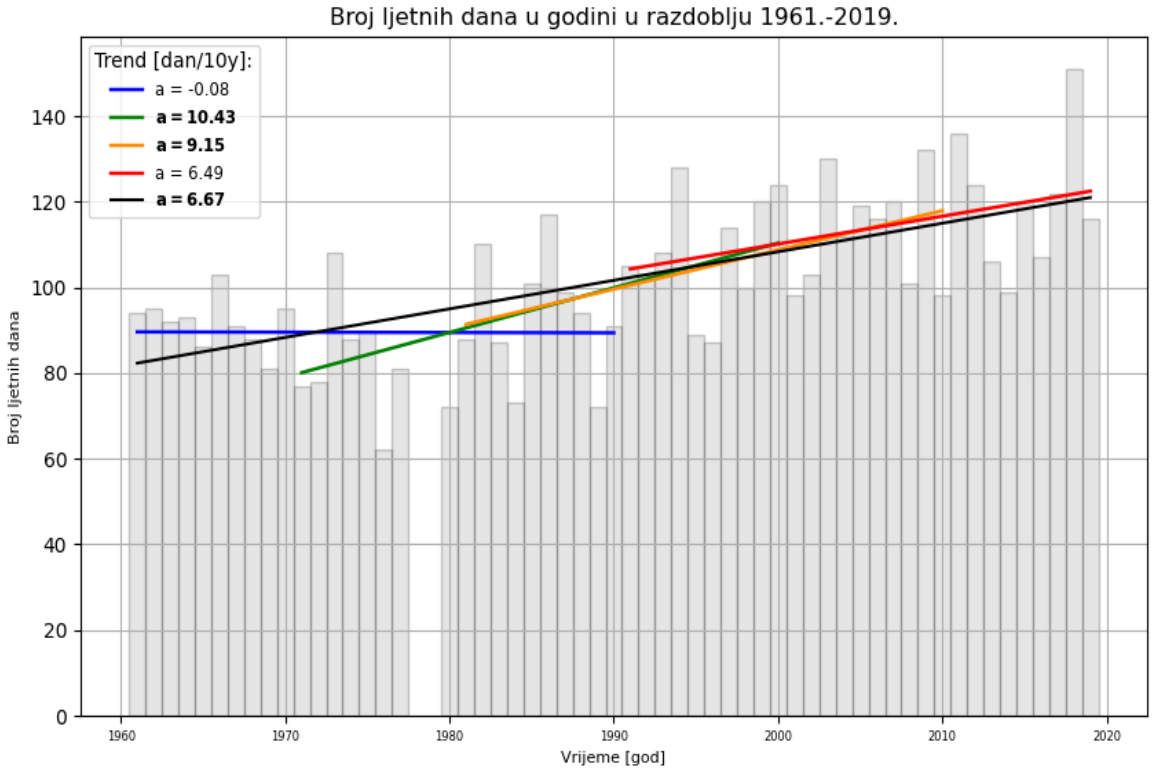
3.1.2. Klimatski indeksi i promjene

Klimatski indeks godišnji broj studenih dana prikazan je na slici 3.8 te je napravljena analiza trendova za cijelo promatrano razdoblje, 1961.-2019. i za 30-godišnja klimatološka razdoblja. Dobiveni rezultati za p-vrijednosti pokazuju da je statistički značajan trend prema MK testu dobiven samo za razdoblje 1961.-1990. ($p_{(1961.-1990.)} = 0.022, p_{(1971.-2000.)} = 1.0, p_{(1981.-2010.)} = 0.841, p_{(1991.-2019.)} = 0.954, p_{(1961.-2019.)} = 0.058$). U tom razdoblju, iznos trenda dobivenog metodom linearne regresije je negativan čime se pokazuje da se godišnji broj studenih dana smanjuje. Dakle, svake godine u tom razdoblju bilo je sve manje dana kada je minimalna dnevna temperatura bila manja od $0\,℃$ iz čega se može zaključiti da je Dubrovnik tada postajao sve topliji kao i zime kada se očekuju najniže temperature. Iako u ostalim razdobljima prema MK testu nema trendova, metodom linearne regresije dobivene su negativne vrijednosti koje također ukazuju da se grad zagrijava i da je sve manje studenih dana.



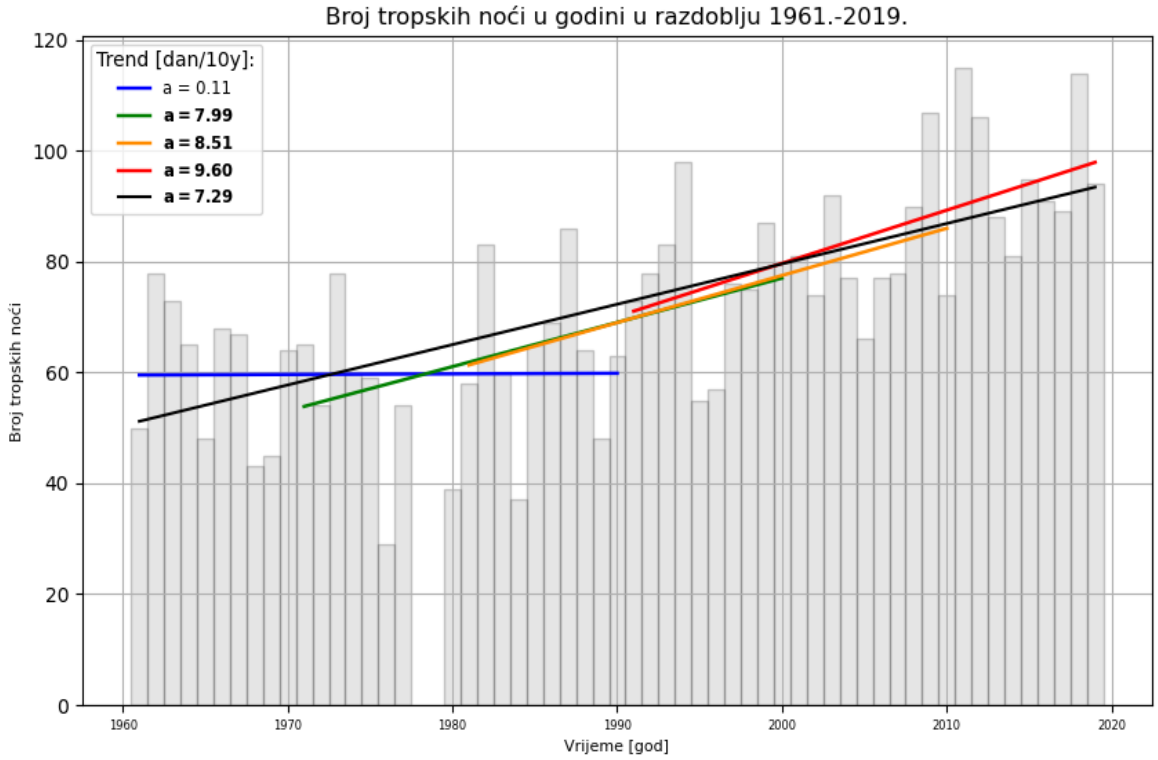
Slika 3.8: Broj studenih dana u godini za meteorološku postaju Dubrovnik s analizom trendova za cjelokupno razdoblje, 1961.-2019. (crna boja), i s trendovima 30-godišnjih klimatoloških razdoblja. S lijeva na desno redom počevši od razdoblja 1961.-1990. (plava boja), 1971.-2000. (zelena boja), 1981.-2010. (narančasta boja) i 1991.-2019. (crvena boja). U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

Na slici 3.9 prikazani su rezultati za godišnji broj ljetnih dana. Statistički značajni trendovi dobiveni su za razdoblja 1971.-2000., 1981.-2010. i 1961.-2019. ($p_{(1961.-1990.)} = 0.464, p_{(1971.-2000.)} = 0.002, p_{(1981.-2010.)} = 0.009, p_{(1991.-2019.)} = 0.077, p_{(1961.-2019.)} = 7.560e^{-7}$) te su metodom linearne regresije dobivene pozitivne vrijednosti trendova u tim razdobljima što govori da se broj dana s maksimalnom dnevnom temperaturom većom od 25 ℃ povećao u pripadnim razdobljima. Najveći iznos trenda, tj. najveći porast broja ljetnih dana zabilježen je u razdoblju 1971.-2000. ($10.43\ dan\ (10y)^{-1}$), dok je u sljedećim razdobljima zabilježen pozitivan trend, ali manjeg iznosa pa se može reći da se godišnji broj ljetnih dana sporije povećava.



Slika 3.9: Broj ljetnih dana u godini za meteorološku postaju Dubrovnik s analizom trendova za cjelokupno razdoblje, 1961.-2019. (crna boja), i s trendovima 30-godišnjih klimatoloških razdoblja. S lijeva na desno redom počevši od razdoblja 1961.-1990. (plava boja), 1971.-2000. (zelena boja), 1981.-2010. (narančasta boja) i 1991.-2019. (crvena boja). U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

Slika 3.10 prikazuje godišnji broj tropskih noći te analizu trendova 30-godišnjih razdoblja i cjelokupnog razmatranog razdoblja. Osim za razdoblje 1961.-1990., MK testom je dobiveno da u promatranim nizovima postoje statistički značajni trendovi ($p_{(1961.-1990.)} = 0.629$, $p_{(1971.-2000.)} = 0.007$, $p_{(1981.-2010.)} = 0.010$, $p_{(1991.-2019.)} = 0.003$, $p_{(1961.-2019.)} = 5.834e^{-8}$). U tim razdobljima trendovi izračunati metodom linearne regresije su pozitivni, a iznos im se povećava sa svakim sljedećim promatranim 30-godišnjim razdobljem počevši od 1971.-2000. Time je pokazano da se broj tropskih noći, tj. broj dana u godini kada je minimalna temperatura veća od 20 ℃ sve brže povećava i da se Dubrovnik ubrzano zagrijava i noću.



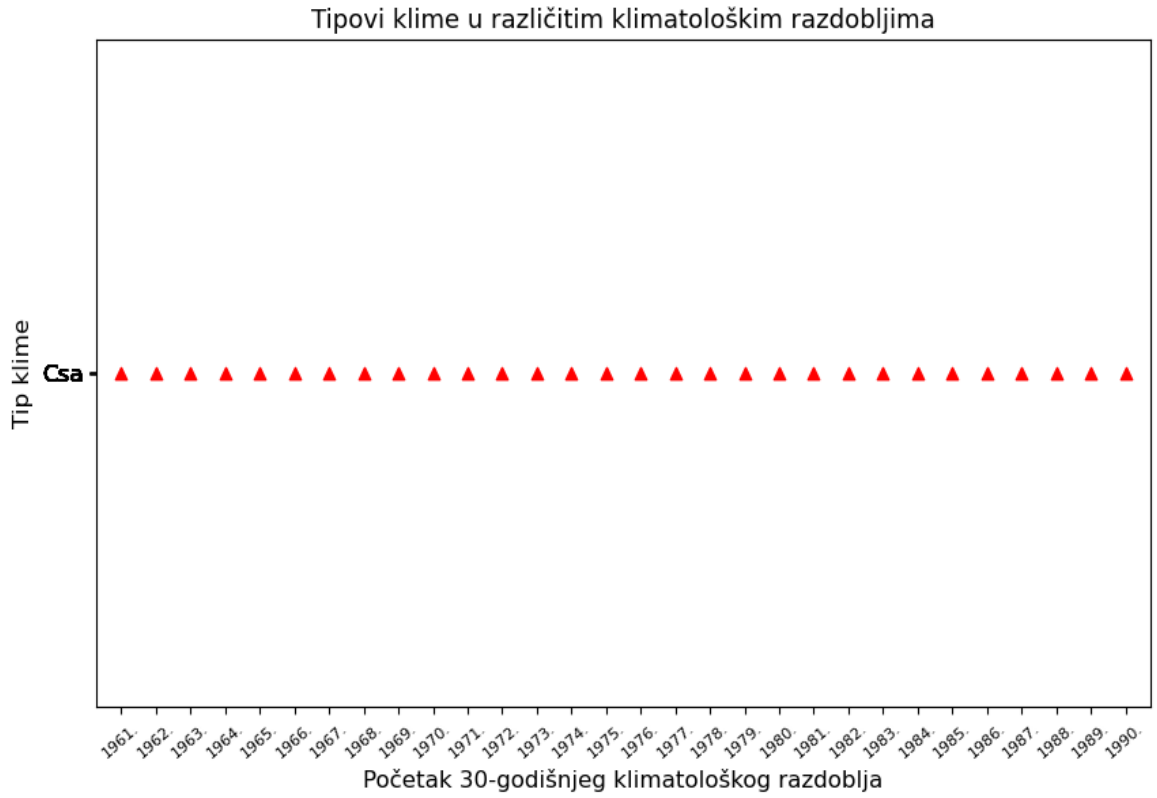
Slika 3.10: Godišnji broj tropskih noći za meteorološku postaju Dubrovnik s analizom trendova za cjelokupno razdoblje, 1961.-2019. (crna boja), i s analizom trendova 30-godišnjih klimatoloških razdoblja. S lijeva na desno redom počevši od razdoblja 1961.-1990. (plava boja), 1971.-2000. (zelena boja), 1981.-2010. (narančasta boja) i 1991.-2019. (crvena boja). U legendi je podebljano otisnuto ako u nizu podataka za pripadno razdoblje prema MK testu postoji statistički signifikantan trend te su prikazani iznosi trendova dobiveni metodom linearne regresije (°C $(10y)^{-1}$).

Analiza ovih klimatskih indeksa ukazuje na ubrzani porast minimalne i maksimalne temperatura zraka u Dubrovniku. Dakle, grad postaje sve topliji, a time i neugodniji za život. Posebno valja uzeti u obzir i jače noćno zagrijavanje koje može biti vrlo neugodno jer to znači da se grad ne uspijeva ohladiti niti tijekom noći.

3.1.3. Köppenova klasifikacija

S obzirom da su prethodni rezultati ukazali na zagrijavanje Dubrovnika, moguće je da je došlo i do promjene u tipu klime prema Köppenovoj klasifikaciji. Stoga je napravljena analiza tipa klime za Dubrovnik u kojoj su obuhvaćena 30-godišnja klimatološka razdoblja počevši od razdoblja 1961. - 1990. Namjera ovog dijela istraživanja je ispitati dolazi li do promjene u prevladavajućem tipu klime u Dubrovniku. Rezultati su grafički prikazani na slici 3.11. Iz slike se vidi da unatoč tome

što prethodni rezultati ukazuju na zagrijavanje Dubrovnika, u promatranim razdobljima ne dolazi do promjena u tipu klime prema Köppenovoj klasifikaciji. Za sva promatrana razdoblja dobiven klimatski tip ima obilježja sredozemne klime sa suhim i vrućim ljetom (Csa).



Slika 3.11: Tip klime prema Köppenovoj klasifikaciji klime po 30-godišnjim klimatološkim razdobljima. Na apscisi je označen početak svakog od razmatranog 30-godišnjeg razdoblja te je obojanim simbolom prikazan pripadni tip klime za to razdoblje.

Prema ovim rezultatima može se zaključiti da Köppenova klasifikacija klime nije izrazito osjetljiva na temperaturne trendove. Sličan zaključak, tj. da Köppenova klasifikacija klime nije izrazito osjetljiva na globalno zatopljenje, navode Triantafyllou i Tsonis (1994). U radu Peel, Finlayson i McMahon (2007) navodi se da su područja koja se nalaze na prijelazu između različitih tipova klime osjetljivija na klimatske trendove nego područja unutar istog tipa klime. S obzirom na geografski položaj Dubrovnika i dobivene rezultate može se reći da se Dubrovnik ne nalazi na prijelazu različitih tipova klime i da ovdje prevladava sredozemna klima sa suhim i vrućim ljetom (Csa).

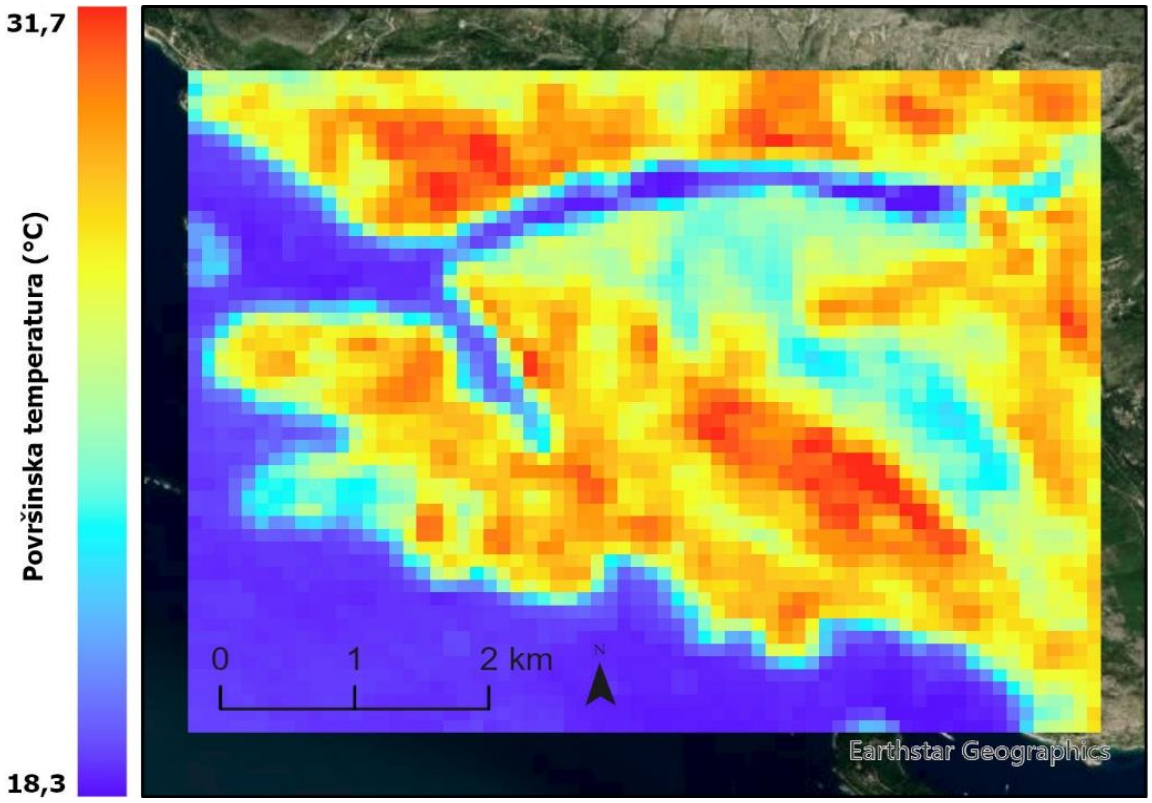
3.2 Toplinsko opterećenje Dubrovnika – satelitski podaci i simulacije modelom MUKLIMO_3

U ovom će se dijelu rada prikazati prosječna ljetna površinska temperatura u razdoblju 2001.-2010. na promatranoj domeni dobivena satelitskim snimkama satelita LANDSAT5 koje su obrađene u GEE-u te potom statistički obrađene i vizualno prikazane pomoću GIS-a. Prikazat će se i klimatski indeksi za razdoblje 2001.-2010. dobiveni primjenom kuboidne metode na podatke dobivene simulacijama modelom MUKLIMO_3. Oni su također uređeni i vizualno prikazani pomoću GIS-a. Napravljena je i analiza toplinskog opterećenja Dubrovnika na temelju raspodjele klimatskih indeksa s obzirom na LULC klase te je grafički prikazana korištenjem programskog jezika *Python*.

3.2.1 Analiza satelitskih podataka

Na slici 3.12 prikazana je prosječna ljetna površinska temperatura u razdoblju 2001.-2010. dobivena satelitskim snimkama satelita LANDSAT5. Prema legendi sa slike, minimalan prosječni LST ljeti na promatranoj domeni iznosi 18.3°C, a te su vrijednosti zabilježene na morskoj površini pa predstavljaju površinsku temperaturu mora. Najviši prosječni ljetni LST iznosi 31.7°C te se javlja na područjima gdje prevladava površina s oskudnom vegetacijom/stijenama (središnji i sjeverozapadni dio domene, klasa 36), područjima nekontinuirane guste urbane površine i nekontinuirane urbane površine srednje gustoće (sjeverni dio domene, klase 1 i 2), područjima poslovnih prostora (istočni dio domene i središnji dio domene, klasa 9). Veće vrijednosti LST-ja zabilježene su i u ostalim urbaniziranim područjima (narančasti spektar), primjerice, stara gradska jezgra (sjeveroistočni dio domene, klasa 7), kontinuirane urbane površine (središnji zapadni i južni dio domene, klase 1,2,3), poslovni prostori (zapadni dio domene, klasa 9), javne ustanove (jugozapadni dio kontinentalnog dijela domene, klasa 11), itd. Niže vrijednosti LST-ja (plavi spektar boja) zabilježene su, osim nad morskom površinom i dijelovima uz nju, također i u šumovitim područjima (istočni dio domene, otočići na zapadnom i južnom dijelu domene, zapadni dio kontinentalnog dijela domene, klasa 28). Na temelju prethodnih zapažanja, može se reći da se ljeti najviše zagrijavaju stjenovite površine, površine s

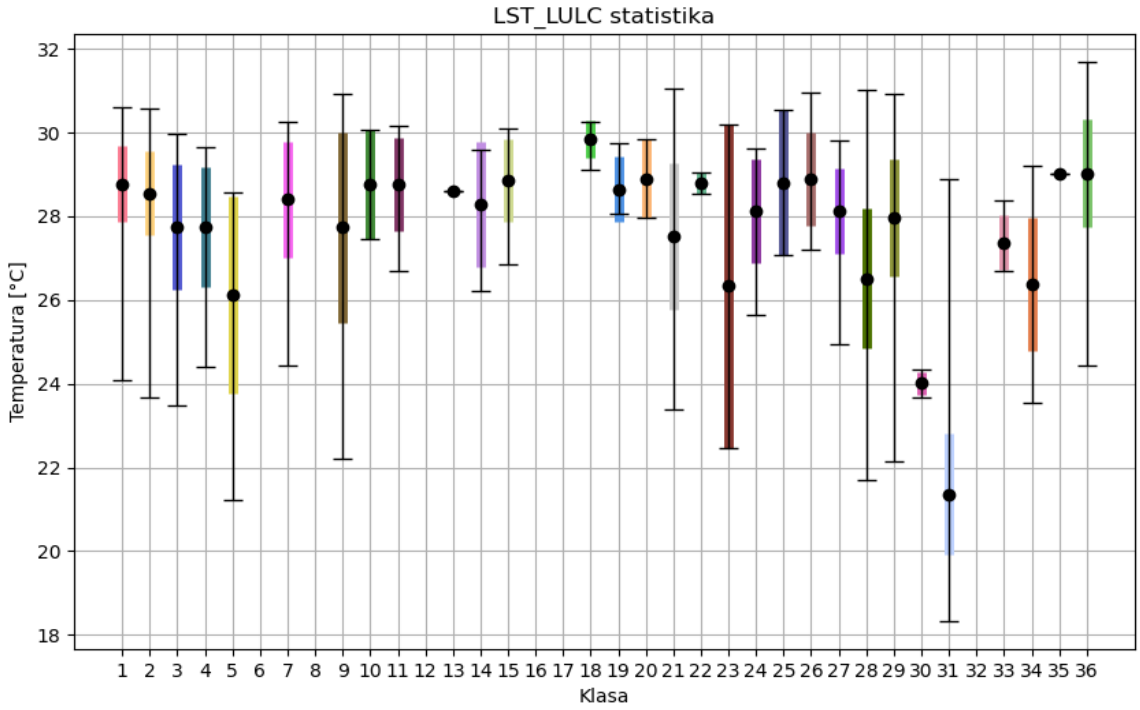
oskudnom vegetacijom i izgrađene površine što je i očekivano s obzirom na karakteristike materijala tih struktura (albedo, toplinski kapacitet materijala, emisivnost, refleksivnost).



Slika 3.12: Prosječna ljetna površinska temperatura (LST) u razdoblju 2001.-2010. dobivena na temelju satelitskih snimaka satelita LANDSAT5.

Na slici 3.13 prikazana je detaljnija analiza prosječnog ljetnog LST-ja prema LULC klasama. Vrijednosti su dobivene usrednjavanjem svih vrijednosti LST-ja dobivenih za pojedinu LULC klasu. Iz tog grafičkog prikaza može se primjetiti da najniži minimum prosječnog ljetnog LST-ja među klasama se javlja za klasu 31 koja predstavlja vodene površine (more) te iznosi 18.3°C. Za klasu 18 (područja rudokopa i odlagališta otpada) zabilježen je najviši minimum prosječnog ljetnog LST-ja iznosa 29.1°C. Najniži maksimum prosječnog ljetnog LST-ja iznosi 24.4°C te odgovara klasi 30, tj. močvarnom području (jugoistočni dio domene), a najviši iznosi 31.7°C i odgovara površinama s oskudnom vegetacijom/stijenama. Najmanja razlika minimuma i maksimuma prosječnog ljetnog LST-ja iznosa $\Delta T = 0.5$°C zabilježena je za klasu 22 (groblja), dok je najveća razlika iznosa $\Delta T = 10.6$°C zabilježena za klasu 31 (more). Velike razlike su zabilježene i za klase 21, 28 i 29, koje odgovaraju klasama prirodnog (vegetacijskog)

porijekla što pokazuje da ove klase imaju veći raspon ljetnog LST-ja u odnosu na većinu drugih klasa. Najmanji srednji prosječni ljetni LST koji je jednak 21.4°C odgovara klasi 31 (more) što je uzevši u obzir toplinski kapacitet mora u skladu s očekivanjima. Najveći srednji prosječni ljetni LST odgovara klasi 18 (rudokopa i odlagališta otpada), ovaj rezultat je s obzirom na karakteristike klase zabrinjavajuć zbog širenja i stvaranja opasnog otpada. Najmanja standardna devijacija dobivena je za klasu 22 (groblja), a najveća za klasu 23 (sadržaji za sport i rekreaciju s gradnjom). Iz ovog prikaza može se još vidjeti da za većinu klasa povezanih s urbanim sadržajima (klase 1, 2, 3, 7, 9, 10, 11, 15, 18 i 23) maksimalan prosječan ljetni LST je veći ili jednak 30°C pri čemu je zanimljivo uočiti da za klase 4 i 5 (nekontinuirane urbane površine manje gustoće izgrađenosti) maksimalan prosječan ljetni LST ne prelazi 30°C. Stoga se može zaključiti da se površine rjeđe gustoće izgrađenosti manje zagrijavaju. Ovi rezultati ukazuju na činjenicu da klase koje su prirodnog porijekla (vegetacijskog, vodenog,...) ili urbane površine male gustoće izgrađenosti imaju manje toplinsko opterećenje od ostalih te su stoga iznimno važne u urbanim sredinama.



Slika 3.13: Grafički prikaz prosječnog ljetnog LST-ja za LULC klase. Za svaku klasu prikazana je minimalna (donja crtica), srednja (crni kružić) i maksimalna (gornja crtica) zabilježena vrijednost prosječnog ljetnog LST-ja te standardna devijacija (obojani dio).

3.2.2 Usporedba rezultata izmjerenih podataka i simulacija modelom MUKLIMO_3

S obzirom da ja svaki model pa tako i MUKLIMO_3 samo približna reprodukcija stvarnosti, potrebno je modelirane podatke usporediti s izmjerenima. U ovom su radu izračunati prosječni brojevi ljetnih dana i tropskih noći u razdoblju 2001.-2010. za simulacije modela MUKLIMO_3 za ćeliju domene koja odgovara položaju meteorološke postaje te su uspoređeni s odgovarajućim izmjerenim vrijednostima. Prosječan broj ljetnih dana za izmjerene podatke jednak je 112.9, dok model simulira 117.0 dana. Relativno malo odstupanje modela od izmjerenih vrijednosti (3,6 %) ukazuje da model vjerno reproducira prosječan broj ljetnih dana u toj ćeliji. Što se broja tropskih noći tiče, prema izmjerenim podacima njih je 81.6, dok simulacije modela daju veću vrijednost (104.3). Ovo je odstupanje veće od onog za ljetne dane (27.8 %) te pokazuje da model precjenjuje prosječan broj tropskih noći. S obzirom da su tropske noći definirane uvjetom za minimalnu temperaturu ($T_n \geq 20°C$) koja se javlja rano ujutro (tj. nešto poslije izlaza Sunca), možemo zaključiti da model simulira toplije noći nego

što su one u stvarnosti. Precjenjivanje indeksa vezanih uz minimalnu temperaturu dobiveno je i za grad Beč (Žuvela-Aloise i sur., 2016.). Ovaj je rezultat potrebno još ispitati i istražiti je li takvo precijenjivanje noćnih temperatura ustrajno te pokušati ustanoviti razloge koji su do njega doveli. Jedna od mogućih pretpostavki je da model ne simulira dovoljno dobro noćno hlađenje, posebno ono povezano sa strujanjem zraka. S tog aspekta, buduća istraživanja vezana uz model bi trebala obuhvatiti detaljniju analizu simulacija vjetra modelom. S obzirom da model dobro reproducira ljetne dane, opravdano ga je koristiti za potrebe ovog rada. Ipak, pri interpretaciji rezultata modela koji se odnose na noćne termine (tropske noći, tople noći i ljetne večeri) potrebno je voditi računa o tome da model simulira veće vrijednosti od stvarnih.

3.2.3 Analiza rezultata simulacija modelom MUKLIMO_3

Na slici 3.14 prikazani su klimatski indeksi u razdoblju 2001.-2010. dobiveni na temelju numeričkih simulacija modelom MUKLIMO_3.

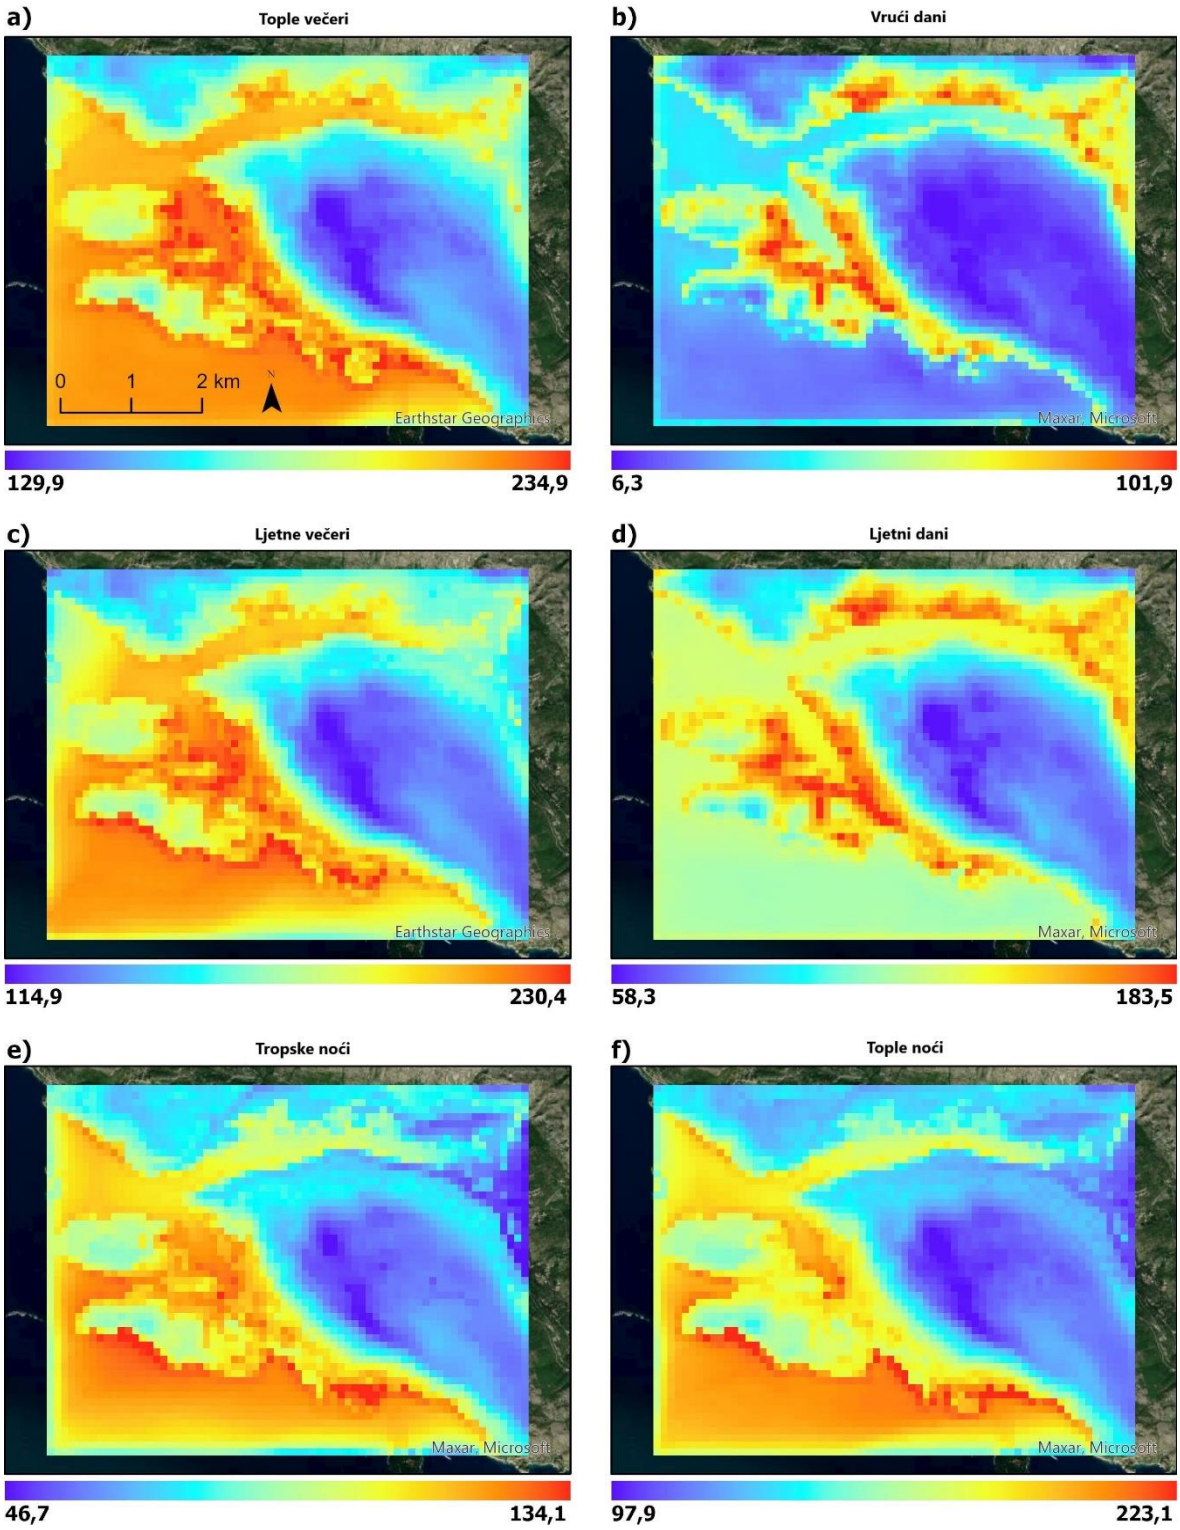
Na slici 3.14a) prikazan je broj dana s toplim večerima. S obzirom da se ovaj indeks odnosi na temperaturu u 20 h prema srednjoeuropskom vremenu (UTC+01 ljeti) vidi se da je čak i za područja s najmanjim prosječnim brojem takvih dana, broj toplih večeri relativno velik (129.9). Točnije, prosječno trećinu godine na cijeloj se domeni u 20 h bilježe temperature veće ili jednake 20°C. Ovaj broj je za urbanizirane površine još i veći, s maksimalnom vrijednošću od 234,9 dana, što znači da su na urbaniziranom području Dubrovnika dvije trećine godine večeri tople. Iz ovih rezultata može se zaključiti da urbanizirane površine upijaju toplinu tijekom dana, zadržavaju je i emitiraju je tijekom noći, dok se površine prirodnog porijekla (npr. stijene, šume) brže hlade.

Slika 3.14b) prikazuje prosječan godišnji broj vrućih dana ($T_x \geq 30°C$) gdje se uočava da je najveći broj takvih dana na urbaniziranom području (101.9). Na ovom prikazu se također može uočiti da je model pokazao da se nad morskim područjem tijekom godine bilježe vrući dani, tj. dani s maksimalnom dnevnom temperaturom većom ili jednakom 30°C što za temperaturu mora nije očekivano na ovom području.

Iz toga se može pretpostaviti da MUKLIMO_3 model precjenjuje temperaturu morskih površina.

Na slici 3.14c) prikazani su prosječni godišnji brojevi ljetnih večeri ($T_{22} \geq 20°C$). U ovom slučaju vidljivo je da se velik broj takvih dana bilježi na cijeloj domeni (minimum 114.9 dana). Ipak, najveći brojevi ljetnih večeri zabilježeni su u urbaniziranim područjima i dijelovima granice između kopnenog i morskog dijela domene (maksimum 230.4 dana). Nad morskom površinom zabilježeni su također veliki prosječni brojevi ljetnih večeri (narančasti spektar boja). More se zbog velikog toplinskog kapaciteta vode, sporo hladi i zagrijava pa velik prosječan godišnji broj ljetnih večeri nad morskom površinom nije iznenađujuć jer se temperatura mora ne mijenja puno tijekom dana stoga je i u 22 sata tijekom toplog dijela godine temperatura morske površine veća ili jednaka 20°C. Na ovom grafičkom prikazu izdvaja se područje granice između morske i kopnene površine, na južnom i jugozapadnom dijelu domene, na tom dijelu rezultati modela pokazuju najveće prosječne godišnje brojeve ljetnih večeri.

Prosječan godišnji broj ljetnih dana ($T_x \geq 25°C$) prikazan je na slici 3.14d), rezultati pokazuju da je najviše ljetnih dana, tj. dana kada je maksimalna dnevna temperatura jednaka ili veća od 25°C, u urbaniziranim područjima, posebice u srednje gustim i gustim nekontinuiranim urbanim površinama i kontinuiranim urbanim površinama. Rezultati modela pokazuju da se najmanje ljetnih dana javlja u šumovitim područjima te područjima s oskudnom vegetacijom/stijenama. S obzirom da je nad tim područjem prisutan neki oblik vegetacije (šuma, grmolika vegetacija, močvarna vegetacija...), zbog procesa evapotranspiracije dolazi do samoohlađivanja, a vlažna tla procesom evaporacije također doprinose hlađenju (Masson i sur., 2020). Zbog tipa i količine vegetacije ovaj proces je najizraženiji u šumovitom dijelu domene, stoga je broj ljetnih dana na ovom području najmanji (središnji dio domene, 58.3 dana).



Slika 3.14: Prosječan godišnji broj u razdoblju 2001.-2010. klimatskih indeksa: **a)** tople večeri, **b)** vrući dani, **c)** ljetne noći, **d)** ljetni dani, **e)** tropske noći i **f)** tople noći.

Na slici 3.14e) prikazani su prosječni godišnji brojevi tropskih noći, tj. dana kada je minimalna dnevna temperatura veća ili jednaka 20°C. Sa slike se može uočiti da je takvih dana najviše uz granicu kopnenog i morskog dijela na jugozapadnom i južnom dijelu domene. Ovakvi rezultati modela mogu se objasniti uzimajući u obzir da more dugo zadržava toplinu, stoga predstavlja izvor topline za obalu. Obala se zbog materijala od kojeg se najčešće sastoji, zagrijava i hladi brže od mora, stoga se gubitak topline obale tijekom noći, kada se očekuju minimalne temperature jer nema kratkovalnog sunčevog zračenja ili tijekom hladnijeg dijela godine, nadoknađuje toplinom pohranjenom u moru. Iz tog razloga je na ovom području broj dana s minimalnom dnevnom temperaturom većom ili jednakom 20°C velik (134.1). Slične rezultate za broj tropskih noći u područjima uz obalu navodi i Žuvela-Aloise (2017). Rezultati za ostale dijelove domene pokazuju da se godišnje u prosjeku najmanje tropskih noći javlja nad prirodnim područjem (šume, stijene; 46.7 dana). U urbaniziranim područjima bilježi se više takvih dana (narančasti i žuti spektar, središnji dio domene) kao i nad morskom površinom. Ovdje je još zanimljivo primjetiti rezultate koji se odnose na urbanizirane dijelove domene na sjevernom i sjeveroistočnom dijelu. Rezultati za ovo područje nalaze se u plavom dijelu spektra prosječnog broja tropskih noći u godini što znači da iako je ovo područje urbanizirano, rezultati su jednaki rezultatima za prirodne dijelove domene. Za razliku od dijela grada na središnjem dijelu domene, ovo urbanizirano područje nije široko rasprostranjeno već se nalazi u užem pojasu između obale, morskog kanala, područja oskudne vegetacije/stijena, šume i topografske prepreke (Srđa), što se može vidjeti i na satelitskoj slici 2.a). S obzirom na dobivene rezultate može se pretpostaviti da je ovo urbanizirano područje pod utjecajem ohlađivanja od okoline, tj. procesi cikulacije obronka i obalne cirkulacije djeluju ohlađujući na to područje zbog čega je tamo prosječan broj tropskih noći manji.

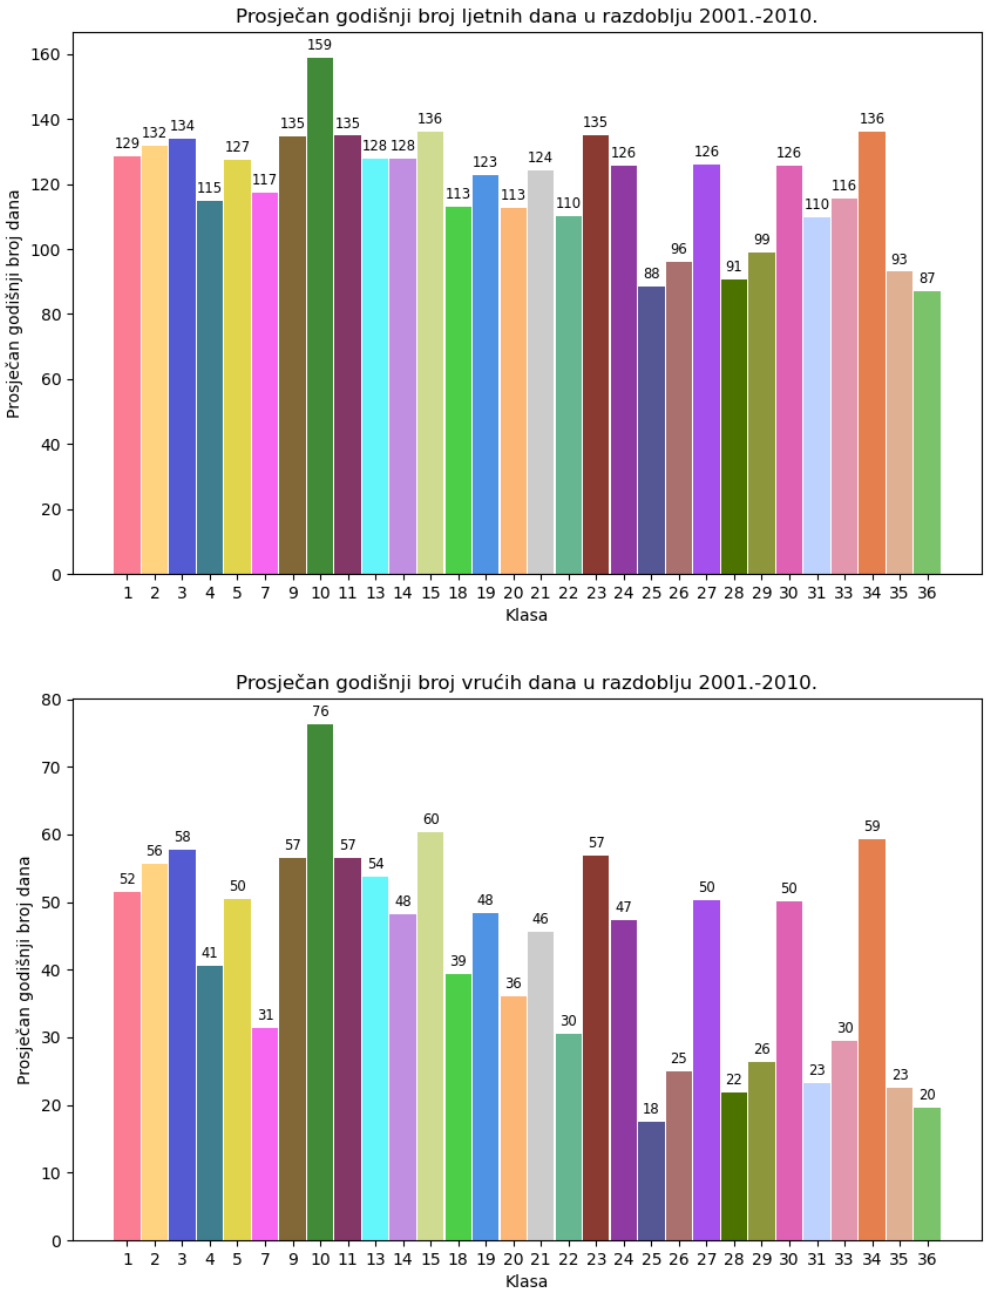
Na slici 3.14f) prikazani su rezultati modela za prosječne godišnje brojeve toplih noći ($T_n \geq 17°C$). Najveći broj toplih noći zabilježen je na istom dijelu kao i kod slučaja tropskih noći, na graničnom dijelu kopnene i morske površine južnog i jugozapadnog dijela domene, dok je najmanji broj toplih noći također zabilježen na istom području kao i kod rezultata za tropske noći, površine prirodnog porijekla. U ovom slučaju se isto može primjetiti razlika između urbaniziranih površina na sjevernom i istočnom dijelu

domene i urbaniziranog dijela u središnjim dijelovima domene gdje se u prosjeku bilježi više toplih noći godišnje. Razlika između rezultata tropskih i toplih noći najviše se uočava u njihovom minimalnom i maksimalnom broju dana. Tako za tople noći oni iznose 46.7 i 134.1 što je značajno manje od vrijednosti za tropske noći (97.9 i 223.1). S obzirom na definiran kriterij klimatskog indeksa tople noći ($T_n \geq 17°C$) koji je niži u odnosu na kriterij za tropske noći ($T_n \geq 20°C$) ova razlika je očekivana.

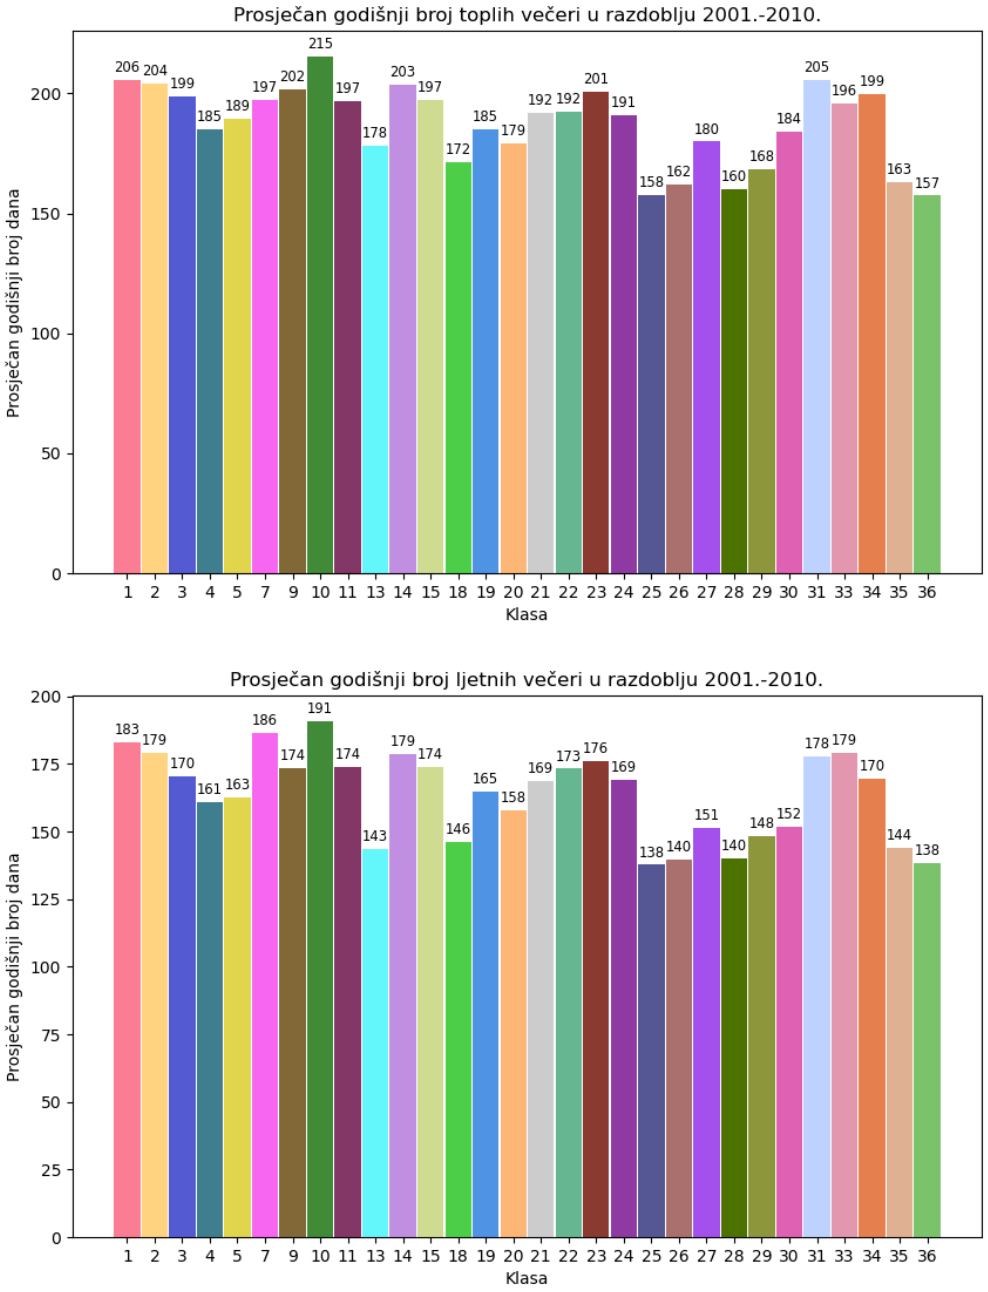
Iz ovih se rezultata može zaključiti da površine prirodnog porijekla postižu manju zagrijanost od urbaniziranih površina. Dijelovi urbaniziranih površina koji nisu široko rasprostranjeni te su okruženi prirodnim dijelovima (šume, oskudna vegetacija, topografske prepreke) noću se hlade više od gusto i široko rasprostranjenih urbanih dijelova. Morska površina ne pokazuje veliku osjetljivost na promjene temperaturnih kriterija klimatskih indeksa zbog velikog toplinskog kapaciteta te djeluje kao izvor topline u hladnijem dijelu dana.

Slika 3.15 prikazuje prosječni godišnji broj dana u razdoblju 2001.-2010. prema LULC klasama za ljetne (gore) i vruće dane (dolje). Prema rezultatima za ljetne dane, najveći prosječan godišnji broj takvih dana dobiven je za klasu 10 (trgovački centri; 159 dana), a najmanji za klasu 36 (površine s oskudnom vegetacijom/stijene; 87 dana). Nadalje, može se primjetiti da je za gotovo sve klase, izuzev klasa 25, 26, 28, 29, 34 i 35, koje imaju potpuno prirodne karakteristike, prosječan broj ljetnih dana u godini veći od 100 što znači da je u prosjeku 3 mjeseca godišnje nad tim dijelovima domene maksimalna dnevna temperatura bila veća ili jednaka 25°C. Ovdje se ponovno pokazuje da se urbanizirane površine danju puno više zagrijavaju u odnosu na prirodne površine što je posljedica njihovih toplinskih karakteristika. Rezultati za vruće dane također pokazuju da je najveći prosječan godišnji broj takvih dana dobiven za klasu 10 (trgovački centri; 76 dana), dok je najmanji za klasu 25 (livade i pašnjaci; 18 dana). Kao i kod ljetnih dana, može se primjetiti da je za klase prirodnih karakteristika (klase 25, 26, 28, 29, 31, 34 i 35) prosječan broj vrućih dana manji od 30, dok je za izgrađene površine veći ili jednak 30. Zanimljivo je uočiti slične rezultate za klase stara gradska jezgra (pretežno izgrađena od kamenog materijala, klasa 7) i stjenovite obale (klasa 33), ti rezultati pokazuju da je prosječan godišnji broj vrućih dana za obje klase oko 30 što je manje u odnosu na većinu ostalih klasa urbaniziranih

površina ($> 50\ dana$). S obzirom da je stara jezgra izgrađena od prirodnog (kamenog) materijala te dvije klase pokazuju slično toplinsko opterećenje. Iz toga se može zaključiti da urbanizirane površine izgrađene od prirodnih materijala, primjerice kamena, prosječno godišnje dostižu manji broj dana s maksimalnim temperaturama.



Slika 3.15: Raspodjela prosječanog godišnjeg broja ljetnih dana (gore) i vrućih dana (dolje) u razdoblju 2001.-2010. po pojedinim LULC klasama.

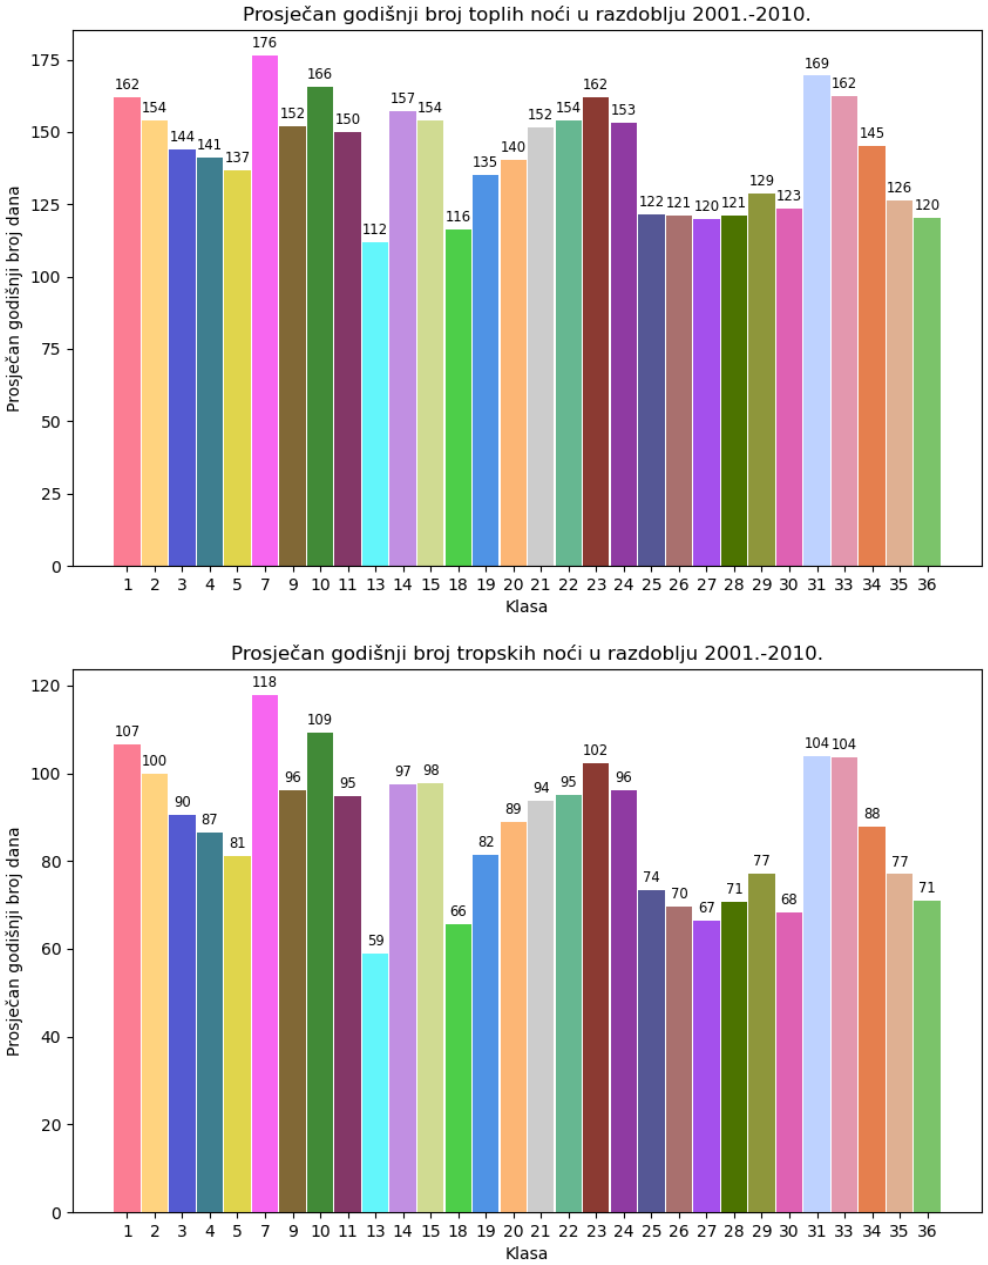


Slika 3.16: Raspodjela prosječanog godišnjeg broja toplih večeri (gore) i ljetnih večeri (dolje) u razdoblju 2001.-2010. po pojedinim LULC klasama.

Na slici 3.16 prikazan je prosječan godišnji broj toplih večeri (gore) i ljetnih večeri (dolje) u razdoblju 2001.-2010. za svaku pojedinu LULC klasu. Za svaku od klasa za oba indeksa zabilježeno je više od 130 takvih dana. Neke klase, ponajviše urbanizirane (1,2,9,10,14,23 i 31) imaju više od 200 večeri s temperaturom u 20 h jednakom ili većom od 20°C. U oba slučaja, najmanji prosječni godišnji broj ljetnih i toplih večeri bilježi se za klase prirodnih vegetacijskih karakteristika (klase 25, 26, 28,

29, 34 i 35). Najveći prosječni godišnji broj toplih i ljetnih večeri ima klasa 10 (trgovački centri), a najmanji klasa 25 (livade i pašnjaci). Kao klasa s najmanje ljetnih večeri još se ističe i klasa 36 (površine s oskudnom vegetacijom i stijene). Uzevši u obzir rezultate numeričke simulacije, cijelo područje grada Dubrovnika pokazuje veliko toplinsko opterećenje u večernjim terminima (20 h i 22 h), ponajviše u urbaniziranim dijelovima. Time je pokazano da izgrađene površine zbog svojih toplinskih svojstava djeluju kao izvor topline u gradu. One apsorbiraju toplinu tijekom dana, zadržavaju je i otpuštaju noću. Na taj način se grad dodatno zagrijava, a večeri postaju tople.

Prosječan godišnji broj toplih i tropskih noći u razdoblju 2001.-2010. prikazan je na slici 3.17. Usporedbom rezultata za oba klimatska indeksa uočava se da je općenito za svaku klasu zabilježeno manje tropskih nego toplih noći što je uzevši u obzir definicije indeksa očekivano ($T_n \geq 20°C\ i\ T_n \geq 17°C$). Rezultati toplih noći pokazuju da se najviše takvih noći (176) javlja za klasu 7 (stara gradska jezgra), a najmanje (112) za klasu 13 (energetska i vodnogospodarska infrastruktura). Slično se dobiva i za tropske noći, tj. najviše tropskih noći se javlja u klasi 7 (118 dana), a najmanje u klasi 13 (59 dana). Ovdje se može uočiti da je kod rezultata za vruće dane ($T_x \geq 30°C$) klasa 7 u odnosu na ostale urbanizirane klase imala najmanji prosječan godišnji broj vrućih dana, dok je kod toplih ($T_n \geq 17°C$) i tropskih noći ($T_n \geq 20°C$) u odnosu na iste klase imala najveći prosječan godišnji broj tih indeksa. Dakle, u odnosu na druge izgrađene površine, stara se jezgra najviše zagrijava tijekom noći. To je posljedica upijanja topline tijekom dana i njenog otpuštanja noću. Time je noćno toplinsko opterećenje najveće upravo u tom dijelu grada. Iz ovih rezultata može se reći da je temperaturni raspon koji se postiže u staroj gradskoj jezgri manji u odnosu na ostale urbanizirane klase. U staroj gradskoj jezgri u odnosu na ostale urbanizirane klase bilježi se u godišnjem prosjeku manje dana s višim temperaturama ($T_x \geq 30°C$), ali i manje dana s nižim temperaturama ($T_n \leq 20°C$). Također, i tople i tropske noći ukazuju na ovisnost o gustoći izgrađenosti urbanih površina. Tako se uočava smanjenje toplih i tropskih noći sa smanjenjem gustoće izgrađenosti urbanih površina (klase 1,2,3,4 i 5). U manje izgrađenim dijelovima grada, noći su prosječno hladnije od gusto izgrađenih dijelova. Nadalje, vegetacija ublažava toplinsko opterećenje pa se za klase s vegetacijskim površinama bilježi manje toplih i tropskih noći (klase 25, 26, 27, 28, 29, 30, 34 i 35).



Slika 3.17: Raspodjela prosječanog godišnjeg broja toplih noći (gore) i tropskih noći (dolje) u razdoblju 2001.-2010. po pojedinim LULC klasama.

4. Zaključak

Prema izmjerenim podacima u posljednjih 50-ak godina na meteorološkoj postaji Dubrovnik bilježi se porast srednjih dnevnih, dnevnih maksimalnih i minimalnih te srednjih sezonskih temperatura. Godišnje srednje dnevne temperature u Dubrovniku ubrzano rastu. Srednje dnevne temperature u Dubrovniku u sezoni DJF u blagom su porastu, u sezoni MAM porast je veći, a u sezoni JJA bilježi se najveći porast. Srednje dnevne temperature u sezonama JJA i MAM rastu ubrzano. Srednje sezonske maksimalne dnevne temperature rastu u svim sezonama, ali porast je najizraženiji u sezoni JJA. Isto vrijedi i za srednje sezonske minimalne dnevne temperature koje bilježe nešto manji porast u odnosu na maksimalne srednje dnevne temperature.

Klimatski indeksi također ukazuju na zatopljenje Dubrovnika. Godišnji broj studenih dana opada što ukazuje da Dubrovnik postaje sve topliji, kao i zime kada se očekuju najniže temperature. Godišnji broj ljetnih dana pokazuje uzlazan trend što ukazuje na zagrijavanje grada. Tropske noći su u porastu što pokazuju na jače noćno zgrijavanje grada. Iako je došlo do promjene temperature, analizom tipova klime dobiveno je da u Dubrovniku nije došlo do promjene tipa klime u promatranim razdobljima te da prevladava sredozemna klima sa suhim i vrućim ljetima (Csa). Očito Köppenova klasifikacija nije osjetljiva na promjene temperature.

Prosječna ljetna površinska temperatura u razdoblju 2001.-2010. dobivena satelitskim mjerenjima pokazuje da se ljeti najviše zagrijavaju stjenovite površine, površine s oskudnom vegetacijom i urbanizirane površine. Klase prirodnog porijekla (vegetacijskog, vodenog,...) ili urbane površine male gustoće izgrađenosti pokazuju manje zagrijavanje.

Usporedbom rezultata prosječnih klimatskih indeksa na temelju izmjerenih podataka s meteorološke postaje Dubrovnik i simulacija modela MUKLIMO_3 na ćeliji domene na kojoj se nalazi meteorološka postaja pokazalo se da model dobro reproducira broj ljetnih dana, dok broj tropskih noći precjenjuje. Uzimajući u obzir navedene rezlutate procijenjeno je da se model može koristiti za potrebe ovog rada, ali pri interpretaciji rezultata klimatskih indeksa s noćnim terminima potrebno je voditi računa o tome da model simulira veće vrijednosti od stvarnih.

Klimatski indeksi dobiveni simulacijama modelom MUKLIMO_3 (ljetni i vrući dani, tople i ljetne večeri, tople i tropske noći) pokazuju da se površine prirodnog porijekla manje zagrijavaju od izgrađenih površina. Dijelovi urbaniziranih površina koji nisu široko rasprostranjeni te su okruženi prirodnim dijelovima (šume, oskudna vegetacija, topografske prepreke) noću se jače hlade nego površine s gusto i široko rasprostranjenim izgrađenim dijelovima. Morska površina ne pokazuje veliku osjetljivost na promjene temperaturnih kriterija klimatskih indeksa zbog velikog toplinskog kapaciteta te djeluje kao izvor topline noću i zimi.

Konačno možemo zaključiti da izmjereni podaci ukazuju da se toplinsko opterećenje Dubrovnika povećava što je i u skladu s globalnim zatopljenjem i dostupnim klimatskim projekcijama. Osim navedenog, do povećanja toplinskog opterećenja dolazi i zbog porasta urbaniziranih površina. Rezultati modela ukazuju na to da urbane strukture grada utječu na prostornu raspodjelu toplinskog opterećenja grada. Tako stara jezgra i gusto izgrađene površine imaju najveće toplinsko opterećenje. To su područja koja su topla i noću. S druge strane, površine manje gustoće izgrađenosti kao i one prirodnog porijekla mogu imati relativno veliku površinsku temperaturu, ali ipak nemaju svojstvo dugotrajnog pohranjivanja topline pa se one ipak brže hlade. Nadalje, u području manje gustoće izgrađenosti na toplinsko opterećenje vjerojatno utječe i vjetar koji pridonosi bržem ohlađivanju. Porast toplinskog opterećenja Dubrovnika nije iznenađujuć, ali je to iznimno važan rezultat, posebno za ljetnu sezonu kada je izražen povećani broj turista u tom gradu. Nadalje, s obzirom da je toplinsko opterećenje manje u područjima manje gustoće izgrađenosti, važno je očuvati prirodne površine u gradu. Na kraju je potrebno istaknuti kako je pri proučavanju toplinskog opterećenja gradova važno iskoristiti različite pristupe (izmjereni podaci na meteorološkoj postaji, satelitski podaci te numeričko modeliranje) jer je tako moguće procijeniti prostornu raspodjelu toplinskog opterećenja Dubrovnika.

Dodatak A

Težinski faktori potrebni za provođenje trilinearne interpolacije 8 MUKLIMO_3 simulacija računaju se pomoću veličina koje opisuju kuteve kuboida ($T_{cmin}, T_{cmaks}, rh_{cmin}, rh_{cmaks}, v_{cmin}, v_{cmaks}$) i dugoročnih podataka s lokalne meteorološke postaje ili podataka iz simulacija modela veće skale (T_i, rh_i, v_i) na način da se najprije izračunaju težinski faktori za svaki meteorološki parametar

$$wf_T = \frac{(T_{cmaks} - T_i)}{(T_{cmaks} - T_{cmin})}$$

$$wf_{rh} = \frac{(rh_{cmaks} - rh_i)}{(rh_{cmaks} - rh_{cmin})}$$

$$wf_v = \frac{(v_{cmaks} - v_i)}{(v_{cmaks} - v_{cmin})}.$$

Kako bi se minimizirale pogreške ekstrapolacije parametara relativne vlažnosti i brzine vjetra, njihovi težinski faktori se ograničavaju na vrijednosti između 0 i 1

$$wf_{rf} = \max\{0, \min\{wf_{rh}, 1\}\}$$

$$wf_v = \max\{0, \min\{wf_v, 1\}\}.$$

Na temelju prethodnih veličina dobivaju se težinski faktori za svaki kut kuboida prema sljedećim relacijama

$$wf_{000} = wf_T \times wf_{rh} \times wf_v$$

$$wf_{001} = wf_T \times wf_{rh} \times (1 - wf_v)$$

$$wf_{010} = wf_T \times (1 - wf_{rh}) \times wf_v$$

$$wf_{011} = wf_T \times (1 - wf_{rh}) \times (1 - wf_v)$$

$$wf_{100} = (1 - wf_T) \times wf_{rh} \times wf_v$$

$$wf_{101} = (1 - wf_T) \times wf_{rh} \times (1 - wf_v)$$

$$wf_{110} = (1 - wf_T) \times (1 - wf_{rh}) \times wf_v$$

$wf_{111} = (1 - wf_T) \times (1 - wf_{rh}) \times (1 - wf_v)$ (Žuvela − Aloise i sur., 2014).

Literatura

Aamir, E., Hassan, I. (2020). The impact of climate indices on precipitation variability in Baluchistan, Pakistan. *Tellus series A-Dynamic Meteorology and Oceanography* [*online*], 72. Dostupno na: 10.1080/16000870.2020.1833584

Balling, R.C. Jr., Cerveny, R.S. i Idso, C.D. (2001). Does the urban CO2 dome of Phoenix, Arizona contribute to its heat island? *Geophysical Research Letters* [*online*], 28 (24), 4599-4601. Dostupno na: http://www.atmos.berkeley.edu/~inez/MSRI-NCAR_CarbonDA/papers/barnet_refs/2000GL012632.pdf [27. rujna 2021.]

Beck, H., Zimmermann, N., McVicar, T. *et al.* Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Sci Data* **5,** 180214 (2018). Dostupno na: https://doi.org/10.1038/sdata.2018.214 [13. rujna 2021.]

Beniston, M. (1998). *From turbulence to climate: Numerical Investigations of the Atmosphere with Hierarchy of models* [*online*]. Berlin; Heidelberg; New York; Barcelona; Budapest; Hong Kong; Milano ; Paris; Santa Clara; Singapore; Tokyo : Springer. Dostupno na: https://ug1lib.org/book/2263698/fe121f?id=2263698&secret=fe121f [30. kolovoza 2021.]

Bevington, P.R. i Robinson, D.K. (2003). *Data reduction and error analysis for the physical sciences [online]*. Thrid edition. New York: McGraw-Hill. Dostupno na : http://hosting.astro.cornell.edu/academics/courses/astro3310/Books/Bevington_opt.pdf [6.rujna 2021.]

Climate Change Adaptation Plan for the City of Dubrovnik (2019). Dostupno na: https://dura.hr/wp-content/uploads/2021/02/Climate-Adaptation-Plan_ENG_DURA_final.pdf [27. rujna 2021.]

Früh, B., Becker, P., Deutschländer, T. , Hessel, J., Kossmann, M., Mieskes, I., Namyslo, J., Roos, M., Sievers, U., Steigerwald, T., Turau, H., Wienert, U. (2010) Estimation of Climate-Change Impacts on the Urban Heat Load Using an Urban Climate Model and Regional Climate Projections. *Journal of Applied Meteorology and Climatology*, 50, 167-184.

Gilbert, R.O. (1987). *Statistical Methods for Enivronmental Pollution Monitoring* [*online*]. New York: Van Nostrand Reinhold company. Dostupno na: https://www.osti.gov/servlets/purl/7037501/ [14. rujna 2021.]

Giorgi, F. (2006). Climate change hot-spots. *Geophysical Research Letters* [*online*], 33. Dostupno na: https://doi.org/10.1029/2006GL025734 [27. rujna 2021.]

Graczyk, D., Pinskwar, I., Kundzewicz, Z.W., Hov, O., Forland, E.J., Szwed, M., Chorynski, A. (2017). The heat goes on – changes in indices of hot extremes in Poland. *Theoretical and applied climatology* [*online*], 129, 459-471. Dostupno na: 10.1007/s00704-016-1786-x

He, H.; Luo, G.; Cai, P.; Hamdi, R.; Termonia, P.; De Maeyer, P.; Kurban, A.; Li, J. Assessment of Climate Change in Central Asia from 1980 to 2100 Using the KöppenGeiger Climate Classification. Atmosphere 2021, 12, 123. https:// doi.org/10.3390/atmos12010123

https://www.climdex.org/learn/indices/ [14. srpnja 2021.]

IPCC, 2018: Annex I: Glossary [Matthews, J.B.R. (ed.)]. In: *Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty* [Masson-Delmotte, V., P. Zhai, H.-O. Pörtner, D. Roberts, J. Skea, P.R. Shukla, A. Pirani, W. Moufouma-Okia, C. Péan, R. Pidcock, S. Connors, J.B.R. Matthews, Y. Chen, X. Zhou, M.I. Gomis, E. Lonnoy, T. Maycock, M. Tignor, and T. Waterfield (eds.)]. Dostupno na : https://www.ipcc.ch/sr15/chapter/glossary/ [30. kolovoza 2021.]

IPCC, 2018: Summary for Policymakers. In: Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty [Masson-Delmotte, V., P. Zhai, H.-O. Pörtner, D. Roberts, J. Skea, P.R. Shukla, A. Pirani, W. Moufouma-Okia, C. Péan, R. Pidcock, S. Connors, J.B.R. Matthews, Y. Chen, X. Zhou, M.I. Gomis, E. Lonnoy, T. Maycock, M. Tignor, and T. Waterfield (eds.)]. In Press. Dostupno na: https://www.ipcc.ch/site/assets/uploads/sites/2/2019/05/SR15_SPM_version_report_LR.pdf [27. rujna 2021.]

IPCC, 2021: Summary for Policymakers. In: Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Masson-Delmotte, V., P. Zhai, A. Pirani, S. L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M. I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J.B.R. Matthews, T. K. Maycock, T. Waterfield, O. Yelekçi, R. Yu and B. Zhou (eds.)]. Cambridge University Press. In Press. Dostupno na: https://www.ipcc.ch/report/ar6/wg1/downloads/report/IPCC_AR6_WGI_SPM.pdf [31.kolovoza 2021.]

Jopp, R., DeLacy, T., Mair, J. (2010). Developing a framework for regional destination adaptation to climate change. Current issues in tourism [online], 13, 591-605. Dostupno na: 10.1080/13683501003653379 [27. rujna 2021.]

Kendall, M.G. (1975). *Rank Correlation Methods*. London: Griffin.

Klaić, Z.B., Nitis, T., Kos, I., Moussiopoulos, N. (2002). Modification of the local winds due to hypothetical urbanization of the Zagreb surroundings. *Meteorology and atmospheric physics*, 79(1-2), 1-12.

Lu, H., Guan, Y., He, L., Adhikari, H., Pellikka, K. E., Heiskanen, J., Maeda, E. (2020). Patch aggregation trends of the global climate landscape under future global warming scenario. *International journal of climatology* [*online*], 40, 2674-2685. Dostupno na: 10.1002/joc.6358 [13. rujna 2021.]

Mann, H.B. (1945). Nonparametric tests against trend. *Econometrica* [*online*], 13(3), 245-259. Dostupno na: https://doi.org/10.2307/1907187 [14. rujna 2021.]

Masson, V., Lemonsu, A., Hidalgo, J., Voogt, J. (2020). Urban Climates and Climate Change. *Annual Reviews of Environment and Resources* [*online*], 45, 411-444. Dostupno na: https://doi.org/10.1146/annurev-environ-012320-083623 [27. rujna 2021.]

Meehl, G.A., T.F. Stocker, W.D. Collins, P. Friedlingstein, A.T. Gaye, J.M. Gregory, A. Kitoh, R. Knutti, J.M. Murphy, A. Noda, S.C.B. Raper, I.G. Watterson, A.J. Weaver and Z.-C. Zhao, 2007: Global Climate Projections. In: Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA. Dostupno na: https://www.ipcc.ch/site/assets/uploads/2018/02/ar4-wg1-chapter10-1.pdf [27. rujna 2021.]

Meshram, S.G., Kahya, E., Meshram, C., Ghorbani, M.A., Ambade, B., Mirabbasi, R. (2020). Long-term temperature trend analysis associated with agriculture crops. *Theoretical and applied climatology* [*online*], 140, 1139-1159. Dostupno na: 10.1007/s00704-020-03137-z

Oke, T.R., Mills, G., Christen, A., Voogt, J.A. (2017). *Urban Climates* [*online*]. Cambridge, New York, Port Melbourne, Daryaganj, Singapore: Cambridge University Press. Dostupno na: https://aerisfuturo.pl/wp-content/uploads/2018/09/Urban Climates-1.pdf [27. rujna 2021.]

Peel, M.C., Finlayson, B.L., McMahon, T.A. (2007). Updated world map of Koppen-Geiger climate classification. *Hidrology and earth system sciences* [*online*], 11, 1633-1644. Dostupno na: 10.5194/hess-11-1633-2007 [13. rujna 2021.]

Pielke, R.A., Sr, Marland, G., Betts, R.A., Chase, T.N., Eastman, J.L., Niles, J.O., Niyogi, D.D.S., Running, S.W. (2002). The influence of land-use change and landscape dynamics on the climate system: relevance to climate-change policy beyond the radiative effect of greenhouse gases. *The Royal Society* [*online*], 360 (1797), 1705-1719. Dostupno na: https://www.researchgate.net/publication/7121846 The influence of land-use change and landscape dynamics on the climate system Relevance to climate-change policy beyond the radiative effect of greenhouse gases [27. rujna 2021.]

Rahimi, J., Laux, P., Khalili, A. (2020). Assesment of climate change over Iran: CMIP5 results and their presentation in terms of Köppen-Geiger climate zones. *Theoretical and applied climatology* [*online*], 141, 183-199. Dostupno na: 10.1007/s00704-020-03190-8 [12. rujna 2021.]

Rubel, F., Brugger, K., Haslinger, K., Auer, I. (2017). The climate of European Alps: Shift of very high resolution Köppen-Geiger climate zones 1800-2100. *Meteorologische Zeitschfrift* [*online*], 26, 115-125. Dostupno na: 10.1127/metz/2016/0816 [12. rujna 2021.]

Skalak, P., Farda, A., Zahradnicek, P., Trnka, M., Hlasny, T., Stepanek, P. (2018). Projected shift of Koppen-Geiger zones in the central Europe: A first insight intointo the implications for ecosystems and society. *International journal of climatology* [*online*], 38, 3595-3606. Dostupno na: 10.1002/joc.5520 [12. rujna 2021.]

Su, B.D., Jiang, T., Jin, W.B. (2006). Recent trends in observed temperature and precipitation extremes in Yangtze River basin, China. *Theoretical and applied climatology* [*online*], 83, 139-151. Dostupno na: 10.1007/s00704-005-0139-y

The World's Cities in 2016 (2016). https://www.un.org/en/development/desa/population/publications/pdf/urbanization/the worlds cities in 2016 data booklet.pdf [27. rujna 2021.]

Triantafyllou, G.N., Tsonis, A.A. (1994). Assessing the ability of the Köppen system to delineate the general world pattern of climates. *Geophysical research letters* [*online*], 21, 2809-2812. Dostupno na: 10.1029/94GL01992 [13. rujna 2021.]

Westra, S., Alexander, L.V., Zwiers, F.W. (2013). Global Increasing Trends in Annual Maximum Daily Precipitation. *Journal of climate* [*online*], 26, 3904-3918. Dostupno na: 10.1175/JCLI-D-12-00502.1

Yue, S., Pilon, P., Cavadias, G. (2002). Power of Mann-Kendall and Spearman's rho tests for detecting monotonic trends in hydgicarolol series. *Journal of Hydrology* [*online*], 259 (2002), 254-271. Dostupno na: https://gec.cr.usgs.gov/outgoing/threshold_articles/Yueetal2002.pdf [14. rujna 2021.]

Zaninović, K., Gajić-Čapka, M., Perčec Tadić, M. et al, 2008: Klimatski atlas Hrvatske / Climate atlas of Croatia 1961–1990., 1971–2000. Državni hidrometeorološki zavod, Zagreb, 200 str. Dostupno na: https://klima.hr/razno/publikacije/klimatski_atlas_hrvatske.pdf [27. rujna 2021.]

Zhang, Q., Xu, C. Y., Zhang, Z., Chen, Y. D., Liu, C. L. (2009). Spatial and temporal variability of precipitation over China, 1951-2005. *Theoretical and applied climatology* [*online*], 95, 53-68. Dostupno na: 10.1007/s00704-007-0375-4

Zhang, R., Corte-Real, J., Moreira, M., Kilsby, C., Birkinshaw, S., Burton, A., Fowler, H.J., Forsythe, N., Nunes, J.P., Sampaio, E., dos Santos, F.L., Mourato, S. (2019). Downscaling climate change of water availability, sediment yield and extreme events: Application to a Mediterranean climate basin. *International journal of climatology* [*online*], 39, 2947-2963. Dostupno na: 10.1002/joc.5994

Zhang, X., Alexander, L., Hegerl, G.C., Jones, P., Klein Tank, A., Peterson, T.C., Trewin, B., Zwiers, F.W. (2011). Indices for monitoring changes in extremes based on daily temperature and precipitation data. Wiley Interdisciplinary Reviews – Climate change [online], 2, 851-870. Dostupno na: 10.1002/wcc.147

Žuvela-Aloise, M. (2017). Enhancement of urban heat load through social inequalities on an example of a fictional city King's Landing. *International Journal of Biometeorology* [*online*], 61(3), 527-539. Dostupno na: https://link.springer.com/content/pdf/10.1007%2Fs00484-016-1230-z.pdf [28. rujna 2021.]

Žuvela-Aloise, M., Koch, R., Neureiter, A., Böhm, R., Buchholz, S. (2014). Reconstructing urban climate of Vienna based on historical maps dating to the early instrumental period. *Urban Climate*, 10 (3), 490-508.

Žuvela-Aloise, M., Koch, R., Buchholz, S., Fruh, B. (2016). Modelling the potential of green and blue infrastructure to reduce urban heat load in t he city of Vienna. *Climatic Change* [*online*], 135(3-4), 425-438. Dostupno na: https://link.springer.com/content/pdf/10.1007%2Fs10584-016-1596-2.pdf [28. rujna 2021.]