Utjecaj promjena podloge na toplinska obilježja grada Zagreba na temelju analize Landsat podataka

Žgela, Matej

Master's thesis / Diplomski rad

2020

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:217:105587

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

Matej Žgela

Utjecaj promjena podloge na toplinska obilježja grada Zagreba na temelju analize Landsat podataka

Diplomski rad

Zagreb
2020.

Matej Žgela

Utjecaj promjena podloge na toplinska obilježja grada Zagreba na temelju analize Landsat podataka

Diplomski rad
predan na ocjenu Geografskom odsjeku
Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu
radi stjecanja akademskog zvanja
magistra geografije

Zagreb
2020.

Ovaj je diplomski rad izrađen u sklopu diplomskog sveučilišnog studija *Geografija; smjer: istraživački (Fizička geografija s geoekologijom)* na Geografskom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, pod vodstvom doc. dr. sc. Mladena Maradina i uz potporu projekta „Klimatske promjene i varijabilnost u Hrvatskoj – od globalnih utjecaja do lokalnih zelenih rješenja“ (voditeljice izv. prof. dr. sc. Ivane Herceg Bulić).

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek

Diplomski rad

Utjecaj promjena podloge na toplinska obilježja grada Zagreba na temelju analize Landsat podataka

Matej Žgela

Izvadak: Izgrađene površine sve više zamijenjuju prirodne, apsorbirajući više Sunčeve radijacije što utječe na stvaranje značajnih temperaturnih razlika između urbanih i ruralnih područja. Rezultat toga je formiranje urbanog toplinskog otoka (UHI) i lokalnih toplinskih otoka (LUHI). Promjenom obilježja podloge, tj. širenjem izgrađenih površina najčešće dolazi do porasta temperature površine tla (LST). Landsat podacima se pristupilo putem Google Earth Engine-a, napredne platforme za geoprostorne analize, putem koje su izrađene toplinske karte i karte NDVI-a. Na temelju njih analizirane su promjene toplinskih obilježja na šest odabranih primjera u gradu Zagrebu za ljetno razdoblje (2000. i 2019.) te zimsko razdoblje (2000./2001. i 2019./2020). Rezultati su pokazali da je širenje izgrađenih površina dovelo do značajnog porasta LST-a te jačanja intenziteta UHI-a Zagreba. Provedena regresijska analiza i Pearsonov koeficijent korelacije ukazuju na statistički značajnu vezu LST-a i NDVI-a.

77 stranica, 30 grafičkih priloga, 14 tablica, 66 bibliografskih referenci; izvornik na hrvatskom jeziku

Ključne riječi: urbana klimatologija, temperatura površine tla, Landsat, Google Earth Engine, NDVI

Voditelj: doc. dr. sc. Mladen Maradin

Povjerenstvo: doc. dr. sc. Mladen Maradin
prof. dr. sc. Anita Filipčić
doc. dr. sc. Luka Valožić

Tema prihvaćena: 13. 2. 2020.

Rad prihvaćen: 4. 6. 2020.

Rad je pohranjen u Središnjoj geografskoj knjižnici Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Marulićev trg 19, Zagreb, Hrvatska.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Department of Geography

Master Thesis

Impact of land surface changes on heat features in the city of Zagreb based on Landsat data

Matej Žgela

Abstract: Built-up areas are increasingly replacing natural ones, absorbing more solar radiation that affects large temperature differences between urban and rural areas. The results are the formation of an urban heat island (UHI) and local heat islands (LUHI). By changing the characteristics of the surface, ie. by the expansion of the built-up area, there is an increase in land surface temperature (LST). Landsat data is accessed through Google Earth Engine, an advanced platform for geospatial analysis, which is used to create heat maps and NDVI maps. Based on them, changes in thermal characteristics of six selected sample areas in the city of Zagreb for the summer period (2000 and 2019) and winter period (2000/2001 and 2019/2020) were analyzed. The results showed that the expansion of the built-up area led to a significant increase in LST and strengthening of the UHI intensity in Zagreb. Regression analysis performed in the paper and the Pearson correlation coefficient indicate a statistically significant relationship between LST and NDVI.

77 pages, 30 figures, 14 tables, 66 references; original in Croatian

Keywords: urban climatology, land surface temperature, Landsat, Google Earth Engine, NDVI

Supervisor: Mladen Maradin, PhD, Assistant Professor

Reviewers: Mladen Maradin, PhD, Assistant Professor
Anita Filipčić, PhD, Full Professor
Luka Valožić, PhD, Assistant Professor

Thesis title accepted: 13/02/2020

Thesis accepted: 04/06/2020

Thesis deposited in Central Geographic Library, Faculty of Science, University of Zagreb, Marulićev trg 19, Zagreb, Croatia.

Sadržaj

1. Uvod....1
1.1. Predmet istraživanja....2
1.2. Ciljevi i hipoteze....3
1.3. Prostorni i vremenski obuhvat....4
2. Pregled dosadašnjih istraživanja....6
3. Podaci i metode obrade....9
3.1. Metodološki okvir....9
3.2. Landsat podaci....10
3.3. Google Earth Engine....14
3.3.1. Metoda izračuna LST-a....17
3.3.2. Metoda izračuna NDVI-a....18
3.4. Obrada i analiza podataka....19
4. Promjene u izgrađenosti grada Zagreba od 2000. do 2015. godine....20
5. Toplinska obilježja šireg područja grada Zagreba....22
6. Rezultati i rasprava....27
6.1. Promjena toplinskih obilježja podloge na izabranim područjima....27
6.1.1. Referentna područja....27
6.1.2. Arena centar....31
6.1.3. Stambene zgrade Selska....40
6.1.4. Kanal Sava-Odra....46
6.1.5. Supernova i Bauhaus Buzin....50
6.2. Usporedba LST-a s NDVI-om....55
7. Rasprava....63
8. Zaključak....66
Literatura....69
Izvori....76
Popis akronima i kratica....VI
Popis slika....VII
Popis tablica....IX

1. Uvod

Čovjek neprestano mijenja površinu Zemlje širenjem naselja, intenziviranjem poljoprivrede ili gradnjom infrastrukture u širem smislu. Takve antropogene modifikacije utječu na toplinska obilježja podloge, tj. dolazi do promjena temperature površine tla (engl. *Land Surface Temperature*, LST) što za posljedicu ima i promjene temperature zraka (Gill i dr., 2007). Obzirom da danas na svega 2,5 % kopnene površine Zemlje na kojoj se nalaze gradovi živi više od 55 % stanovništva (*World bank*, 2019) potrebno je dobiti jasniji uvid u klimu grada. Od izdvajanja urbane klimatologije kao discipline klimatologije 70-ih godina 20. stoljeća (Mills, 2014) došlo je do velikog napretka u kvaliteti istraživanja, zbog čega je danas omogućeno pouzdano determiniranje antropogenog utjecaja na izmjenu energetske bilance na svim prostornim razinama. Izgrađene površine sve više zamijenjuju prirodne, apsorbirajući više Sunčeve radijacije što utječe na stvaranje značajnih temperaturnih razlika između urbanih i ruralnih područja. Rezultat je formiranje urbanog toplinskog otoka (engl. *Urban Heat Island*, UHI) koji je kontrast često hladnijoj ruralnoj okolici (Oke, 1976). Također, na nižoj prostornoj razini uočavaju se razlike unutar samog grada čime se mogu definirati urbani toplinski otoci lokalne razine, tj. lokalni toplinski otoci (engl. *Local Urban Heat Island*, LUHI) koji su podrobnije analizirani u ovom radu. U gradu se uočava porast LST-a i temperature zraka u odnosu na okolno područje, zbog promjena u obilježjima podloge, koje su primarno uzrokovane morfologijom grada i korištenim građevinskim materijalima. Isto je primjetno i u Zagrebu gdje se mogu uočiti područja jače zagrijanosti (Čmrlec, 2019; Kovačić, 2014). Najčešće je riječ o područjima homogene prekrivenosti umjetnim materijalima koji formiraju „otoke“ višeg LST-a ili temperature zraka, npr. područje *Arena centra*. No, postoje i hladni „otoci“ kojima dominiraju prirodna obilježja podloga, primjerice *Botanički vrt*. Iako je UHI vidljiv tijekom cijele godine, njegove negativne posljedice dolaze do izražaja ljeti kada su pod utjecajem izgrađenosti grada vrijednosti LST-a i temperature zraka vrlo visoke. One pogađaju ljudsko zdravlje, smanjenja je kvaliteta života gradskog stanovništva, veća je potrošnja energije, a raste i zagađenje zraka (Landsberg, 1981). Međutim, postoje i pozitivni utjecaji UHI-a kao što su manji troškovi za grijanje unutrašnjih prostora zimi, što je posljedica zagrijanosti grada.

LST je važan parametar korišten u klimatološkim istraživanjima jer omogućuje praćenje toplinskih obilježja podloga u urbanom području (Parastatidis i dr., 2017). Povezan je s albedom kao indikatorom refleksije Sunčevog zračenja; površina s velikom refleksijom ima visoke vrijednosti albeda. Što je površina bjelija, ona apsorbira manje Sunčeve radijacije u odnosu na tamnije površine. Manja apsorpcija znači i niži LST čime se smanjuje količina topline koju

zgrada apsorbira, a samim time i potreba za njezinim hlađenjem u toplom dijelu godine (Bonafoni i dr., 2016).

Zbog naglog razvoja tehnologije daljinskih istraživanja, danas se uz pomoć termičkih satelitskih senzora mogu dobiti precizne vrijednosti LST-a (Malakar i dr., 2018). Vodeću važnost u istraživanjima obilježja Zemljine površine ima Landsat satelitska misija. Njome se od 1972. prikupljaju vrijedni podaci korišteni u istraživanjima promjena zemljišnog pokrova (engl. *land cover*) i načina korištenja zemljišta (engl. *land use*) (USGS, 2020). Landsat sateliti trenutno u orbiti imaju prostornu rezoluciju od 30 metara kojom se relativno dobro mogu analizirati uočene promjene. Iako svaku točku na Zemlji snime jednom u 16 dana, zbog specifičnog položaja Zagreba na prijelazu između dviju satelitskih scena[1] ta je razlika u Zagrebu samo 8 dana, što značajno doprinosi vremenskoj razlučivosti.

Često je u znanstvenim istraživanjima korištenje Landsat satelitskih snimaka ograničeno na analizu manjeg broja scena. Problem je stvarala obrada velike količine podataka, tj. ograničenja softverske i hardverske računalne opreme. Mnogo toga je olakšano uspostavom *Google Earth Enginea* (*GEE*), platforme u *oblaku* za geoprostorne analize koja se sastoji od velikog broja baza podataka te ima iznimne sposobnosti obrade velike količine podataka (Gorelick i dr., 2017). Podacima se pristupa preko aplikacijskog programskog sučelja (engl. *Application Programming Interface*, API) i povezanog interaktivnog okruženja u kojemu se koristi *JavaScript* programski jezik. Obzirom da se tehnički dio odvija na Googleovim serverima, a ne lokalno na osobnom računalu cijeli proces je ubrzan i nudi mnogo više opcija za analizu. Na GEE-u su dostupni i Landsat podaci koji su u ovom radu korišteni za izračun LST-a i vegetacijskog indeksa normalizirane razlike (engl. *Normalized Difference Vegetation Index*, NDVI) kao glavnih parametara.

1.1. Predmet istraživanja

Predmet istraživanja ovog rada je utjecaj promjene obilježja podloge na promjenu LST-a u gradu Zagrebu. U zadnjih su 20-ak godina grad Zagreb i njegova okolica doživjeli velike promjene. Broj stanovnika Grada u razdoblju od 2001. do 2011. povećao za oko 20 tisuća, dok je procijenjeno da je taj broj 2018. bio veći za 15 tisuća stanovnika (Grad Zagreb, 2019). Van granica Grada također je došlo do porasta broja stanovnika, a njihov veći broj zahtijeva i

[1] Satelitska scena (engl. *satellite scene*) predstavlja područje Zemljine površine 170x185 km za Landsat. Sustav satelitskih scena osmišljen je kako bi se lakše manipuliralo globalnim satelitskim podacima.

izgradnju stambenih zgrada i prateće infrastrukture što dovodi do širenja izgrađene površine grada. Novoizgrađena područja svojim toplinskim obilježjima doprinose zagrijavanju grada i pojačavanju efekta UHI-a čije su posljedice najvećim dijelom negativne za stanovnike gradova (Anthony i Quatrocchi, 2005; Landsberg, 1981; Oke, 1969; Oke, 1987). Prema tome, postoji velika potreba za razumijevanjem složenih odnosa između izgrađenih površina i LST-a. Uz navedeno, nužno je uspostaviti korelaciju s drugim faktorima poput utjecaja vegetacije o kojemu ovise vrijednosti LST-a. U ovom radu će se na temelju četiri izabrana područja u gradu koja su doživjela promjenu obilježja podloge te dva koja nisu, prikazati kakav je to utjecaj imalo na njihova toplinska obilježja, tj. na promjene LST-a.

1.2. Ciljevi i hipoteze

Temeljem do sad iznesenih spoznaja proizlazi nekoliko osnovnih ciljeva ovog istraživanja:

1. Metodom satelitske detekcije ispitati toplinska obilježja u područjima grada Zagreba koja su zabilježila promjenu obilježja podloge.

2. Upotrebom *Google Earth Engine-a* izraditi toplinske karte Zagreba i karte NDVI-a te ga predstaviti kao korisni alat u geografsko-klimatološkim istraživanjima.

3. Utvrditi postojanje UHI-a i LUHI-a grada Zagreba.

4. Dokazati kako širenjem izgrađenih površina dolazi do jačanja intenziteta LUHI-a.

Iz navedenih ciljeva i na osnovu dosadašnjih spoznaja urbane klimatologije, postavljaju se sljedeće hipoteze:

H1. Promjene obilježja podloge dovele su do promjena LST-a.

H2. Na novoizgrađenim površinama u Zagrebu došlo je do porasta vrijednosti LST-a, dok na nepromijenjenim površinama nije došlo do značajnije promjene.

H3. Smanjenjem površina pod vegetacijom i povećanjem izgrađenih površina dolazi do stvaranja LUHI-a, a time i jačanja intenziteta UHI-a Zagreba.

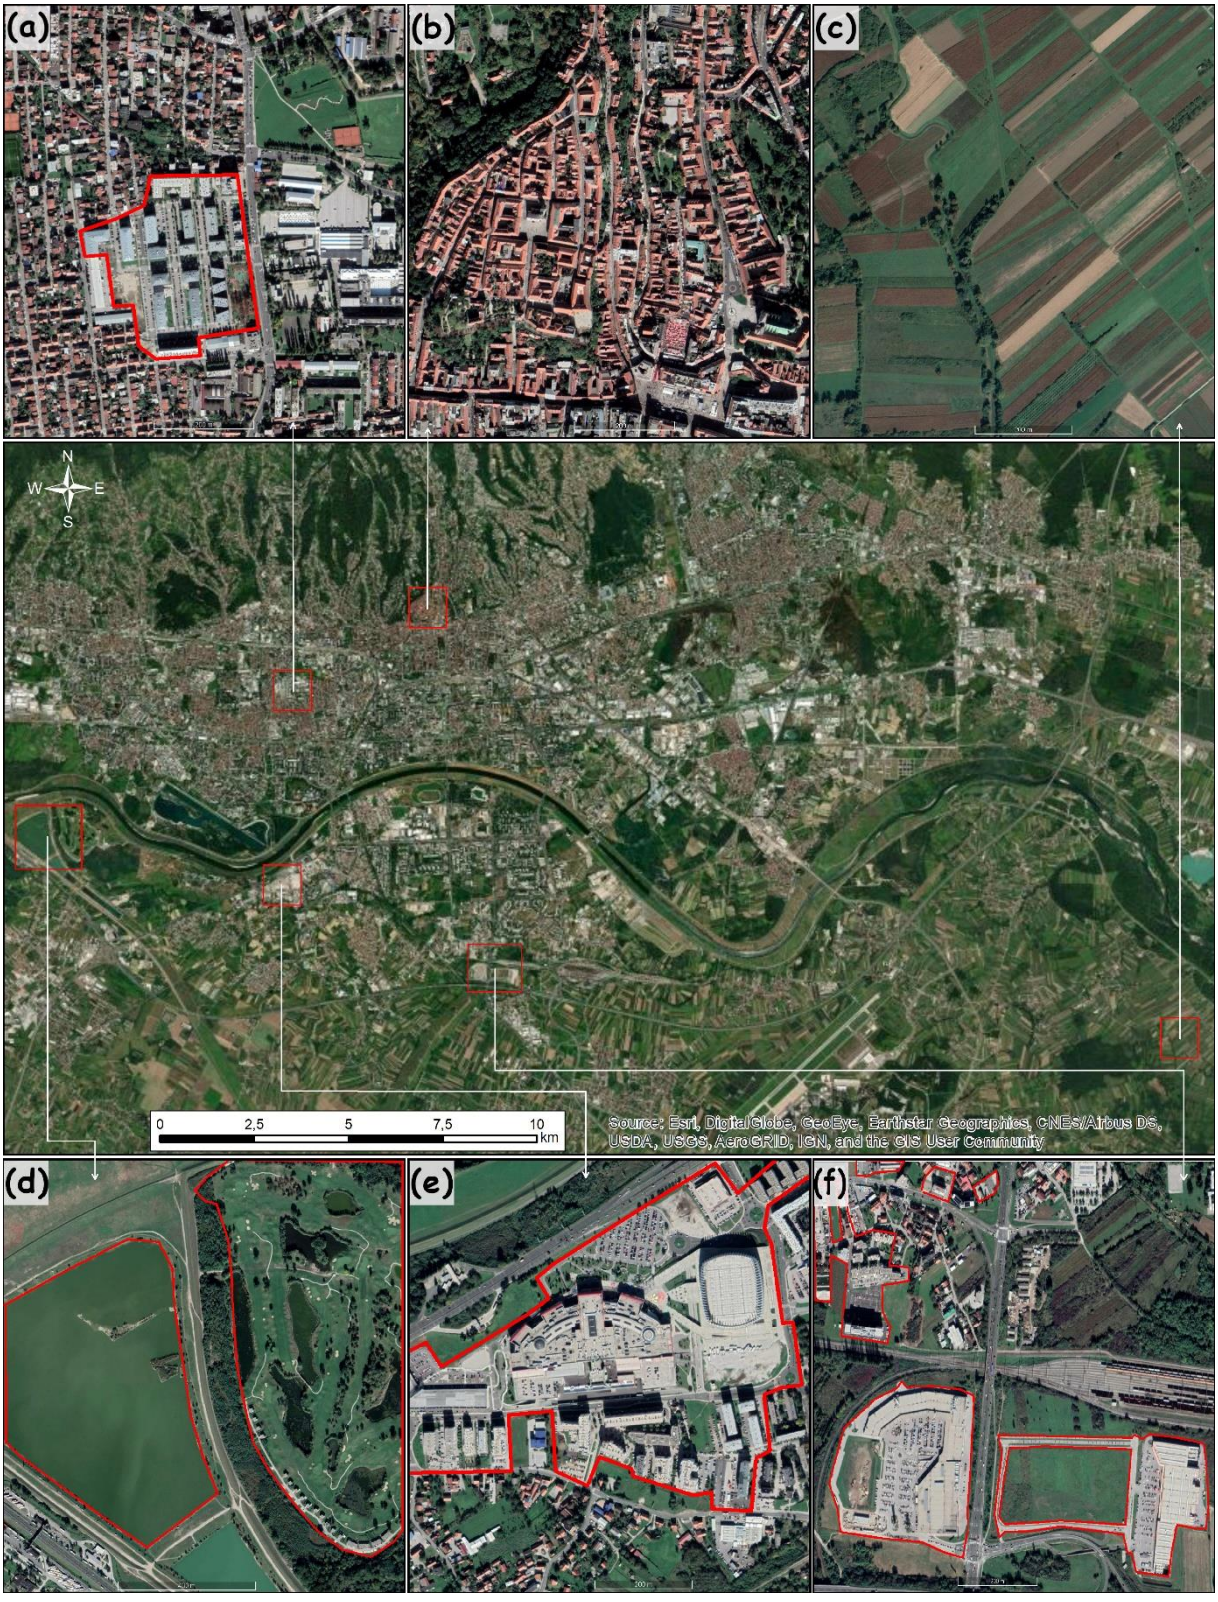
H4. LUHI su vidljivi i u zimskom i u ljetnom razdoblju.

1.3. Prostorni i vremenski obuhvat

Područje istraživanja čini izgrađeno područje grada Zagreba. Opća obilježja UHI-a Zagreba proizlaze iz mnoštva lokalnih klimatskih obilježja koja se javljaju na njegovom području, a ona su predmet istraživanja ovog rada. Naglasak je stavljen na lokalnu prostornu razinu i područja koja su antropogeno izmijenjena u zadnjih 20-ak godina za koja se pretpostavlja da zbog promjena u obilježjima podloge imaju primjetan lokalni toplinski utjecaj.

Kako bi se uočila područja na kojima je došlo do promjene podloge korišten je QGIS plug-in *trends.earth*. On nudi mogućnost izrade prostorno-vremenskih karata s petogodišnjim promjenama zemljišnog pokrova od 2000. do 2015. godine. Na osnovu toga odabrana su četiri područja kod kojih je uočena promjena obilježja podloge: *Arena Centar, Kanal Sava-Odra, Supernova i Bauhaus Buzin* te *Stambene zgrade Selska* (sl. 1). Korištena su i dva referentna područja bez promjena od kojih je jedno *Gornji grad* u samom središtu Zagreba, dok je drugo *ruralna okolica*, poljoprivredno zemljište u okolici Zagreba (sl. 1). Odabrana područja su približno istih dimenzija, osim *Kanala Sava-Odra* i *Supernove i Bauhausa Buzin* kod kojih je odabrano nešto šire područje zbog veličine uočene promjene.

U radu se uspoređuje utjecaj promjena obilježja podloge na toplinska obilježja odabranih područja za ljetno razdoblje 2000. i 2019. godine te zimsko 2000./2001. i 2019./2020. godine. Ljetno razdoblje uključuje mjesece: lipanj, srpanj, kolovoz i rujan, a zimsko: prosinac, siječanj, veljaču i ožujak. Iako su klimatološko ljeto i zima određeni sa tri mjeseca, dakle uz iznimku lipnja i prosinca u ovom slučaju, u radu su korištena četiri mjeseca koja predstavljaju ljetno i zimsko radzoblje, tj. topli i hladni dio godine. Naime, dodatan mjesec za pojedino razdoblje može povećati broj satelitskih snimaka uzetih u obzir što doprinosi reprezentativnosti podataka. Dodatan mjesec može omogućiti do čak četiri satelitske snimke više.



Sl. 1. Satelitske snimke istraživanih područja u Zagrebu 2019. godine: (a) *Stambene zgrade Selska*; (b) *Gornji grad*; (c) *ruralna okolica*; (d) *Kanal Sava-Odra*; (e) *Arena centar*; (f) *Supernova i Bauhaus Buzin*. Napomena: na slikama (a), (d), (e) i (f) crvene linije označuju novoizgrađeno područje u odnosu na 2000.; slike (b) i (c) prikazuju referentna područja

Izvor: ESRI World Imagery, 2018; Maxar Technologies, 2019.

2. Pregled dosadašnjih istraživanja

UHI je prvi put otkriven prije gotovo dva stoljeća kada je Luke Howard zamijetio da je u središtu Londona toplije nego u njegovoj okolici (Howard, 1833). Njegov rad smatra se prvim u okviru urbane klimatologije, no tek se 1970-ih godina ta disciplina počinje jasnije izdvajati kao znanstvena disciplina klimatologije (Mills, 2014). Jedan od njenih začetnika je Tim Oke (1969, 1973) koji među prvima 70-ih i 80-ih godina 20. stoljeća opisuje glavna obilježja gradskih klima, pa tako i UHI-a. Značajan je i njegov rad u kojemu se bavi energetskom bilancom grada (Oke, 1982). Također, po prvi puta izdvaja različite slojeve atmosfere iznad gradova, tzv. urbani granični sloj i sloj urbanog pokrivača (Oke, 1976, 1987).

Danas se zna da su gradovi, bez obzira na njihovu veličinu, uglavnom topliji od svoje okolice (Anthony i Quatrocchi, 2005). Ta razlika naglašenija je u većim gradovima, s više površine pokrivene umjetnim materijalima i više stanovnika. Zagreb je grad srednje veličine u europskim razmjerima te je za njega izvjesna pojava UHI-a. Postoji značajan broj radova koji su važni za razumijevanje UHI-a Zagreba, a da istraživanje temelje na analizi temperature zraka (Šegota, 1986; Šegota, 1987; Šegota, 1988; Hrabak-Tumpa, 1988; Ogrin, 2015; Ogrin i Krevs, 2015; Bonacci i Roje-Bonacci, 2018; Maradin i Filipčić, 2018). Bitno je istaknuti starija istraživanja Šegote (1986, 1987, 1987) i Hrabak-Tumpe (1988). Tada je moderna urbana klimatologija tek bila u svojim počecima na ovim prostorima, a oni su bili jedni od predvodnika. Šegota se u svojim radovima dotiče minimalnih, maksimalnih i srednjih temperatura zraka te ističe postojanje UHI-a Zagreba. Usto, uočava da je gušće izgrađeno gradsko područje u svim mjesecima toplije od okolice te da je njhova temperaturna razlika najveća u ljetnim i zimskim mjesecima, no u godišnjem prosjeku iznosi do 1 °C (Šegota, 1986). S druge strane, Hrabak-Tumpa (1988) detaljnije analizira sam toplinski otok i potvrđuje Šegotin (1986) intenzitet UHI-a Zagreba od 1 °C. Maradin i Filipčić (2018) proučavali su intenzitet UHI-a Zagreba. Na osnovu srednjih minimalnih temperatura postaja *Zagreb-Grič* i *Zagreb-Botinec* u razdoblju 1995. – 2014. uočili su vrijednost intenziteta od 2,8 °C. Time je potvrđeno da su vrijednosti u središtu grada (*Zagreb-Grič*) znatno više nego u njegovoj okolici (*Zagreb-Botinec*), ali i da je od 1979./1980. godine (Hrabak-Tumpa, 1988) do danas, došlo do porasta intenziteta UHI-a. Ogrin (2015) i Ogrin i Krevs (2015) uočili su trend porasta srednje temperature zraka za postaju *Zagreb-Grič* od 1950. – 2010. u vrijednosti od +1,3/50 god. za navedeno razdoblje, dok za razdoblje 1862. – 2010. trend iznosi +0,9 °C/100 god. Pojačavanje trenda može se objasniti jačanjem intenziteta UHI-a Zagreba što je uzrokovano intenzivnom urbanizacijom grada.

Problem koji se često javlja u istraživanjima UHI-a je nedostatak gradskih meteoroloških postaja. Osim toga, terestrička mjerenja rezultiraju točkastim podacima, dok satelitski podaci nude mogućnost izračuna kontinuiranog polja podataka LST-a te su time istraživanja prostorno reprezentativnija (Li i dr., 2013). Tako se mogu točno prostorno izdvojiti UHI i LUHI. Prvi izračuni LST-a podacima sa satelita dobiveni su 70-ih godina 20. stoljeća te su zahtijevali brojne korekcije, od atmosferskih do geometrijskih. Danas su dostupni USGS-ovi korigirani setovi podataka za gotovo cijelu Zemlju čime je znatno ubrzana obrada podataka.

Mali je broj radova koji su se bavili analizom vrijednosti LST-a i UHI-a za Zagreb, ali i za Hrvatsku. U pravilu, za područje Zagreba ističu se dva diplomska rada s Geodetskog fakulteta Sveučilišta u Zagrebu (Kovačić, 2014; Čmrlec, 2019). Kovačić (2014) obradom Landsat 8 satelitskih podataka dobio je karte raspodjele urbanih toplinskih otoka i indeksa kritičnosti okoliša za Grad Zagreb 20. i 29. srpnja 2013. godine. Čmrlec (2019) je izradio tematske karte LST-a i NDVI-a za sva četiri godišnja doba i također odredio lokacije UHI-a u Gradu Zagrebu. Nešto je veći broj istraživanja koja se bave LST-om ili NDVI-om za područje Hrvatske. Kovačić (2015) proveo je usporedbu LST-a Osječko-baranjske i Splitsko-dalmatinske županije u proljeće i jesen, a opisao i površinsku temperaturu mora u Splitsko-dalmatinskoj županiji. Babić (2016) također određuje LST za šire područje grada Splita prema snimkama s početka ljeta i sredine jeseni. Neki od ovih autora (Babić, 2016; Čmrlec, 2019) proveli su usporedbu LST-a i temperature tla na dubini od 2 cm za metorološke postaje DHMZ-a. Uočili su sličnost u vrijednostima, no temperatura tla na dubini od 2 cm nije isto što i temperatura površine tla, stoga se podaci DHMZ-a ne mogu koristiti za određivanje točnosti LST-a dobivenog satelitskom detekcijom. Duplančić Leder i dr. (2016) koriste Landsat 7 i Landsat 8 podatke za izračun LST-a metropolitanskog područja grada Splita za ljetne i zimske mjesece. Analiziraju nekolicinu snimaka 2000. i 2015. godine te uočavaju da je zbog značajne urbanizacije i gubitka zelenih površina ojačao efekt UHI-a, a posebno u ljetnim mjesecima. Sličnim se bave i u radu Duplančić Leder i Leder (2018) za područje grada Mostara gdje uz LST računaju i NDVI te zaključuju da na smanjivanje UHI-a utječe povećanje površine pod vegetacijom. Potrebno je istaknuti projekt *CroClimGoGreen,* voditeljice izv. prof. Ivane Herceg Bulić, koji je trenutno u tijeku, a čiji je glavni cilj istraživanje UHI-a Zagreba pomoću numeričkih simulacija u uvjetima sadašnje i buduće klime.

Postoji veliki broj radova koji su se od 70-ih godina 20. stoljeća bavili razvojem formula za izračun LST-a i NDVI-a. Danas se njihov izračun uglavnom temelji na nekolicini formula koje su se pokazale kao najpouzdanije. Izračun LST-a proveden je s različitim formulama za

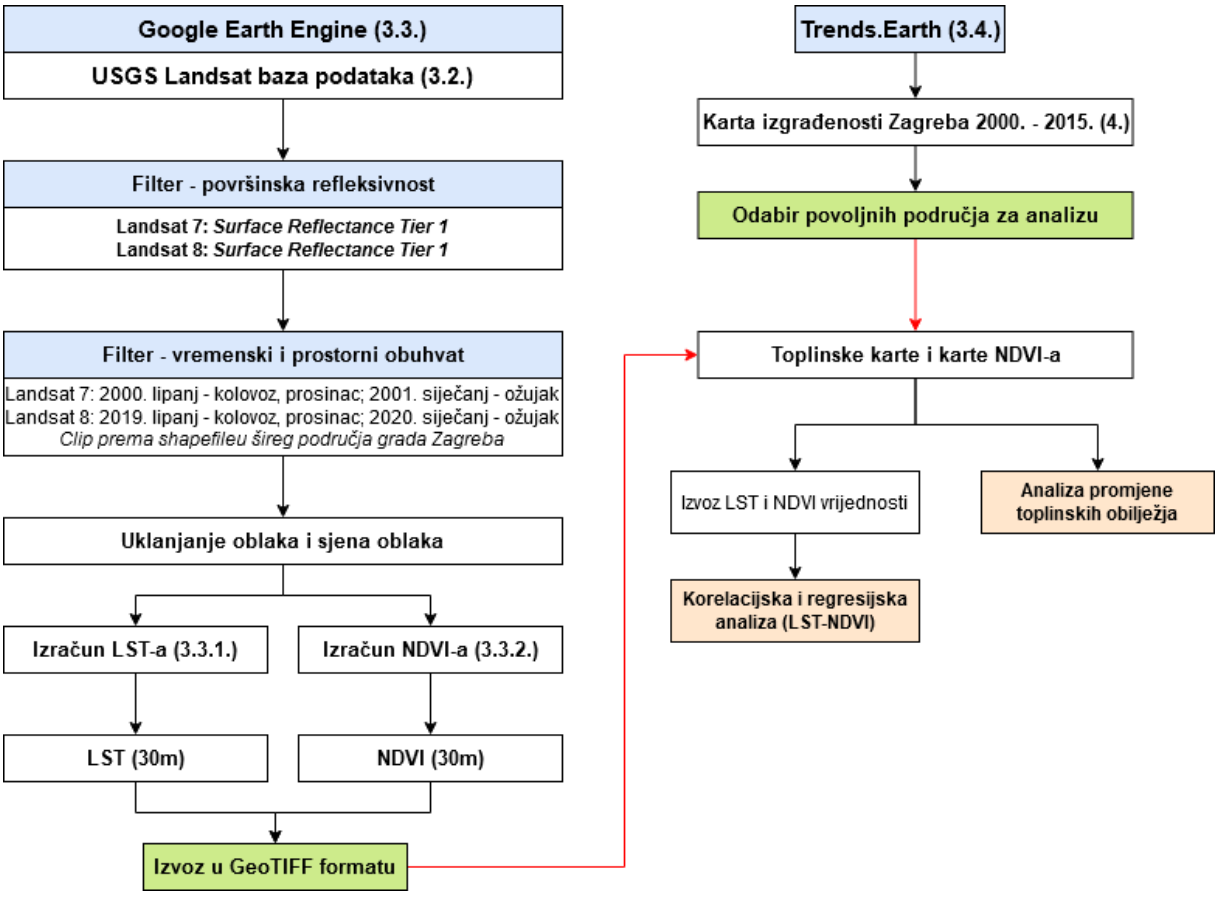
pojedine parametre. Za emisivnost površine tla prema Sobrino i dr. (2004), za udio vegetacije prema Carlson i Ripley (1997) te za LST na temelju prethodnih parametara prema Artis i Carnahan (1982). Formulu za izračun NDVI-a osmislio je Crippen (1990).

Pronađen je mali broj radova koji se isključivo bavi lokalnim promjenama podloge te opisom toplinskih obilježja do kojih je došlo pod utjecajem takvih promjena. Većina radova proučava toplinske promjene na osnovu površine cijelog grada prema promjenama LULC (engl. *land use/land cover*) (Hu i Jia, 2009; Zhou i dr., 2014; Alavipanah i dr., 2015; Aslan i Koc-San, 2016; Estoque i dr., 2016; Majkowska i dr., 2016; Brunori i dr., 2017; Wang i dr., 2017; Xiao i dr., 2018; Lemus-Canovas i dr., 2020). Međutim, Mackey i dr. (2012), Bonafoni i dr. (2016) i Bonafoni i dr. (2017) raspravljaju o utjecaju koji promjene na lokalnoj razini imaju na LST i NDVI. Bonafoni i dr. (2016) ističu povezanost LST-a s promjenama albeda. Na primjeru građevina velikih površina u gradu Terni u Italiji, tj. njihovih krovova uočili su smanjenje albeda u periodu od 2000. do 2015. te porasta LST-a za 2,3 °C. Iako se u ovom radu ne analizira albedo kao jedan od parametara, prema vizualnim obilježjima podloge moguće je usporediti albedo pojedinih površina i tako opisati njihove eventualne razlike u LST-u. Bonafoni i dr. (2017) također za grad Terni uočili su smanjenje LUHI-a između 2006. i 2014. na primjeru obnove manjeg dijela grada. Mackey i dr. (2012) uz albedo su analizirali i NDVI na raznih primjerima lokalne prostorne razine u Chicagu na osnovu 1998. i 2010. godine. Zamjetili su da je bojanje krovova u svjetlije boje, većinom bijele, u gusto izgrađenoj četvrti grada smanjilo LST za 3,4 °C. Za industrijsku zonu LST je snižen za čak 5 °C. Sadnja redova drveća u dijelu ulica grada dovela je do smanjenja LST-a od 1,1 °C, a zamjena asfalta travnatom površinom do smanjenja od 0,9 °C. Prema tome, autori su zaključili da veći utjecaj na smanjenje LST-a ima povećanje refleksivnosti površine negoli sadnja vegetacije. Međutim, time nisu analizirali ukupni ohlađujući utjecaj koji vegetacija ima na temperature zraka. S druge strane, veliki je broj autora koji istražuju utjecaj zelenih površina u gradovima na snižavanje vrijednosti LST-a (Yue i dr., 2007; Gabor i Jombach, 2009; Molnar, 2016; Guha i dr., 2018; Guha i Govil, 2020). Potrebno je istaknuti Molnara (2016) koji se detaljno bavio NDVI-om i LST-om u Budimpešti. Uočio je da je u vrlo vrućim ljetnim danima znatno izražen utjecaj vegetacije na snižavanje vrijednosti LST-a. U središtu grada gradske zelene površine snižavaju LST za oko 10 °C u odnosu na kontinuirano urbano područje srednje visine zgrada.

3. Podaci i metode obrade

3.1. Metodološki okvir

Kako bi se metodom satelitske detekcije uspješno izradile toplinske karte i karte NDVI-a potrebno je provesti složenu pripremu samih podataka. U tome veliku ulogu ima GEE, koji olakšava pristup i obradu Landsat podataka. U radu su korišteni podaci spektralnih kanala Landsat 7 i Landsat 8 satelita. Njihova priprema sastoji se od filtriranja skupa satelitskih snimaka prema vremenskom i prostornom obuhvatu, uklanjanja oblaka i njihovih sjena sa snimaka te izračuna LST-a i NDVI-a za šire područje Zagreba. Tada se pristupa geoprostornoj i statističkoj analizi odabranih područja koja se provodi u ArcGIS-u i QGIS-u. Za odabir povoljnih područja za analizu korišten je *trends.earth* QGIS plugin. Za ta područja provedena je analiza promjene toplinskih obilježja u ovisnosti o uočenim promjenama obilježja podloge. Kako bi se proučio utjecaj vegetacije na vrijednosti LST-a provedena je korelacijska i regresijska analiza LST-a i NDVI-a. Sažeta shema metodologije primijenjene u ovom radu prikazana je na sl. 2.



Sl. 2. Metodologija korištena u radu

Napomena: u zagradama su istaknuta poglavlja u kojima su koraci detaljnije opisani

3.2. Landsat podaci

Landsat predstavlja najdužu satelitsku misiju za istraživanja površine Zemlje čiji je početak bio 1972. godine (Roy i dr., 2014). Tehničke značajke optičkih senzora kontinuirano su napredovale, što je omogućilo veću razlučivost detalja na snimkama (USGS, 2020). Sve ostale satelitske misije imaju bolju vremensku, ali lošiju prostornu rezoluciju[2] (Duplančić Leder i dr., 2016). Stoga su se za provedbu ovog rada Landsat satelitski podaci pokazali vrlo prikladni. Njihovom upotrebom može se „pogledati" u prošlost te tako istražiti promjene na površini Zemlje i njihove posljedice, što je cilj ovog rada. Danas se Landsat podaci koriste u gotovo svim disciplinama istraživanja okoliša te su jedan od najvažnijih izvora podataka o površini Zemlje (Gutman i Masek, 2012). Landsat satelitske snimke postale su besplatne i javno dostupne 2008. godine.

U ovom su radu korišteni podaci multispektralnih i termičkih kanala dvaju satelita iz Landsat misije, Landsat 7 i Landsat 8. Landsat 7 operativan je od travnja 1999. godine te je opremljen ETM+ senzorom (engl. *Enhanced Thematic Mapper Plus*) koji prikuplja podatke u osam spektralnih kanala (*USGS*, 2019a). Prostorna rezolucija snimaka iznosi 15 m u pankromatskom, 30 m u multispektralnim i 120 m u termičkom kanalu. U svibnju 2003. godine uređaj *scan line corrector (SLC)* na ETM+ senzoru je doživio kvar koji nije bilo moguće popraviti, što do danas uzrokuje kontinuirani gubitak oko 22% podataka sa svake Landsat 7 scene, a samo je njen središnji dio potpuno upotrebljiv. Kvar SLC-a ne utječe na rezultate ovog rada jer se analiza provodi za 2000. i 2001. godinu kada je uređaj još uvijek bio ispravan. Landsat 8 operativan je od veljače 2013. godine i sastoji se od dva senzora, OLI (engl. *Operational Land Imager*) i TIRS (engl. *Thermal Infrared Sensor*) koji prikupljaju podatke u dvanaest spektralnih kanala (USGS, 2019b). Prostorna rezolucija ista je kao kod Landsata 7 uz izuzetak dva termička kanala koji su rezolucije 100 metara. Kako bi se podaci svih kanala uskladili, termičkim kanalima su rezolucije metodom kubične konvolucije prilagođene na 30m.

Glavni izvor Landsat podataka su USGS-ovi *Landsat 7 Surface Reflectance Tier 1 i Landsat 8 Surface Reflectance Tier 1* kojima je pristupljeno *online* putem GEE-a. Površinska refleksija (engl. *surface reflectance*) predstavlja udio Sunčevog zračenja koji se reflektira od Zemljine površine te dolazi do Landsat senzora. Setovi podataka također su atmosferski korigirani. Naime, tijekom prolaska kroz atmosferu dio elektromagnetskog zračenja biva raspršen ili apsorbiran od strane plinova, oblaka i aerosola čime do senzora ne dolaze podaci koji

[2] Primjerice: GOES (2 km – svakih 15 minuta), AVHRR (1,1, km – dva puta dnevno), MODIS (1 km – 1-2 dana), ASTER (90 m – 16 dana)

predstavljaju stanje na površini Zemlje te je potrebna spomenuta korekcija (Masek i dr., 2006). Podaci o površinskoj refleksiji osnova su za izračun vrijednosti LST-a i NDVI-a. Usto, u metapodacima su dostupne maske[3] za oblake, njihovu sjenu, vodene površine i snijeg razvijene pomoću CFMASK algoritma od strane USGS-a. Od spomenutog, u radu se koriste maske za oblake i sjene oblaka radi njihovog uklanjanja sa snimaka.

Svaka satelitska scena definirana je putanjom (engl. *path*) i redom (engl. *row*) prema WRS-2 (*World Reference System*) sustavu. Područje Zagreba prekrivaju dvije Landsat scene istih dimnezija od 170x185 km za oba satelita. Za prvu su putanja i red 189 i 28 (189/28) koja područjem istraživanja prolazi oko 9:30 i 9:41 sati UTC (engl. *Coordinated Universal Time*) ovisno o satelitu i razdoblju unutar godine (tab. 1). Drugoj su putanja i red 190 i 28 (190/28), a područjem istraživanja prolazi oko 9:36 i 9:47 sati UTC. Lokalno vrijeme prolaska je UTC + 2 sata, tj. otprilike između 11:30 i 11:47 sati.

Za potrebe klimatskih istraživanja bitno je osigurati snimanje podataka u isto ili slično vrijeme dana, ali i godine kako bi međugodišnji podaci bili usporedivi. Razlika između vremena snimanja scena tokom dana između satelita i za oba razdoblja iznosi oko 10 minuta (tab. 1). Ona je dovoljno mala kako bi se odstupanja u prikupljenim podacima zbog toga mogla zanemariti. Ujedno, Landsat 8 snima scene 189/28 i 190/28 tri dana ranije unutar godine od Landsata 7. Razmak snimanja dviju scena unutar razdoblja je sedam pa devet dana te je broj snimaka u mjesecu između tri i četiri. Prema tome, broj dostupnih snimaka za sva razdoblja je petnaest, osim za zimsko razdoblje 2019./2020. kada ih je četrnaest (tab. 1).

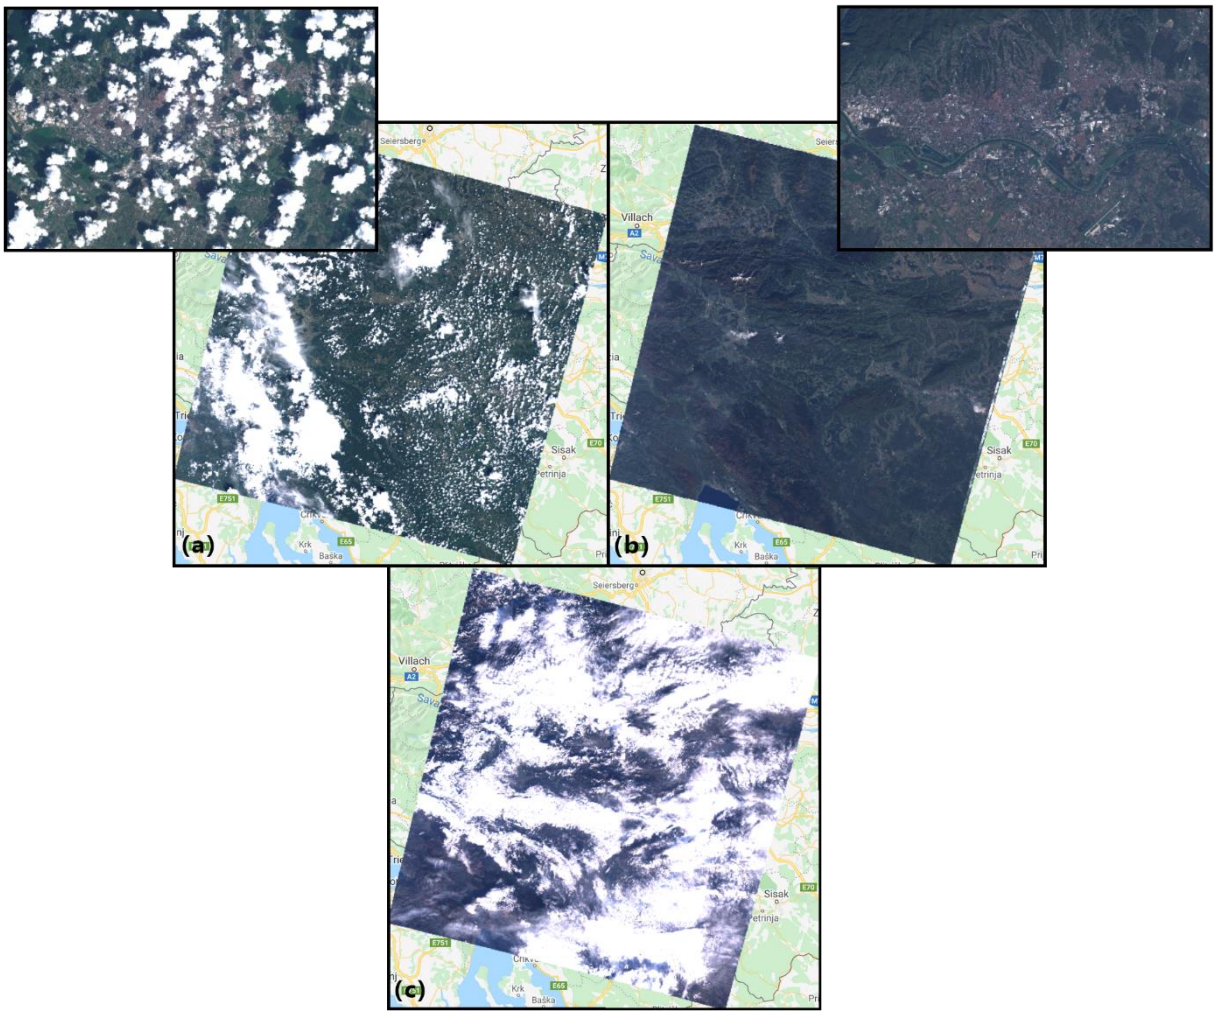
Unatoč većem broju dostupnih snimaka, nisu sve uzete u obzir za izračun istraživanih parametara. Naime, njihovi dijelovi često znaju biti prekriveni oblacima ili sjenama oblaka zbog čega do satelitskih senzora ne dolaze podaci s površine Zemlje već s vrha oblaka (sl. 3). Takve podatke potrebno je zanemariti u izračunima, tj. provesti njihovo uklanjanje (Mateo-Garcia i dr., 2018). Uklanjanje (engl. *masking*) oblaka i sjena oblaka provedeno je u GEE-u pomoću informacija iz Landsat setova podataka. Tim se pikselima na satelitskim snimkama nakon uklanjanja dodjeljuje *no_data* vrijednost čime se oni ne koriste za kasniji izračun. Bitno je napomenuti kako su greške moguće, no rijetke su. Tako se neki pikseli mogu prepoznati kao oblaci ili njihova sjena, iako to ustvari nisu, pa se uklanjanju. Oblaci zbog velikih dimenzija mogu prekrivati veliki dio istraživanog područja čime se gube vrijedni podaci (sl. 3). Primjerice,

[3] Maska (engl. *mask*) je algoritmom dobiven sloj oblaka i njegovih sjena koji služi za njihovo uklanjanje s odabranih satelitskih snimaka.

Tab. 1. Vremena snimanja Landsat 7 i Landsat 8 scena korištenih u radu za Zagreb za zimsko i ljetno razdoblje

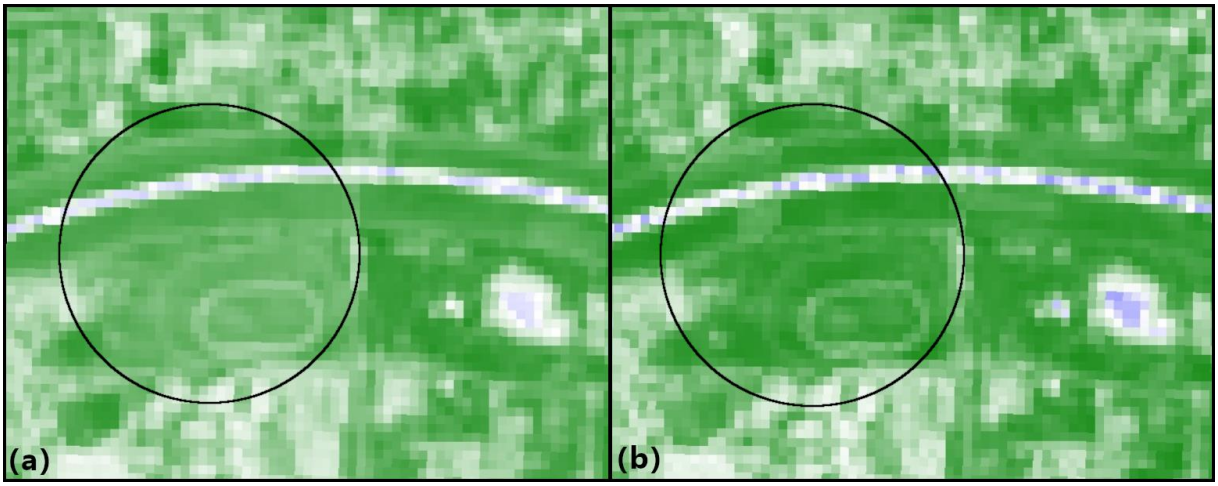
Zimsko razdoblje				***Ljetno razdoblje***			
Landsat 7		**Landsat 8**		**Landsat 7**		**Landsat 8**	
Datum	**Vrijeme (UTC) [hh:mm: ss]**	**Datum**	**Vrijeme (UTC) [hh:mm: ss]**	**Datum**	**Vrijeme (UTC) [hh:mm: ss]**	**Datum**	**Vrijeme (UTC) [hh:mm: ss]**
08/12/2000	09:30:23	05/12/2019	09:40:24	06/06/2000	09:38:04	03/06/2019	09:46:00
15/12/2000	09:36:38	12/12/2019	09:46:34	15/06/2000	09:31:54	12/06/2019	09:39:53
24/12/2000	09:30:30	/	/	22/06/2000	09:38:01	19/06/2019	09:46:07
31/12/2000	09:36:38	28/12/2019	09:46:30	01/07/2000	09:31:41	28/06/2019	09:39:58
09/01/2001	09:30:30	06/01/2020	09:40:17	08/07/2000	09:37:47	05/07/2019	09:46:11
16/01/2001	09:36:42	13/01/2020	09:46:27	17/07/2000	09:31:29	14/07/2019	09:40:01
25/01/2001	09:30:34	22/01/2020	09:40:13	24/07/2000	09:37:29	21/07/2019	09:46:14
01/02/2001	09:36:42	29/01/2020	09:46:22	02/08/2000	09:31:13	30/07/2019	09:40:07
10/02/2001	09:30:27	07/02/2020	09:40:08	09/08/2000	09:37:17	06/08/2019	09:46:21
17/02/2001	09:36:39	14/02/2020	09:46:18	18/08/2000	09:31:06	15/08/2019	09:40:13
26/02/2001	09:30:23	23/02/2020	09:40:05	25/08/2000	09:37:12	22/08/2019	09:46:26
05/03/2001	09:36:34	01/03/2020	09:46:13	03/09/2000	09:30:52	31/08/2019	09:40:17
14/03/2001	09:30:20	10/03/2020	09:39:59	10/09/2000	09:36:56	07/09/2019	09:46:29
21/03/2001	09:36:25	17/03/2020	09:46:06	19/09/2000	09:30:31	16/09/2019	09:40:22
30/03/2001	09:30:12	26/03/2020	09:39:50	26/09/2000	09:36:40	23/09/2019	09:46:35

za izračun NDVI-a za ljetno razdoblje 2000. u jednom je od piksela korišteno 10 snimaka od dostupnih 15 što znači da je taj piksel pokriven oblakom ili njegovom sjenom na pet snimaka. Iako bi za što kvalitetnije rezultate optimalno bilo imati sve snimke bez oblaka, to je često nemoguće. Povrh svega, problem je izraženiji zimi kada je zbog učestalijih ciklona nebo češće zastrto oblacima (sl. 3c). Tada se uklanja i veći broj piksela, a konačni rezultati nisu reprezentativni u onoj mjeri koliko bi bili s manje naoblake. Zbog toga će u idućim poglavljima rezultati dobiveni za zimsko razdoblje biti podrobnije proučeni kako bi se uočile moguće nepravilnosti.



Sl. 3. Primjer prekrivenosti scene 190/28 oblacima: (a) Landsat 8 RGB kompozit 19.6.2019.; (b) Landsat 8 RGB kompozit 25.10.2019.; (c) Landsat 8 RGB kompozit 29.1.2020.

U slučaju neuklanjanja oblaka sa snimaka, vrijednosti bi uključivale oblake i bile neodgovarajuće za analizu. NDVI vrijednosti prije i nakon uklanjanja oblaka mogu se vidjeti na sl. 4 i primjeru dijela Zagreba kod hipodroma. Primjetno je „zamućenje“ NDVI-a na sl. 4a što je posljedica prisutnosti oblaka. Isto vrijedi i za LST, gdje su neodgovarajuće vrijednosti posljedica temperature vrha oblaka ili njegove sjene.



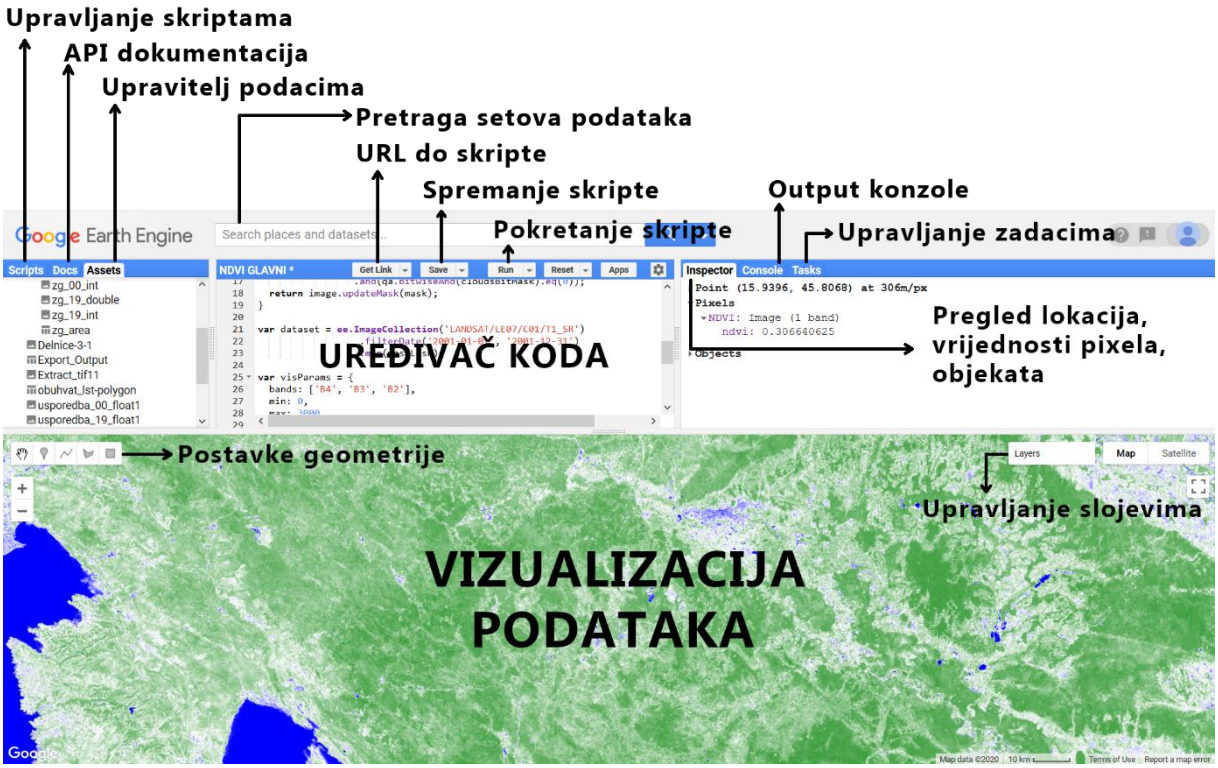
Sl. 4. Modifikacija NDVI vrijednosti zbog utjecaja oblaka, 6.8.2019.; (a) prije uklanjanja oblaka; (b) nakon uklanjanja oblaka

3.3. Google Earth Engine

GEE je dizajniran za pohranu i obradu velike količine podataka, koje se mjere u petabajtima[4]. Nakon što su Landsat podaci postali javno dostupni 2008. godine *Google* ih je kontinuirano arhivirao i kasnije povezao u svojoj bazi podataka u *oblaku* koja je dostupna preko GEE-a. Jednostavan pristup i *user-friendly* sučelje stvaraju efikasno okruženje za razvoj interaktivnih podataka i algoritama (Mutanga i Kumar, 2019). Prednost GEE-a je što omogućuje provođenje složenih analiza i istraživačima koji nemaju računala velikih procesorskih snaga. Kreiranje programa omogućeno je putem Python i JavaScript programskih jezika. U ovom radu za izradu kodova korišten je *JavaScript* programski jezik koji nudi preko 800 različitih funkcija koje se u složenosti kreću od jednostavnih matematičkih do složenih geostatističkih funkcija, strojnog učenja i naprednih obrada slika (Gorelick i dr., 2017).

Samo sučelje GEE-a omogućava lako snalaženje (sl. 5). Izrada skripte odvija se u uređivaču koda (engl. *code editor*). Po završetku izrade rezultati se mogu vizualno prikazati, no mogu biti i izvezeni u različitim tipovima podataka, poput CSV, GeoTIFF, SHP, TFRecord i drugih. Za potrebe ovog rada podaci su izvezeni u GeoTIFF formatu i kao takvi su spremni za kasniju analizu u GIS-u. U izborniku sučelja GEE-a *Inspector* omogućen je pregled vizualiziranih podataka za svaki piksel, a u *Console* se mogu vizualizirati grafikoni i drugi statistički podaci i prikazi.

[4] 1 petabajt (PB) = 1 048 575 gigabajta (GB)



Sl. 5. Google Earth Engine sučelje

Neke od osnovnih funkcija u GEE-u korištenih u radu bit će predstavljene s nekoliko primjera. Za definiranje područja interesa (engl. *Region of Interest*, ROI) potrebno je uvesti *shapefile* analiziranog područja ili ručno izraditi geometriju u *Postavkama geometrije* (sl. 5). Kako bi se u daljnjem dijelu skripte pozivalo na područje istraživanja potrebna je izrada varijable *roi* koja se definira pomoću funkcije:

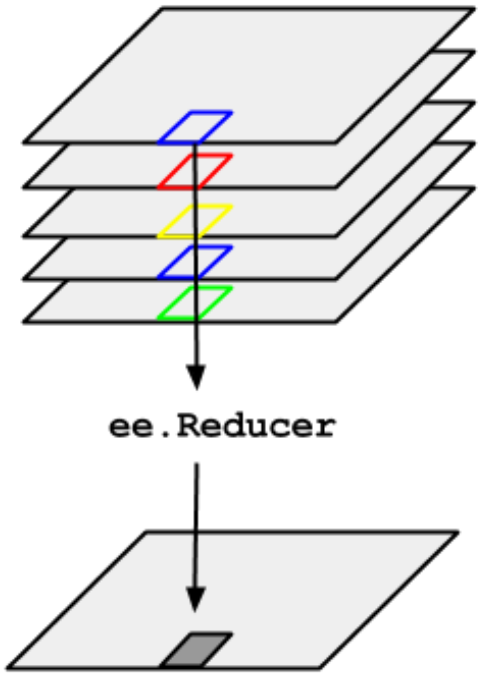
var roi = (zagreb.first().geometry().bounds());

Vremenski okvir rada odnosi se na dva zimska i dva ljetna razdoblja. Za pojedino razdoblje potrebno je definirati skup svih tada dostupnih satelitskih snimaka. Kako bi se to ostvarilo koristi se ee.*ImageCollection* funkcija. *ImageCollection* je skup svih satelitskih snimaka određenog područja u određenom vremenskom periodu, a funkcija za njeno definiranje je:

var LS8R = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
.filterBounds(roi.bounds())
.filterDate('2019-06-01', '2019-09-30')

U prvom retku se poziva na skup snimaka Landsat 8 satelita, a u drugom i trećem se definiraju prostorni i vremenski obuhvat. Tako se smanjuje vrijeme za izračun, ali i izvoz

željenih podataka. Nakon što su definirani vremenski i prostorni obuhvat moguće je nastaviti s daljnjim razvijanjem skripte. Primjerice, za izračun statističkih vrijednosti u svakom pikselu koristi se funkcija ee.*Reducer*. Neke od vrijednosti su: medijan, standardna devijacija, srednja vrijednost, minimum, maksimum i druge. Obzirom da su sve satelitske scene istih dimenzija i pozicija, svaki njihov piksel odgovara istom području na površini Zemlje. Stoga je moguće provesti izradu kompozit snimke kojoj vrijednost svakog piksela odgovara odabranoj statističkoj vrijednosti svih snimaka područja Zagreba (sl. 6). LST i NDVI vrijednosti u ovom radu su srednje vrijednosti, pa je vrijednost svakog piksela srednja vrijednost svih neuklonjenih piksela iz ulaznih snimaka koji se prije svega uklanjaju radi oblaka i njihovih sjena.



Sl. 6. Ilustracija primjene *ee.Reducer* na *ImageCollection*
Izvor: ImageCollection Reductions, 2020.

Za vizualizaciju obrađenih podataka na Google Maps podlogu koristi se funkcija:

Map.addLayer (imeVarijable);

Podaci su tada vizualizirani kao rasterski set podataka, gdje svaki piksel predstavlja stvarnu površinu veličine 30 sa 30 metara, tj. 900 m^2.

3.3.1. Metoda izračuna LST-a

U radu su korišteni skupovi satelitskih snimaka u kojima su kanali s refleksijom s površine Zemlje već korigirani za atmosferske greške, a termički kanali su preračunati u temperaturu odsjaja na satelitu u Kelvinima. Izračun LST-a je zato uvelike ubrzan. Naime, prije nego su satelitske snimke bile dostupne u korigiranom stanju bilo je potrebno provesti vlastito određivanje parametara atmosferske korekcije i pretvaranje dobivenih digitalnih vrijednosti u temperaturu kao u Duplančić Leder i dr. (2016).

Za dobivanje vrijednosti LST-a korištena je NDVI metoda za emisivnost[5] površine tla (engl. *Land Surface Emissivity*, LSE). Za početak, potrebni su podaci o vrijednostima LSE koja se prema Sobrino i dr. (2004) računa kao: $\boldsymbol{\varepsilon = 0.004*P_v+0.986}$, gdje je P_v udio vegetacije. P_v se prema Carlson i Ripley (1997) izračunava kao:

$$P_v = \left[\frac{NDVI - NDVI_{\min}}{NDVI_{\max} - NDVI_{\min}} \right]^2$$

Gdje je $NDVI_{min}$ 0,2, a $NDVI_{max}$ 0,5. Vrijednosti ispod 0,2 su golo tlo, a više od 0,5 gusta vegetacija (Sobrino i Raissouni, 2000). Nakon što je dobiven LSE moguće je izračunati vrijednosti LST-a prema formuli Artis i Carnahan (1982):

$$LST = \frac{T_B}{1 + \left(\frac{\lambda \cdot T_B}{\rho} \right) \cdot \ln(\varepsilon)} \quad - \quad 273.15$$

gdje su:

T_B = vrijednost temperature svjetlosti na satelitu (u Kelvinima)

λ = 10,89 μm (središnja valna dužina termičkog 10. kanala na Landsat 8)
= 11,45 μm (središnja valna dužina termičkog 6. kanala na Landsat 7)

$\rho = h*c/\sigma = 1{,}38*10^{-2}$ m*K [*σ (Boltzmanova konstanta)* = $1{,}38*10^{-23}$ J/K, *h (Planckova konstanta)* = $6{,}626*10^{-34}$ J*s, *c (brzina svjetlosti)* = $2{,}998*10^{8}$ m/s

Završni korak je oduzimanje vrijednosti 273,15 od rezultata formule kako bi se dobila temperatura u °C. Za izračun LST-a za oba satelita korišten je jedan termički kanal. Naime,

[5] Emisivnost govori o tome koliko topline površina zrači pri određenoj temperaturi, tj. koliko lako jedna površina emitira toplinu. Emisivnost površine igra ulogu u određivanju utjecaja materijala na UHI (Hui, 2016).

Landsat 8 posjeduje dva termička kanala i LST se može računati temeljem oba. Riječ je o 10. i 11. kanalu OLI senzora, tzv. TIRS1 i TIRS2. No, u *Data Users Handbook* Landsat 8 satelita predlažu zaobilaženje termičkog 11. kanala zbog njegovih netočnosti te korištenje isključivo termičkog 10. kanala (USGS, 2019b).

3.3.2. Metoda izračuna NDVI-a

NDVI je najzastupljeniji vegetacijski indeks u istraživanjima vegetacijskog pokrova (Hashim i dr., 2019). Ukazuje na udio vegetacije, ali predstavlja i obilježja podloge. Iz tog razloga je odabran kao jedan od parametara pomoću kojeg se može procijeniti utjecaj vegetacije na vrijednosti LST-a. Očekuje se značajna korelacija s LST-om zbog pretpostavke da smanjenjem udjela vegetacije dolazi do povećanja LST-a.

Promatranjem određenih spektara valnih duljina reflektiranih s površine Zemlje moguće je odrediti NDVI. Formula za njegov izračun je: **NDVI = (NIR – Red) / (NIR + Red)** (Crippen, 1990). *NIR* označava valne duljine blizu infracrvenog dijela spektra (engl. *Near Infrared*), a *Red* crvenog, oboje reflektiranih s površine Zemlje. Za Landsat 7 satelit *NIR* odgovara 4. kanalu ETM+ senzora, a *Red* 3. kanalu. S druge strane, zbog većeg broja spektralnih kanala OLI senzora, za Landsat 8 satelit *NIR* odgovara 5. kanalu, a *Red* 4. kanalu. Izračun NDVI-a u GEE-u proveden je upotrebom funkcije *image.normalizedDifference* koja je osmišljena zbog vrlo česte upotrebe indeksa normalizirane razlike u daljinskih istraživanjima.

Vrijednosti NDVI-a variraju od -1 do +1 (tab. 2). Kako je upotreba NDVI-a češća na prirodnim površinama, potrebno je smjestiti izgrađene površine negdje u definiranom rasponu. One spadaju u razred NDVI-a od -0,1 do 0,2. Međutim, najčešće su im vrijednosti oko nule, tj. imaju blago pozitivne vrijednosti što se pokazalo i na primjeru Zagreba.

Tab. 2. Vrijednosti NDVI-a i odgovarajuća obilježja podloge

Vrijednost NDVI-a	**Obilježje podloge**
-1 do 0	Vodene površine
-0,1 do 0,2	Gole stijene, pijesak, snijeg i izgrađene površine
0,2 do 0,5	Grmoliko bilje i travnjaci
0,5 do 1	Gusta vegetacija

Izvor: Kshetri, 2018; Hashim i dr., 2019

3.4. Obrada i analiza podataka

Već je spomenut *trends.earth* QGIS *plug-in* koji je korišten za uočavanje novoizgrađenih površina u Zagrebu do 2015. godine. Razvijen je u suradnji organizacije *Conservation International* s NASA-om. Metodom koju su razvili moguće je detektirati promjene pokrova zemljišta temeljem Landsat scena od 2000. do 2015. i podacima indeksa nepropusnosti površine (Trends.Earth, 2020). Rezultati ovog alata nisu dostupni na godišnjoj razini, već u petogodišnjim intervalima. Razlog tomu je što tek nakon određenog vremena ima smisla vizualno prikazati konkretne promjene u pokrovu zemljišta nekog područja. To je za *trends.earta* pet godina, dok primjerice najpoznatija dostupna baza podataka pokrova zemljišta *Copernicus Land Cover* ima šestogodišnje intervale. Stoga podaci *trends.eartha* za 2019. i 2020. godinu nisu dostupni. Ipak, obzirom na visoku prostornu rezoluciju, dostupne promjene su dobro uočene, a alat pruža kvalitetan uvid u intenzitet prostornog širenja grada.

Za pregled povijesnih satelitskih snimaka koristio se program *Google Earth Pro*. On se temelji na satelitskim snimkama Landsat i Copernicus satelita. Područje Zagreba moguće je većim dijelom vidjeti u kvalitetnijoj rezolucije od 2000. godine što je potrebno za uočavanje promjena obilježja podloge. Iz *Google Earth Pro*-a su izvezene slike odabranih područja istraživanja te su georeferencirane u ArcGIS-u radi daljnje analize.

Glavna analiza podataka provedena je u ArcGIS i QGIS računalnim programima za geoprostorne analize. Podaci generirani u GEE-u su u WGS84 koordinatnom sustavu koji se nastavio koristiti u ArcGIS-u. Na grafičkim prikazima vrijednosti LST-a izdvojena su područja promjene kako bi se lakše pratila promjena toplinskih obilježja uzrokovana promjenom obilježja podloge. Također, vrijednosti LST-a su vizualizirane putem jedinstvenih razreda koji se temelje na najnižem i najvišem zabilježenom LST-u u ljetnom, odnosno zimskom razdoblju. Toplinska obilježja su za pojedina analizirana područja prikazana pomoću horizontalnih toplinskih profila te prikazom broja piksela po temperaturnim razredima od 1 °C. Statistički pokazatelji svakog analiziranog područja prikazani su za područje gdje je došlo do promjene obilježja podloge, neizmijenjeni dio područja te za cijelo područje. Promatrani pokazatelji LST-a su: minimalna i maksimalna vrijednost, raspon vrijednosti, srednja vrijednost te standardna devijacija. Srednja vrijednost LST-a računa se prema svim pikselima rastera te daje reprezentativnu vrijednost LST-a kroz istraživano razdoblje.

Korelacija NDVI-a i LST analizirana je isključivo za ljetna razdoblja 2000. i 2019. godine. Razlog za odabir ljetnog razdoblja naspram zimskog jest veći utjecaj NDVI-a na vrijednosti LST-a ljeti, nego je to zimi, pa je tada očekivana i bolja korelacija podataka. Kako bi se

predstavio što recentniji utjecaj vegetacije na LST regresijska analiza je provedena samo za ljetno razdoblje 2019. godine. Zavisna varijabla je LST, a nezavisna NDVI. Rezultati regresije te upotreba Pearsonovog koeficijenta korelacije [r] ukazuju na stupanj i smjer statističke povezanosti između setova podataka.

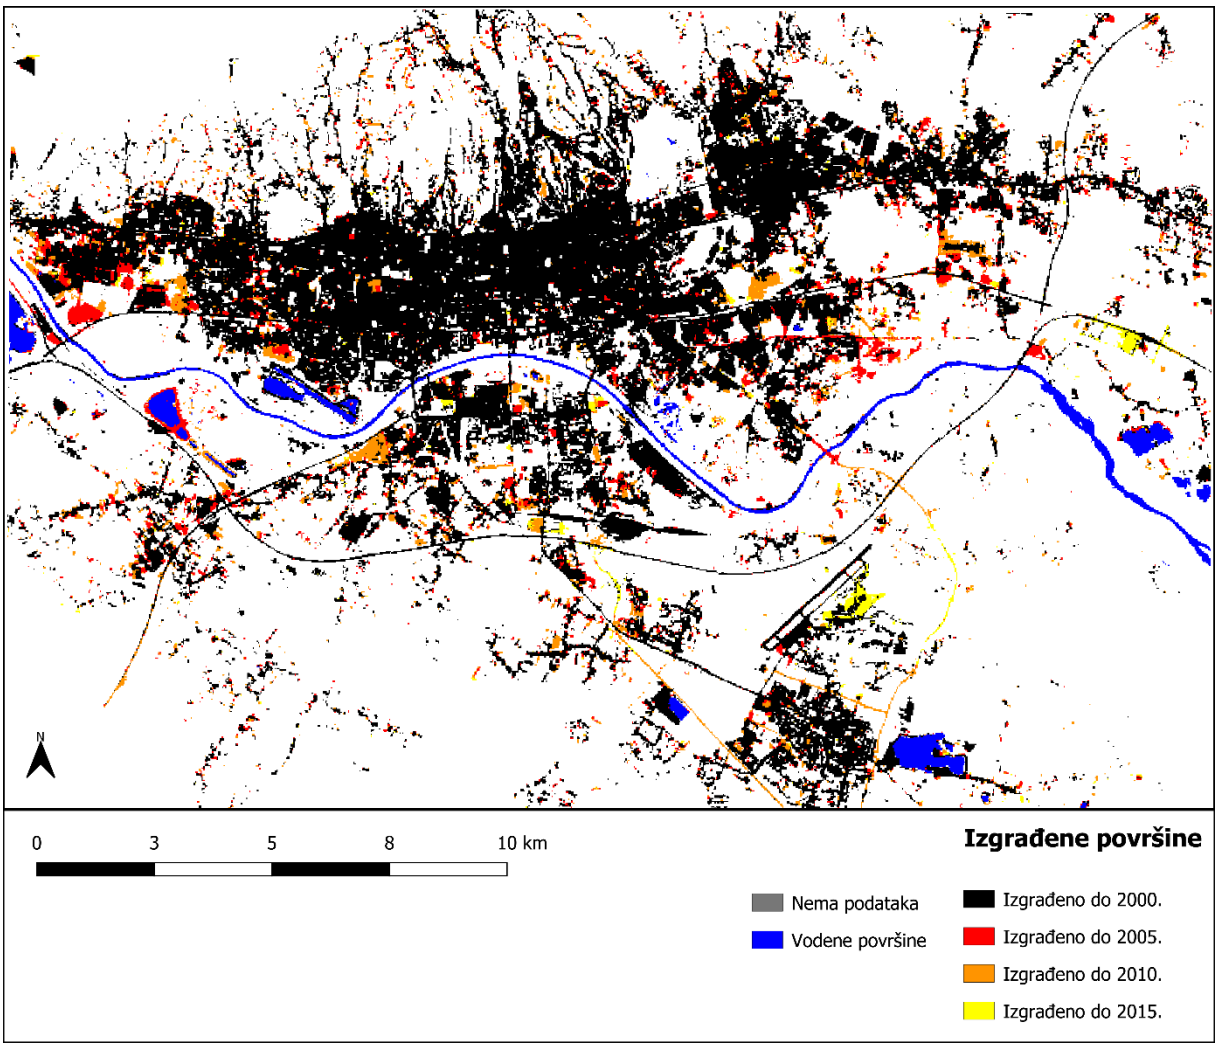
Statistička obrada podataka provedena je u Microsoft Office programu *MS Excel*, a dio grafičke obrade uz pomoć *GIMP 2.10.* računalnog programa.

4. Promjene u izgrađenosti grada Zagreba od 2000. do 2015. godine

U istraživanjima UHI-a potrebno je odrediti lokaciju i vrijeme kada je došlo do promjene obilježja podloge. Na taj se način može provesti usporedba obilježja podloge prije i poslije utvrđene promjene, što uključuje LST i NDVI. Rezultati *trends.earth*-a temelje se na algoritmima koji dobro raspoznaju izgrađene površine, a k tomu posjeduju i preciznu 30-metarsku prostornu rezoluciju. Bitno je napomenuti da nije korištena baza podataka o pokrovu zemljišta *Corine Land Cover* (CLC) čija je prostorna reprezentacija nešto lošija od *trends.eartha*, gdje je minimalna širina kartiranih jedinica 25ha/100 m (HAOP, 2015). Rezultati su stoga generalizirani, a snalaženje je otežano i brojnim klasama pokrova zemljišta. Stoga se *trends.earth* temeljen na Landsat podacima pokazao kao koristan alat. Iako su podaci dostupni do 2015. godine, svejedno nude kvalitetan izvor podataka za uočavanje većeg dijela promjena koje su zahvatile Zagreb u periodu istraživanja ovog rada. Potrebno je naglasiti kako rezultati dobiveni ovom metodom ne mogu biti u potpunosti točni, tj. i oni su djelomično generalizirani obzirom da se prostornom rezolucijom od 30 metara (900 m^2) ne mogu precizno razlučiti sve promjene u izgrađenosti površine. U tu svrhu bi rezolucija satelita trebala biti što veća, optimalno u rezoluciji od nekoliko metara čemu se danas pojedini sateliti i približavaju.

Korištenjem *trends.earth*-a dobivena je karta prikazana na sl. 7. Na njoj se mogu uočiti područja gdje su se dogodile promjene u razdoblju između 2000. i 2015. godine te je pomogla u odabiru područja za koja će se istražiti promjene toplinskih obilježja. Izgradnja novih površina u gradu je rijetko zabilježena u njegovom središnjem dijelu, što je posljedica nedostatka slobodnih površina, a to je primjetno i u Zagrebu (sl. 7). Češće dolazi do izmjene same izgrađene površine. Na primjer, radi produženja Branimirove ulice u Zagrebu srušene su industrijske i stambene građevine te su zamijenjene asfaltom. Takve promjene su relativno male u kontekstu cijelog grada. Njih se može uočiti metodom satelitske detekcije, no tu je ponovni problem prostorne rezolucije satelita čime je interpretacija rezultata otežana. Zbog toga se pokušao odabrati jedan primjer promjene podloge veće površine što bliže središtu grada kako

bi se rezultati mogli usporediti s onima gdje je do promjene došlo na rubu grada. Te je kriterije zadovoljilo područje *Stambene zgrade Selska*, dok su sva ostala odabrana područja udaljenija od središta.



Sl. 7. Izgrađene površine šireg područja grada Zagreba od 2000. do 2015. godine

Period intenzivne izgradnje zabilježen je od 2000. do 2010. godine (sl. 7). Vidljiva su područja u kojima je došlo do izgradnje novih površina na rubovima grada, ali i širenja na obronke Medvednice. Područja u kojima je došlo do promjene podloge *Arena Centar*, *Stambene zgrade Selska* i *Supernova Buzin*, koji će se obrađivati u idućim poglavljima, izgrađeni su između 2005. i 2010. Nakon 2010. najznačajniji novoizgrađeni objekti su IKEA te novi terminal zračne luke Zagreb, oboje na samim rubovima grada. Također, izgrađen je i *Bauhaus Buzin* čiji je toplinski utjecaj istraživan u ovom radu.

Sva novoizgrađena područja dovode do promjena u apsorpciji kratkovalne i dugovalne radijacije, veće emisije aeropolutanata, izmjene turbulencije vjetra i obrasca otjecanja vode, itd. (Oke, 1976). Sve navedeno potencijalno doprinosi jačanju efekta UHI-a grada kao cjeline, a tako se lokalno mogu stvarati i LUHI, što se ispituje u idućim poglavljima.

5. Toplinska obilježja šireg područja grada Zagreba

Prvi rezultat ovog rada su toplinske karte Zagreba dobivene na temelju Landsat 7 i Landsat 8 satelitskih snimaka. Njima će se prikazati opća toplinska obilježja grada Zagreba, a također su osnova za analizu toplinskih obilježja područja s promjenom podloge.

Na sl. 8 prikazane su vrijednosti LST-a za ljetna i zimska razdoblja. Pri prikazu LST-a za zimsko razdoblje javljaju se određeni problemi u odnosu na ljetno razdoblje koje je potrebno argumentirati. Problem koji se javlja u zimskom razdoblju je već spomenuta česta naoblaka. Zbog toga je zimi veliki broj nepovoljnih snimaka, pa dolazi do uklanjanja velikog broja piksela prekrivenih oblacima i njihovom sjenom, a time i manje reprezentativnih rezultata LST-a za zimsko razdoblje. Iz tog razloga su provjerena obilježja prekrivenosti oblacima svih satelitskih snimaka dostupnih za istraživana razdoblja (tab. 3).

Tab. 3. Broj satelitskih snimaka Zagreba u ovisnosti u stupnju prekrivenosti oblacima

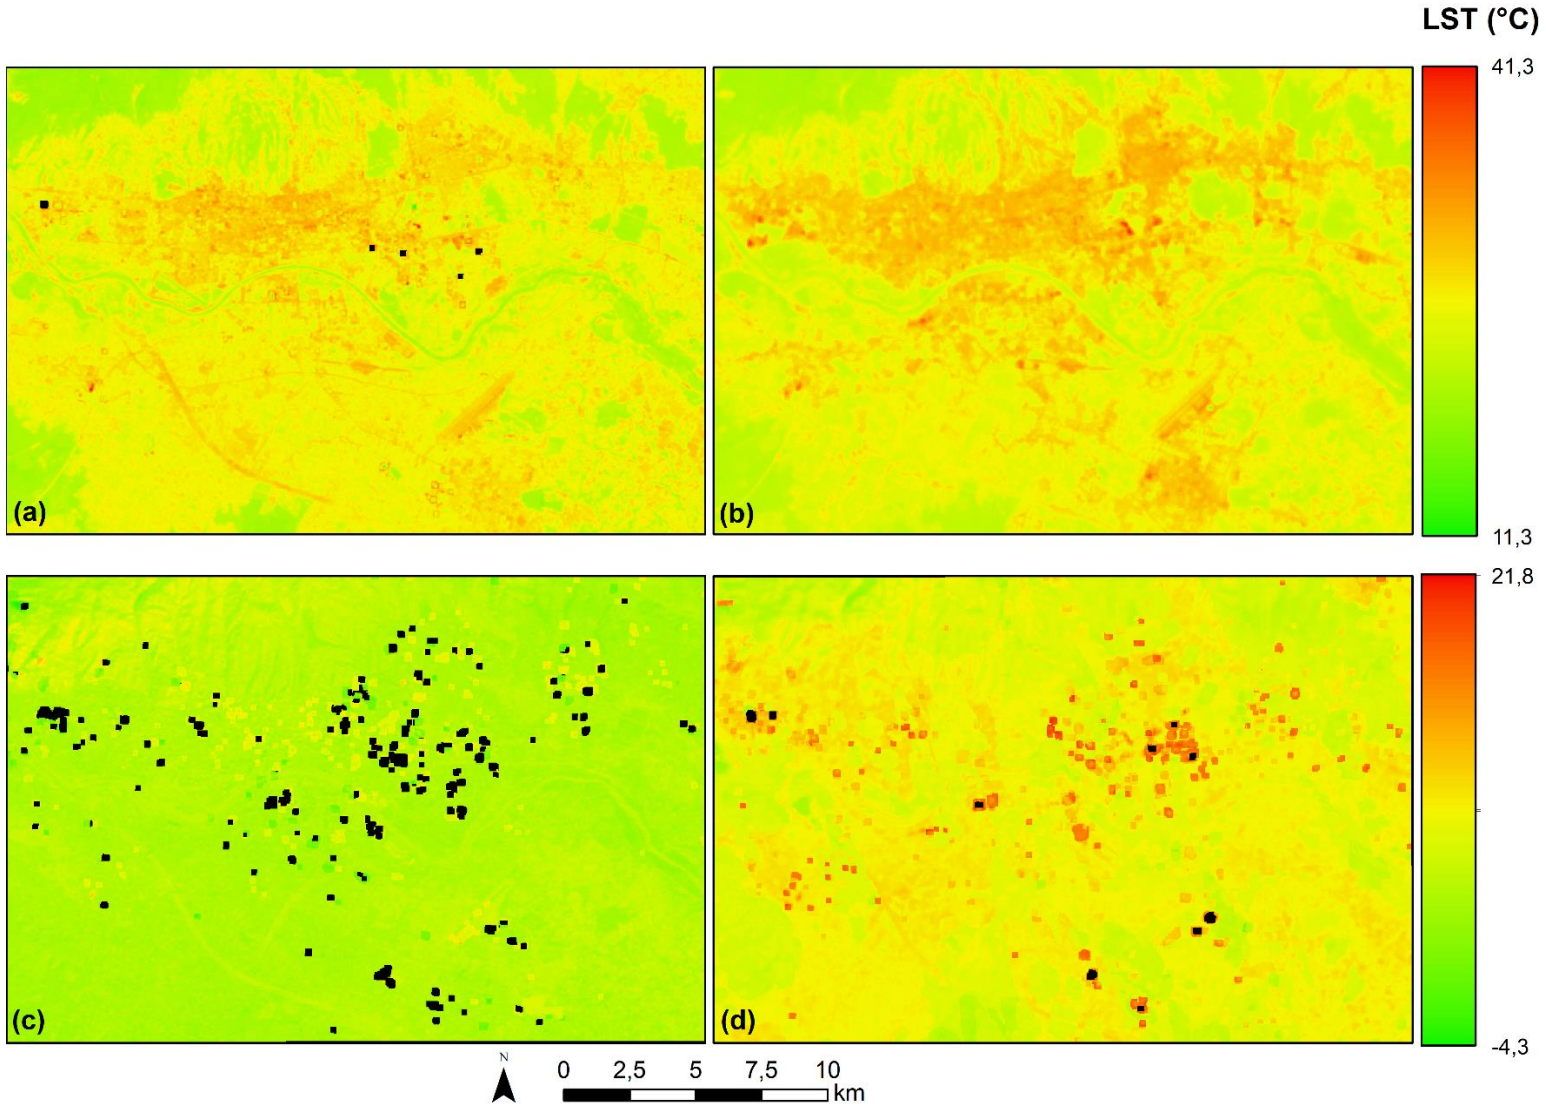
Obilježje snimke	Zimsko razdoblje		Ljetno razdoblje	
	2000./2001.	2019./2020.	2000.	2019.
U potpunosti prekrivena oblacima	12	8	3	4
Djelomično prekrivena oblacima	1	3	3	4
Bez prekrivenosti oblacima	2	3	9	7

Za ljetno razdoblje područje Zagreba je u potpunosti prekriveno oblacima na samo tri od petnaest snimaka 2000. godine, tj. četiri od petnaest 2019. godine. Dakle, najveći broj povoljnih satelitskih snimaka predstavljaju one s djelomičnom prekrivenošću te bez prekrivenosti oblacima. U tom su pogledu ljeta vrlo slična jer postoji ukupno dvanaest takvih snimaka za ljetno razdoblje 2000. i jedanaest za 2019. godinu zbog čega se za ljetna razdoblja (sl. 8a, sl. 8b) vrlo dobro uočavaju toplinske karakteristike Zagreba, a i srednja vrijednost LST-a je znatno reprezentativnija. Zato se većina istraživanja LST-a i provode ljeti kada je veća vjerojatnost

pronalaženja kvalitetnih snimaka bez oblaka (Bonafoni i dr., 2016; Hofierka i dr., 2020; Molnar, 2016).

Zimska razdoblja su očekivano pokazala najveći broj snimaka u potpunosti prekrivenih oblacima s njih dvanaest od maksimalno petnaest za 2000./2001. zimsko razdoblje, tj. osam od maksimalno četrnaest snimaka za 2019./2020. Posljedica su samo tri povoljne snimke za 2000./2001. i šest za 2019./2020. Također, snimke s djelomičnom prekrivenošću mogu prekrivati pojedina analizirana područja u radu, a druga ne. Uzrok tomu je prostorna raspodjela oblaka i njihovih sjena na snimkama koje su djelomično prekrivale područje Zagreba. To znači da broj korištenih snimaka za srednje vrijednosti LST-a varira od piksela do piksela, a isto tako i za istraživana područja. Stoga vrijednosti LST-a za zimsko razdoblje mogu biti nepouzdane jer se srednja vrijednost temelji na malom broju satelitskih snimaka, iako ih je maksimalno dostupno četrnaest, odnosno petnaest (tab. 3).

Nakon uklanjanja nepovoljnih piksela sa snimaka slijedi njihovo preklapanje pomoću funkcije za izračun srednje vrijednosti LST-a. Tamo gdje je došlo do uklanjanja piksela stvara se diskontinuitet u podacima pa nakon preklapanja to izgleda kao na sl. 8c i sl. 8d gdje dio piksela ima *no_data* vrijednosti. Što to znači za rezultate? Primjerice, za dio analiziranog područja *Arena centra* za zimsko razdoblje 2019./2020. godine srednja vrijednost LST-a dobivena je na osnovu dvije satelitske snimke, a za ostatak područja na osnovu četiri satelitske snimke. Dakle, na dijelu područja došlo je do uklanjanja piksela na dvije snimke više negoli u ostatku područja. Iz tog su razloga za pojedine dijelove istraživanih područja s promjenom podloge uočeni nepouzdani podaci. Tom se problemu pokušalo doskočiti odabirom samo jedne snimke za svako zimsko razdoblje. Ipak, javila su se dva problema. Za početak, na snimkama je još uvijek određena zastupljenost niske naoblake ili magle zbog koje se ti pikseli uklanjanju. A još važnije, nije bilo moguće odabrati snimke što bližih datuma unutar oba zimska razdoblja kako bi toplinske karte bile uspredive. Zbog navedenih razloga nije bilo moguće provesti metodu s jednom snimkom za svako zimsko razdoblje zbog čega se koristila metoda srednjih vrijednosti. No, obzirom na sve do sada iznesene spoznaje potreban je oprez i kritički pristup tijekom analize i interpretacije rezultata zimskog razdoblja.



Sl. 8. Toplinske karte s vrijednostima LST-a na području grada Zagreba za: (a) ljetno razdoblje 2000.; (b) ljetno razdoblje 2019.; (c) zimsko razdoblje 2000./2001.; (d) zimsko razdoblje 2019./2020. *(Napomena: crni pixeli predstavljaju no_data vrijednosti)*

Vrlo bitan čimbenik o kojemu ovisi usporedba ljetnih i zimskih razdoblja su vremenske prilike. Naime, za što pouzdaniju usporedbu vrijednosti LST-a najpovoljnije bi bilo kada bi prosječne temperature u razdobljima 2000./2001. i 2019./2020. bile što sličnije. Stoga je izvršena klimatološka analiza ljetnog i zimskog razdoblja u istraživanim godinama. DHMZ redovno objavljuje mjesečne biltene u kojima se osvrće na klimatološke prilike te daje ocjenu odstupanja srednjih mjesečnih temperatura zraka od prosječnih vrijednosti za standardni period (1961.-1990.) (DHMZ, 2000; 2001; 2019a; 2020a). Zimsko razdoblje 2000./2001. ima prosječno odstupanje temperature zraka 4,0 °C (tab. 4). U 2019./2020. jedino za siječanj nije bilo značajnih odstupanja srednjih mjesečnih temperatura od prosječnih vrijednosti, a odstupanje iznosi 3,1 °C. Oba zimska razdoblja su bila znatno toplija od višegodišnjih prosječnih vrijednosti te bi prema tome usporedba LST vrijednosti trebala biti reprezentativnija.

Za ljetno razdoblje 2000. srpanj i rujan su pokazali blago pozitivna odstupanja od 0,8 °C. No, lipanj i kolovoz su zato bili ekstremno topliji od višegodišnjeg prosjeka (tab. 4). Ljetno razdoblje 2019. slično je onom iz 2000., a jedino je rujan bio topao, dok su svi ostali mjeseci bili vrlo ili ekstremno topliji. Prosječno odstupanje iznosi 2,1 °C za 2000. te 2,5 °C za 2019. godinu. Usporedba ljetnih razdoblja mogla bi pokazati nešto više vrijednosti LST-a u 2019. godini, što će biti provjereno pomoću referentnih postaja i primijenjeno na ostalim analiziranim područjima s promjenom obilježja podloge.

Tab. 4. Odstupanja srednjih mjesečnih temperatura zraka (°C) u zimskim i ljetnim razdobljima od prosječnih vrijednosti (1961.-1990.) za meteorološku postaju *Zagreb-Grič*

Mjesec	**Zimsko razdoblje**		**Mjesec**	**Ljetno razdoblje**	
	2000./2001.	**2019./2020.**		**2000.**	**2019.**
Prosinac	3,7 (Vrlo toplo)	3,1 (Vrlo toplo)	*Lipanj*	3,1 (Ekstremno toplo)	4,6 (Ekstremno toplo)
Siječanj	4,8 (Vrlo toplo)	1,1 (Normalno)	*Srpanj*	0,8 (Toplo)	1,7 (Vrlo toplo)
Veljača	3,0 (Toplo)	5,1 (Vrlo toplo)	*Kolovoz*	3,7 (Ekstremno toplo)	2,5 (Vrlo toplo)
Ožujak	4,5 (Vrlo toplo)	/*	*Rujan*	0,8 (Normalno)	1,1 (Toplo)

Izvor: DHMZ, 2000; 2001; 2019a; 2020a

**Napomena: bilten za ožujak 2020. objavljen je tijekom pisanja rada, no zbog potresa koji je zadesio Zagreb 22.3. DHMZ nije objavio srednju mjesečnu temperaturu za taj mjesec*

Također, izvjestan je trend porasta prosječne temperature zraka, a utjecaj klimatskih promjena moguć je i na LST. Prema Ogrin i Krevsu (2015) uočen je porast od +0,9 °C / 100 godina za meteorološku postaju *Zagreb-Grič* u razdoblju između 1862. i 2010. Godine. Za

razdoblje 1951. – 2010. porast je naglašeniji i iznosi 1,3 °C / 50 godina. Evidentno je da je dio porasta LST-a uzrokovan klimatskim promjenama uz utjecaj promjena obilježja podloge. Navedenu vezu proučavaju Bonacci i Roje-Bonacci (2018) na primjeru meteorološke postaje *Zagreb-Grič* u razdoblju 1881. - 2017. Ističu kako je urbanizacija imala primaran i značajan utjecaj na promjene minimalne temperature zraka. Statistički značajan porast minimalne temperature zraka zabilježen je od 1970-ih do danas te ga primarno objašnjavaju efektom UHI-a. S druge strane porast maksimalne temperature započeo je tek 20-ak godina kasnije. Uočili su jači utjecaj klimatskih promjena i UHI-a u periodu od siječnja do kolovoza, a manji od rujna do prosinca. Međutim, naglašavaju problem diferencijacije utjecaja klimatskih promjena i UHI-a na porast temperature zraka.

Nakon provjere okolnosti poput utjecaja satelitskih snimaka te vremenskih prilika i klimatskih promjena na vrijednosti LST-a moguće je pristupiti analizi statističkih pokazatelja za šire područje grada Zagreba (tab. 5). Ljetno razdoblje ima vrlo slične maksimume za 2000. i 2019. godinu. Minimum 2000. godine je poprilično nizak, što je provjereno u GEE-u, no nije uočen razlog zašto je tomu tako. Moguće je da je riječ o softverskoj grešci u GEE-u, no ona se ne može potvrditi, ali niti isključiti. Također je pregledan set podatka i uočeno je da svega 0,2 % svih piksela 2000. godine ima vrijednost LST-a niže od 18,8 °C. Srednja vrijednosti 2000. godine viša je za 0,4 °C 2019. godine. S obzirom da je standardna devijacija u obje godine bila jednaka, 2,4 °C, može se reći kako su ljetna razdoblja bila sličnih toplinskih obilježja i prema tome su povoljna za daljnju analizu i usporedbu. Ljeto 2019. ostalo je obilježeno kao ljeto toplinskih valova te iznadprosječne topline (DHMZ, 2019), isto kao i ljeto 2000. godine.

Tab. 5. Osnovni statistički pokazatelji LST-a (°C) šireg područja grada Zagreba

Statistički pokazatelj	**Zimsko razdoblje**		**Ljetno razdoblje**	
	2000./2001.	**2019./2020.**	**2000.**	**2019.**
Minimum	-4,3	0,8	11,3	19,6
Maksimum	13,0	21,8	41,3	40,4
Raspon	17,3	21,0	30	20,8
Srednja vrijednost	4,3	8,3	25,7	26,1
Standardna devijacija	1,12	1,8	2,4	2,4

Zimsko razdoblje 2000./2001. ima sve pokazatelje niže nego zimsko razdoblje 2019./2020. godine. Rezultati se sada mogu povezati sa spomenutom problematikom satelitske detekcije. Za svako se razdoblje razlikuje broj snimaka, ali i datum kada su snimljene. U 2000./2001. dvije korištene snimke su snimljene 24. prosinca i 17. veljače te bilježe vrijednosti LST-a između 4

i 8 °C. S druge strane, 2019./2020. četiri korištene snimke su snimljene 6. i 21. siječnja te 10. i 17. ožujka. Posljednje dvije bilježe vrlo visoki zimski LST od 22 – 25 °C. Prema tome može se pretpostaviti da će zimske vrijednosti LST-a biti značajno uvjetovane raspodjelom dostupnih snimaka bez naoblake unutar zimskog razdoblja. Tomu u prilog govori i gotovo dvostruko veća srednja vrijednost LST-a za 2019./2020. godinu. Minimalne vrijednosti veće su za 5,1 °C, a maksimalne za 8,8 °C za 2019./2020. zimsko razdoblje. Nadalje, tu je i oko 0,7 °C viša standardna devijacija 2019./2020. koja označava veću raspršenost podataka vjerojatno zbog viših vrijednosti LST-a za to razdoblje.

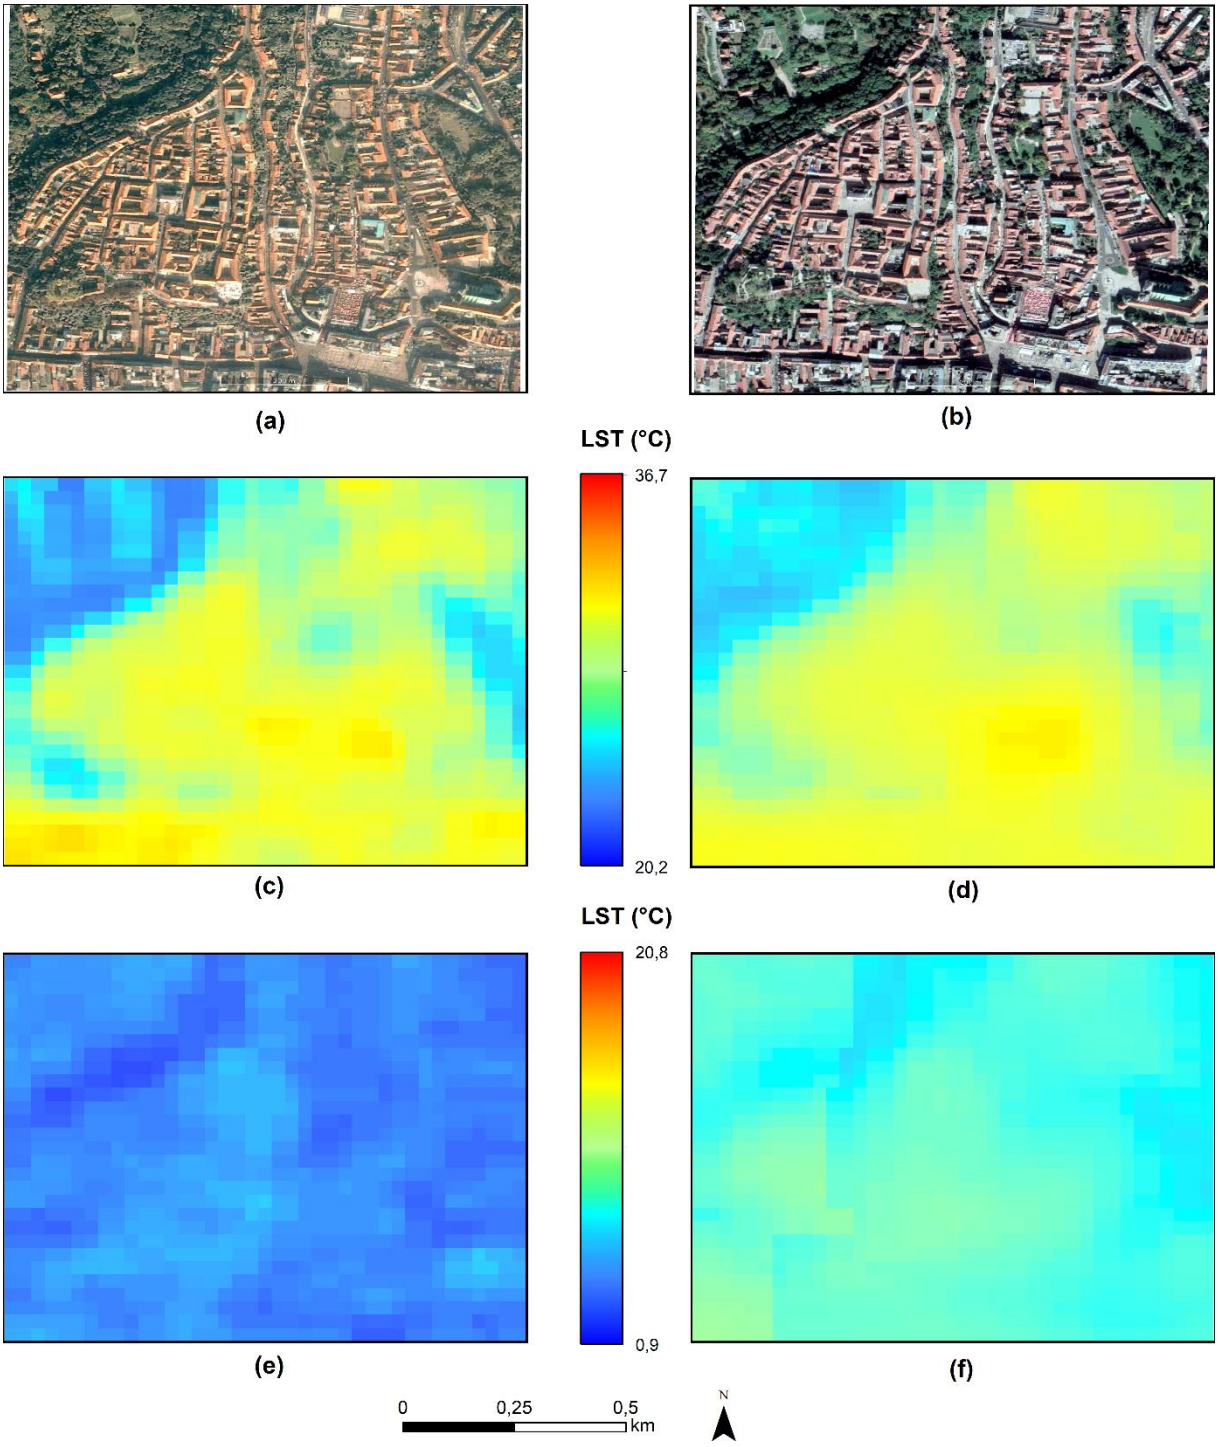
6. Rezultati i rasprava

6.1. Promjena toplinskih obilježja podloge na izabranim područjima

6.1.1. Referentna područja

Analiza referentnih područja poslužiti će za usporedbu s područjima u kojima je došlo do promjene obilježja podloge. Pretpostavka je da su u neizmijenjenim područjima LST vrijednosti ostale približno iste. Toplinska obilježja neizmijenjenih područja na primjeru *Gornjeg grada* i *ruralne okolice* prikazana su na sl. 9 i sl. 10.

Morfološka obilježja *Gornjeg grada* ostala su ista za istraživane godine, 2000./2001. i 2019./2020 (sl. 9a, sl. 9b). Većina područja je izgrađena od umjetnih materijala, dok je udio vegetacije relativno mali. Uočavaju se vrlo slična toplinska obilježja za ljetno razdoblje za područje *Gornjeg grada* (sl. 9c, sl. 9d). Vrijednosti LST-a su na izgrađenoj površini podjednake za oba ljetna razdoblja te su većinom u rasponu 29 – 31 °C. Površina pokrivena vegetacijom ima najniži LST u cijelom području te je u rasponu 23 – 25 °C za 2000. godinu te 24 – 26 °C za 2019. Razlika između vegetacije i izgrađene površine iznosi oko 7 °C za oba ljetna razdoblja. Vrijednosti LST-a malo su više 2019. godine, što se može pripisati nešto toplijem ljetu te godine u odnosu na ljeto 2000. godine. Vrijednosti LST-a znatno su više za zimsko razdoblje 2019./2020. nego 2000./2001. godine (sl. 9e, sl. 9f). U zimskom razdoblju 2000./2001. godine izgrađenu površinu nije moguće jasno vizualno izdvojiti od područja vegetacije prema vrijednostima LST-a kao što je to slučaj za ljetno razdoblje. To je posljedica manjih razlika između vrijednosti LST-a izgrađenih i prirodnih površina zimi. Za izgrađene površine LST je u rasponu 4,5 – 6 °C. Primjetan je niži LST područja prekrivenog vegetacijom od onog izgrađenog za otprilike 2 do 3 °C. Za ljetno razdoblje ista je razlika iznosila oko 7 °C što potvrđuje tvrdnju slabijeg utjecaja vegetacije na LST zimi. U zimskom razdoblju 2019./2020. godine LUHI *Gornjeg grada* je jasnije primjetan nego 2000./2001. godine. Tada su vrijednosti LST-a izgrađenog područja većinom između 9 – 10 °C, a vegetacije između 7 – 8 °C.



Sl. 9. Opća morfološka obilježja i toplinska obilježja područja *Gornjeg grada*: (a) prikaz 2005. godine; (b) prikaz 2019. godine; (c) LST za ljetno razdoblje 2000. godine; (d) LST za ljetno razdoblje 2019. godine; (e) LST za zimsko razdoblje 2000./2001. godine; (f) LST za zimsko razdoblje 2019./2020. godine.

Morfološka obilježja *ruralne okolice* pokazuju da je gotovo cijelo područje poljoprivredne namjene, a mali je udio površine prekrivene drvećem (sl. 10a, sl. 10b).

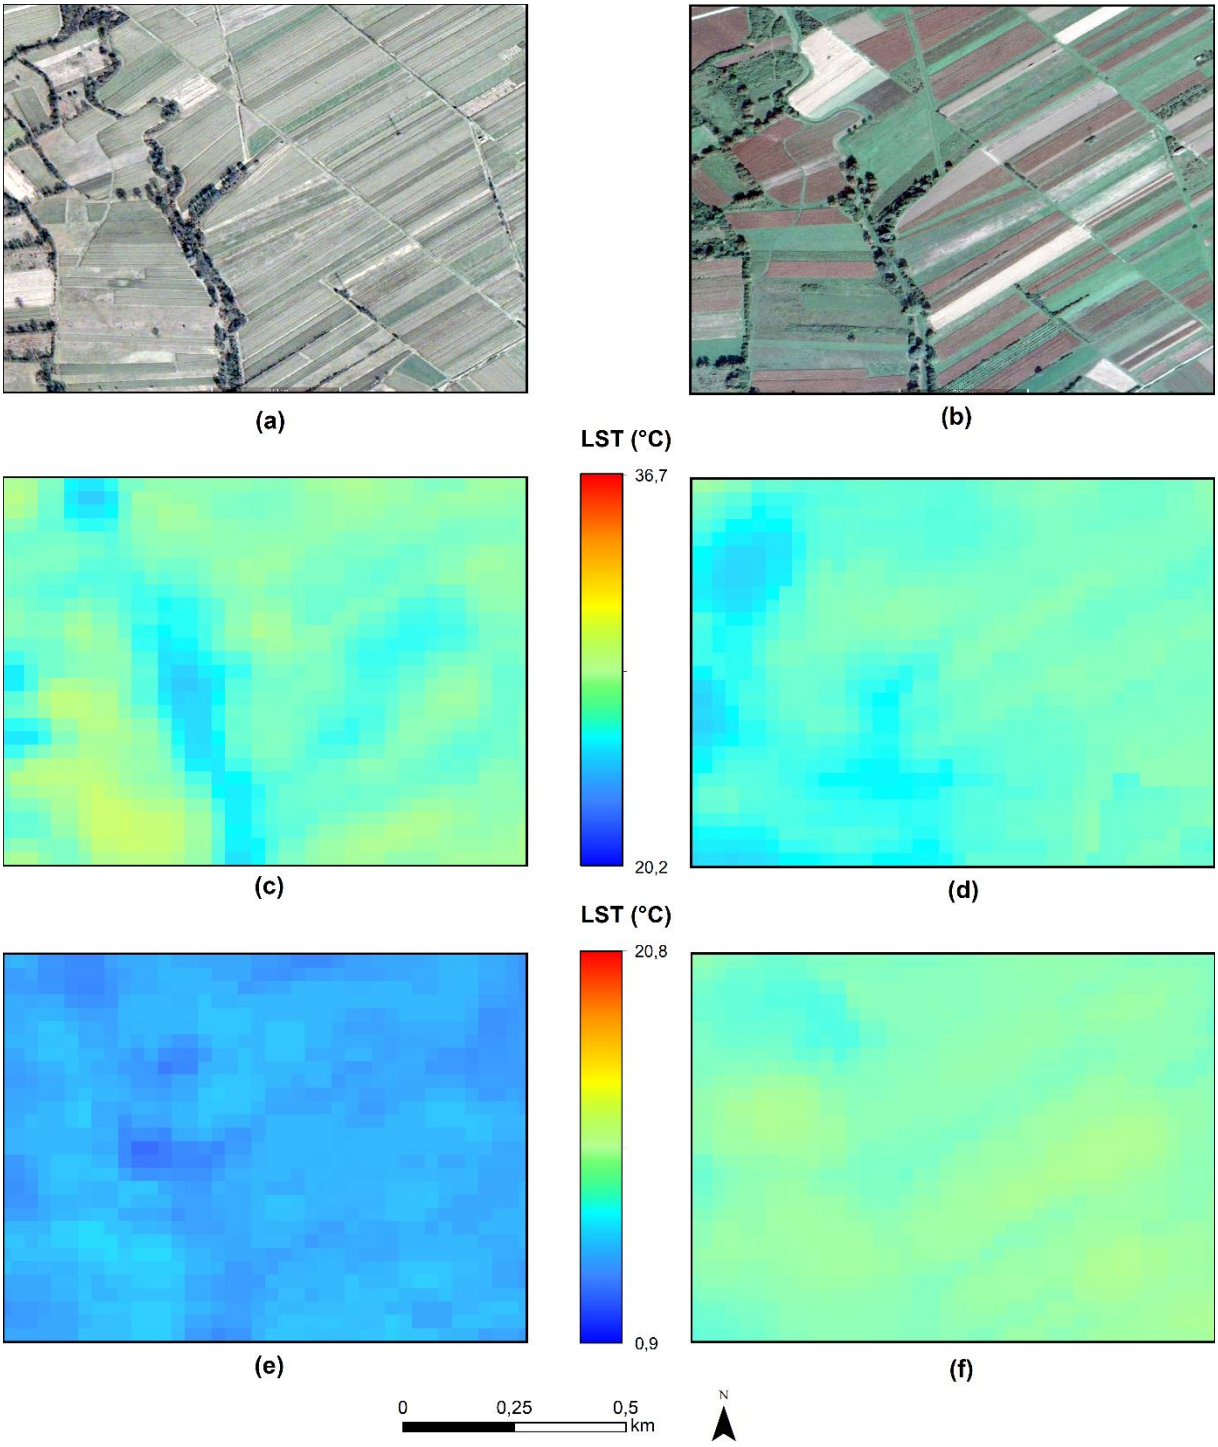
Kao i u slučaju *Gornjeg grada* uočena je sličnost toplinskih obilježja za oba ljetna razdoblja (sl. 10c, sl. 10d). Doduše, u donjem desnom kutu na sl. 10c za ljetno razdoblje 2000. godine primjetna je viša vrijednost LST-a nego za isti dio područja u ljetnom razdoblju 2019. godine. Obzirom na poljoprivrednu namjenu podloge u cijelom području, može se pretpostaviti kako je u ljetu 2000. godine spomenuti dio područja većinom bio neobrađeno golo zemljište, dok je 2019. bio kultiviran. Time bi se mogle objasniti više vrijednosti LST za taj dio područja. Za ostatak područja vrijednosti su slične te su najvećim dijelom u rasponu 27 – 28 °C.

Zimsko razdoblje također pokazuje ujednačenost vrijednosti LST-a. Za gotovo cijelo područje 2000./2001. godine vrijednosti LST-a su između 5,5 i 6,5 °C (sl. 10e). S druge strane, za zimsko razdoblje 2019./2020. godine većina područja ima raspon vrijednosti LST-a između 9,5 i 10,5 °C (sl. 10f).

Pretpostavka o sličnim vrijednostima LST-a za odabrana razdoblja dodatno je potvrđena statističkim pokazateljima (tab. 6). Razlika srednjih vrijednosti LST-a između ljetnog razdoblja 2019. i 2000. godine za *Gornji grad* iznosi 0,3 °C. Time je potvrđeno kako je LST nešto viši za 2019. godinu, ali i da su toplinska obilježja područja tijekom oba razdoblja uglavnom ista. Zimsko razdoblje pokazuje porast od 3,9 °C za 2019./2020. godinu. Razlog tomu je problematična satelitska detekcija zimi, tj. vremenske prilike u trenucima snimanja satelitskih snimaka, kao i sam broj korištenih satelitskih snimaka.

Ruralna okolica također pokazuje vrlo slična toplinska obilježja. Razlika srednjih vrijednosti LST-a između ljetnih razdoblja je 0,5 °C (tab. 6). Za zimsko je razdoblje ta razlika 4,2 °C te time vrlo slična onoj *Gornjeg grada*. Zanimljivo je da su minimalne vrijednosti LST-a *Gornjeg grada* u sva četiri razdoblja niže od minimalnih vrijednosti za *ruralnu okolicu*. To je posljedica malog udjela guste vegetacije u ruralnim područjima, gdje poljoprivredno zemljište bilježi više vrijednosti LST-a od područja prekrivenog drvećem u samom središtu grada.

Vrijednosti standardnih devijacija niže su u zimskom razdoblju, a rastu u ljetnom. Također su izraženije za *Gornji grad* zbog prisutnosti kompaktno izgrađene površine i guste vegetacije, dok je u *ruralnoj okolici* gotovo cijelo područje homogeno te isključivo poljoprivredne namjene.



Sl. 10. Opća morfološka obilježja i toplinska obilježja područja *ruralne okolice*: (a) prikaz 2002. godine; (b) prikaz 2019. godine; (c) LST za ljetno razdoblje 2000. godine; (d) LST za ljetno razdoblje 2019. godine; (e) LST za zimsko razdoblje 2000./2001. godine; (f) LST za zimsko razdoblje 2019./2020. godine.

Prema vizualnom i statističkom prikazu za oba referentna neizmijenjena područja moguće je zaključiti kako su uočena slična toplinska obilježja između dva ljetna i dva zimska razdoblja. Uočeno je i da su homogena prirodna obilježja podloge *ruralne okolice* utjecala na manji raspon vrijednosti LST-a nego u slučaju *Gornjeg grada*. Rezultati analize toplinskih obilježja referentnih područja poslužit će za usporedbu s rezultatima dobivenim za područja s uočenom promjenom obilježja podloge. Jedan od elemenata za usporedbu bit će razlika između srednjih vrijednosti za cijelo područje između pojedinih razdoblja. Ona je za *Gornji grad* iznosila svega 0,3 °C, odnosno 0,5 °C za *ruralnu okolicu*. Također, uočeni porast od 3,9 °C za zimsko razdoblje za *Gornji grad*, odnosno 4,2 °C za *ruralnu okolicu* poslužit će za usporedbu s neizmijenjenim dijelovima područja ostalih analiziranih primjera u ovom radu.

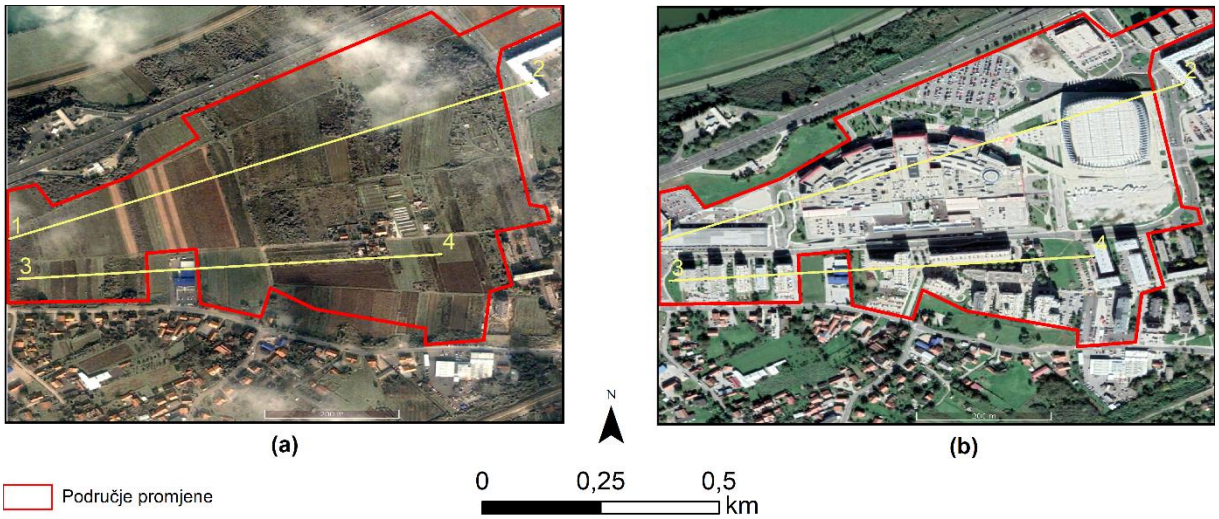
Tab. 6. Statistički pokazatelji LST-a (°C) referentnih područja za zimsko i ljetno razdoblje

Statistički pokazatelj	**Gornji grad**				**Ruralna okolica**			
	Zimsko razdoblje		**Ljetno razdoblje**		**Zimsko razdoblje**		**Ljetno razdoblje**	
	2000./ 2001.	**2019./ 2020.**	**2000.**	**2019.**	**2000./ 2001.**	**2019./ 2020.**	**2000.**	**2019.**
Minimum	2,7	6,7	22,9	24,3	3,6	8,2	24,5	24,7
Maksimum	6,3	10,2	31,9	31,5	6,6	10,7	29,2	27,8
Raspon	3,6	3,5	9	7,2	3,0	2,5	4,7	3,1
Srednja vrijednost	4,5	8,4	28,5	28,8	5,5	9,7	27,1	26,6
Standardna devijacija	0,6	0,7	2,4	1,9	0,4	0,5	0,8	0,6

6.1.2. Arena centar

U razdoblju između 2000./2001. i 2019./2020. kompleks zgrada *Arena centra* predstavlja najveću zabilježenu novoizgrađenu površinu u usporedbi s ostalim analiziranim područjima. Riječ je o jednom od najvećih trgovačkih centara, ali i sportsko-zabavnih okupljališta u Hrvatskoj i samim time privlači veliki broj dnevnih posjetitelja zbog čega su izgrađene velike parkirališne površine koje doprinose višim vrijednostima LST-a. Izgradnja sportske dvorane je započela 2006. godine, a dovršena je 2009. Pored sportske dvorane u razdoblju od 2008. do 2010. godine izgrađen je trgovački centar. Istodobno je izgrađen kompleks zgrada Jaruščica,

kao nove atraktivne lokacije u gradu. Morfološki gledano, na tom je području došlo do znatne promjene obilježja podloge (sl. 11). Prije izgradnje (sl. 11a) veliki dio područja imao je poljoprivrednu namjenu, a izgrađene površine bile su prometnice, nekoliko poslovnih zgrada i obiteljske kuće u južnom dijelu analiziranog područja. Nakon izgradnje (sl. 11b), većina područja je izgrađena od materijala poput asfalta i betona koji su promijenili albedo i radijacijsku bilancu. Nove zgrade su većim dijelom visokogradnja, osim obiteljskih kuća. Trgovački centri i sportska dvorana predstavljaju kontinuiranu izgrađenu površinu za razliku od okolnog prostora gdje su i dalje zastupljene zelene površine.



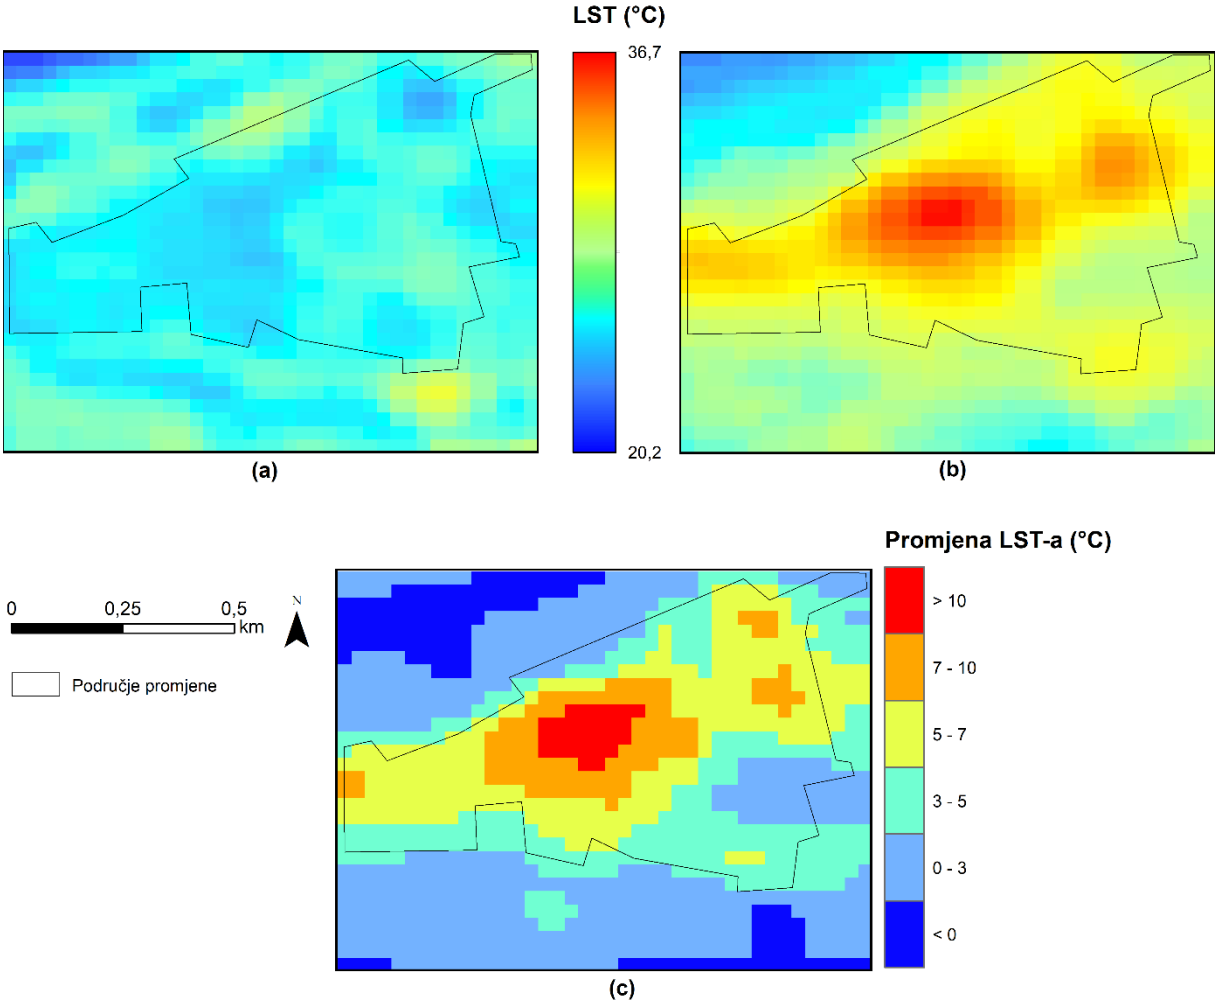
Sl. 11. Opća morfološka obilježja područja *Arena centra*: (a) prikaz 2005. godine; (b) prikaz 2019. godine

Napomena: žute linije predstavljaju toplinske profile na sl. 13

Utjecaj promjene obilježja podloge na vrijednosti LST-a za ljetno razdoblje 2000. i 2019. te zimsko 2000./2001. i 2019./2020. prikazan je na sl. 12 i sl. 13.

LST cijelog područja prije izgradnje *Arena centra* pokazuje više vrijednosti na rijetkim izgrađenim površinama (sl. 12a, sl. 13a). To je nešto slabije vidljivo za zimsko razdoblje budući da je riječ o razlici od svega nekoliko °C. Najviše zabilježene temperature za područje istraživanja primijećuju se u krajnjem jugoistočnom dijelu analiziranog područja na sl. 12a i sl. 13a gdje se nalazi nekoliko gusto izgrađenih poslovnih zgrada. Ovdje vrijednosti LST-a ljeti dosežu maksimalno 30,5, a zimi 8 °C. Jasno je vidljiv i termički utjecaj prometnica, a pogotovo Jadranske avenije u sjevernom dijelu prikaza. Analizirano područje promjene (označeno crnom linijom na sl. 12 i sl. 13) je u ljetnom razdoblju 2000. godine, prije izgradnje, bilo hladnije od okolnog područja (sl. 12a). Tomu su razlog prirodna obilježja površine, kod kojih se također raspoznaju razlike između tipova pokrova zemljišta, a u ovom slučaju površine obrasle

drvećem, niske vegetacije i golog poljoprivrednog tla. Vegetacija utječe na smanjenje LST-a jer se veći dio Sunčeve radijacije utroši u procesu evapotranspiracije ili se pretvara u kemijsku energiju korištenu u fotosintezi (Hidalgo i dr., 2008). Kada biljke imaju velike zalihe vode transpiracija im je izraženija pa su njihovi listovi uglavnom niže temperature od okolnog zraka, tj. smanjuje im se LST (Huete, 2004). Nadalje, listopadno drveće reflektira dio Sunčeva zračenja čime se dodatno utječe na smanjenje LST-a, a tomu treba dodati i utjecaj koji stvara sjena drveća (Gill, 2007).



Sl. 12. Toplinska obilježja područja *Arena centra* za ljetno razdoblje: (a) LST 2000. godine; (b) LST 2019. godine; (c) promjena LST-a

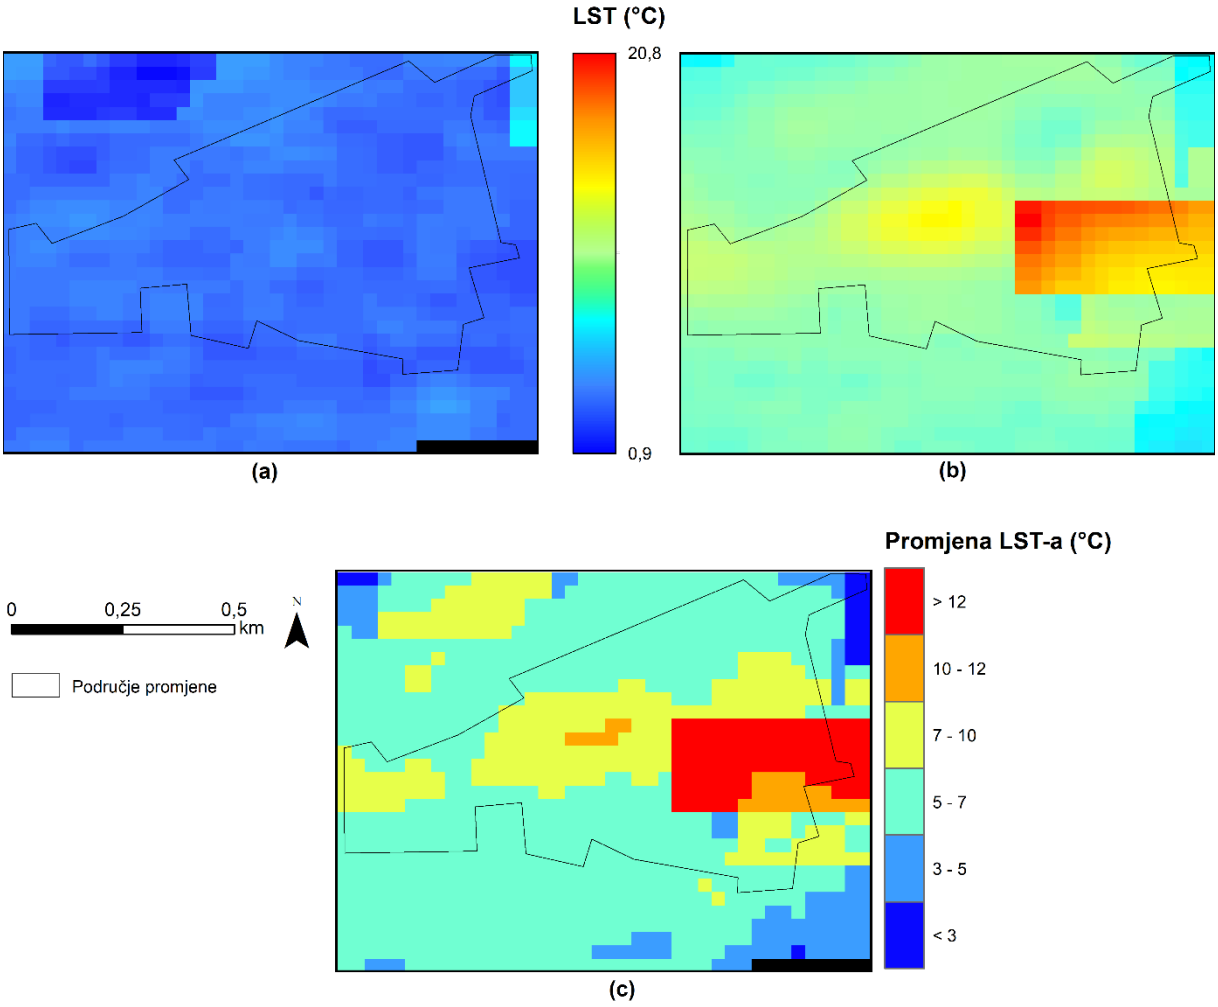
Na sl. 12a niže vrijednosti LST-a podudaraju se s manjim grupama drveća ili visoke vegetacije sa sl. 11a. Tako je LST na tim površinama ljeti 6 – 7 °C niži od LST-a poslovnih zgrada u jugoistočnom dijelu prikaza te su vrijednosti LST-a, pa i temperatura zraka uvjetovane udjelom vegetacije. Slične vrijednosti uočene su i na primjeru *Gornjeg grada* gdje je razlika izgrađene i prirodne površina iznosila oko 7 °C. Niska vegetacija ima sličan termički učinak, no nešto manjeg intenziteta pa su zato i vrijednosti LST-a više. Unutar područja promjene

vidljive su i zone s višim vrijednostima LST-a za što se pretpostavlja da je riječ o utjecaju golog poljoprivrednog zemljiša bez vegetacije. Naime, evapotranspiracija je tada niža, a dolazna Sunčeva energija se ne troši na fotosintezu već pretežno na zagrijavanje površine. Ipak, tlo ne može apsorbirati istu količinu Sunčevog zračenja kao umjetni materijali te su u usporedbi s njima vrijednosti LST-a nešto niže. Navedeno se odnosi na ljetno razdoblje, dok zimi vrijednosti LST-a u većoj mjeri ovise isključivo o obilježjima podloge jer ima manje vegetacije. Usto, zimi se postojećoj vegetaciji smanjuje albedo zbog izostanka lišća u krošnjama zbog čega se apsorpcija povećava. Tada se temperature u području promjene kreću uglavnom između 3 i 4 °C pa razlike između vrijednosti LST-a skupina drveća i golog tla nisu značajne. Za kvalitetniji uvid utjecaja vegetacije u mikroklimatskom pogledu potrebna je nešto veća prostorna rezolucija satelita.

U ljetnom i zimskom razdoblju 2019./2020. godine veći je dio analiziranog područja izgrađen, a poljoprivrednih površina više nema što se jasno vidi i prema vrijednostima LST-a (sl. 11b, sl. 12b, sl. 13b). Minimalne i maksimalne vrijednosti LST-a su više od istih za 2000./2001. godinu. Cijeli kompleks *Arena centra* danas predstavlja jednu od najzagrijanijih gradskih površina, a time i jedan od najuočljivijih LUHI-a u gradu, što se može vidjeti na sl. 8. Također, u ovom slučaju su vrijednosti LST-a dobro vidljive i zimi. Međutim, posljedica veće naoblake zimi su neuobičajene vrijednosti LST-a u dijelu područja koji je stoga nepouzdan. Riječ je o pravokutniku viših vrijednosti LST-a (sl. 13b) koji je posljedica oblaka na jednom od snimaka zbog čega je dio podataka izostavljen iz izračuna srednje vrijednosti LST-a.

Budući da su vrijednosti LST-a mjerene otprilike oko 11:40 po lokalnom vremenu, one ne prikazuju maksimalne dnevne vrijednosti. Usto, LUHI je najbolje uočljiv noću, no to nije moguće analizirati korištenjem Landsat satelitskih podataka. Za 2019./2020. vidljiva su u pravilu tri manja „otoka“ od kojih je svaki povezan s tri građevine koje pokrivaju veliku površinu (sl. 11b). S lijeva, manji trgovački centar, zatim veći trgovački centar u sredini i na desnoj strani sportska dvorana, koji su u potpunosti izgrađeni od umjetnih materijala poput asfalta i betona. Središnji trgovački centar najveći je površinom, a ujedno ima i najviše vrijednosti LST-a, oko 37 °C ljeti i 14 °C zimi. Zanimljivo je kako je najviša vrijednost LST-a sportske dvorane oko 33 – 34 °C ljeti, a 8,5 °C zimi što je za nekoliko °C niže od trgovačkog centra. To bi se moglo objasniti visokim albedom zgrade, pošto je njen krov bijele boje, kao i materijal u okolini. S druge strane, krov zgrade trgovačkog centra nešto je tamniji te apsorbira više Sunčeve radijacije što dovodi do viših vrijednosti LST-a. Također je opažen maksimum LST-a u središtima zgrada, a prema vanjskim rubovima on se smanjuje. Jadranska avenija „se

spojila“ s cijelim izgrađenim kompleksom jer su njena toplinska obilježja slična obilježjima parkirališta i ostalih građevina. Najhladniji dijelovi područja su rijeka Sava te njena obala. Njena blizina mogla bi imati ohlađujući utjecaj, no on je neznatan zbog guste izgrađenosti cijelog kompleksa, ali i nasipa koji onemogućava dotok hladnog zraka. Nepromijenjeni dio područja ima slična toplinska obilježja kao i prije izgradnje s time da su vrijednosti LST-a nešto više zbog toplijeg ljeta 2019. godine.



Sl. 13. Toplinska obilježja područja *Arena centra* za zimsko razdoblje: (a) LST 2000./2001. godine; (b) LST 2019./2020. godine; (c) promjena LST-a

Promjena LST-a predstavlja apsolutnu razliku temperatura između ljetnog razdoblja 2019. i 2000. te zimskog 2019./2020. i 2000./2001. što pruža uvid u intenzitet promjena do kojih je došlo. Za ljetno je razdoblje zapaženo izrazito podudaranje zona najveće promjene LST-a i područja promjene obilježja podloge (sl. 12c). Porast iznad 10 °C primijećen je u središtu trgovačkog centra, a prema vanjskim rubovima porast je u razredima od 7 – 10 °C i 5 – 7 °C.

Primjetno je i kako se zelene površine unutar područja promjene ne izdvajaju kao hladnije površine. Te su zelene površine uglavnom bez drveća, a okružene su umjetnim materijalom pa ustvari ljeti nemaju ohlađujući utjecaj kakav bi mogle imati da se na njima nalazi drveće.

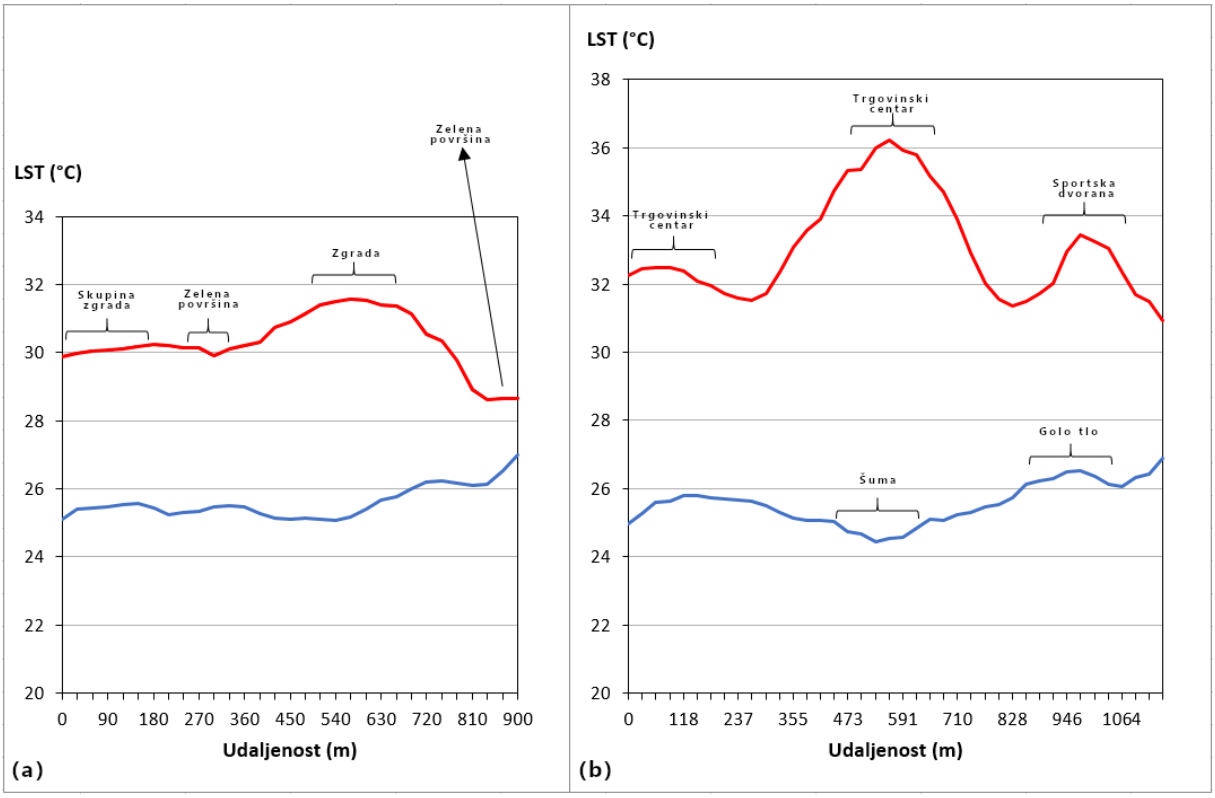
Tijekom zimskog razdoblja je uočen sličan obrazac, no uz poneke iznimke, primjerice uz obalu rijeke Save te u pravokutniku s nepouzdanim vrijednostima sl. 13c. Porast je jasno vidljiv i u zimskom razdoblju, na najvećem dijelu analiziranog područja on je unutar razreda 7 - 10 °C, a u središnjem dijelu trgovačkog centra 10 – 12 °C. Porast vrijednosti LST-a iznad 12 °C prisutan je isključivo na području spomenutog pravokutnika s nepouzdanim vrijednostima te se stoga vrijednosti za taj dio moraju zanemariti.

Izvan područja promjene je zamijećen manji porast za ljetno (0 – 3 °C) nego za zimsko razdoblje (5 – 7 °C). Vjerojatni razlog tomu su sličnija temperaturna obilježja ljeta 2000. i 2019. godine. Iako je prema tab. 4 zima 2000./2001. bila toplija od zime 2019./2020., pokazalo se da su mali broj zimskih snimaka i njihov raspored unutar zimskog razdoblja utjecali na niske vrijednosti LST-a za zimsko razdoblje 2000./2001., a time i na značajnu pozitivnu promjenu LST-a za cijelo područje. Doduše, dokazano je da vrijednosti LST-a variraju više nego temperature zraka zbog razlika toplinskih obilježja podloge i zraka (Hofierka i dr., 2020). Stoga porast LST-a od npr. 5 °C ne mora značiti isti porast temperature zraka, već mnogo manji.

U uvjetima istog primitka topline umjetni materijali imat će viši LST od prirodnih materijala. Obzirom da se zrak zagrijava od podloge, on će iznad umjetnih materijala također biti topliji nego iznad prirodnih. Potrebno je uzeti u obzir činjenicu da se LST odnosi na temperaturu krovova zgrada, dok građani većinu vremena provode u klimatiziranom unutrašnjem prostoru zgrada. Ipak, uz zgrade su uvijek i parkirališta i druge površine izgrađene od umjetnih materijala. Stoga je osjet ugode posjetitelja van klimatiziranog prostora smanjen, a on ovisi o temperaturi zraka koja je naglašena u područjima poput *Arena centra*, ali i drugim faktorima poput vlažnosti zraka i brzine vjetra (DHMZ, 2020b). To može stvoriti toplinski stres kod ljudi, pogotovo starije životne dobi, te narušiti njihovo zdravstveno stanje. Ozelenjivanjem površine može se povoljno utjecati na lokalnu klimu, a time i smanjiti negativne utjecaje UHI-a poput navedenih. U prilog potrebi ozelenjivanja grada govori prosvjed koji su 2016. godine u naselju Lanište građani podigli protiv izgradnje nove zgrade gdje su naglasili da je Lanište već prenaseljeno i preizgrađeno, a ističu da im nedostaje zelenih površina (Radio Student, 2016).

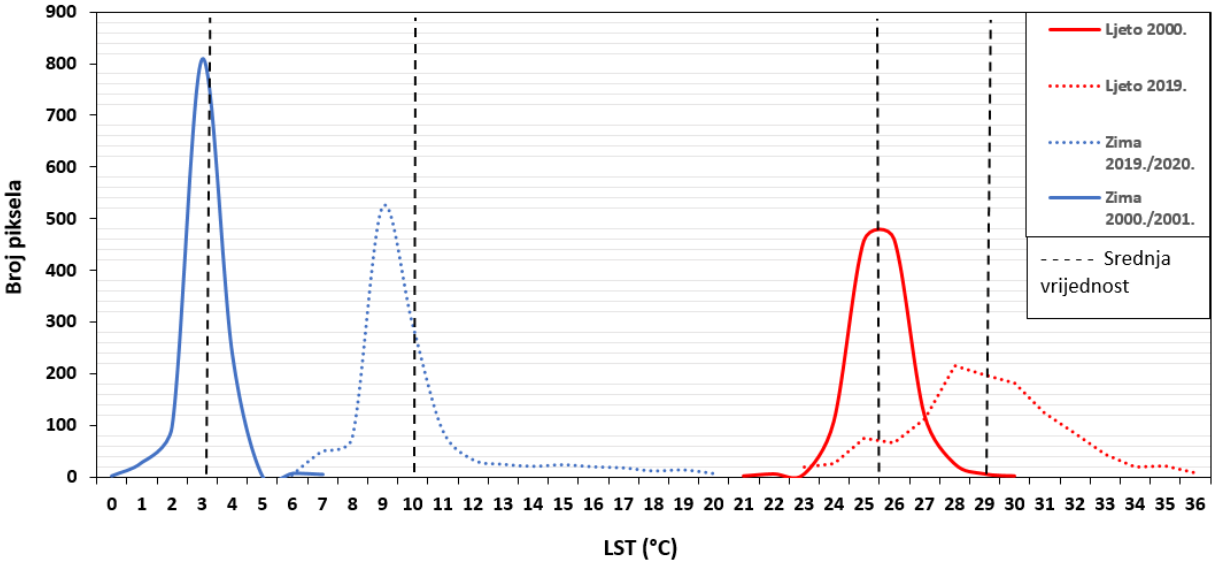
Iako je efekt LUHI-a dobro uočljiv na sl. 12 i sl. 13, moguće ga je predstaviti i horizontalnim profilima temperature (sl. 14). Profili su prikazani za ljetno razdoblje zbog pouzdanijih vrijednosti LST-a za to razdoblje. Horizontalni profil temperature između točaka 1 i 2 (sl. 14a)

prolazi najzagrijanijim područjem, dok profil između točaka 3 i 4 (sl. 14b) prikazuje promjene LST-a područja koje nije kontinuirano izgrađeno, već se tamo nalaze visoke stambene zgrade koje su okružene zelenim površinama. Pokazalo se kako se LST mijenja ovisno o obilježjima podloge. Zelene površine dobro se uočavaju pošto na njima vrijednosti LST-a padaju, a izgrađena područja su topli „otoci“ u prostoru. Vrijednosti prije izgradnje su ujednačenije i variraju unutar 2 °C razlike za oba profila, a nakon izgradnje 3,5 °C (sl. 14a) i 5 °C (sl. 14b).



Sl. 14. Horizontalni profili LST-a za ljetno razdoblje 2000. (plave linije) i 2019. (crvene linije); (a) između točaka 1 i 2; (b) između točaka 3 i 4 (sl. 11)

Promjena obilježja podloge uočljiva je i na sl. 15 koja pokazuje koliki je broj piksela unutar raspona temperature od 1 °C. Tako je 2000./2001. godine većina svih piksela bila između 25 – 27 °C u ljetnom, odnosno 3 – 4 °C u zimskom razdoblju, a tek manji broj piksela se nalazio unutar raspona 29 – 30 °C, odnosno 6 – 7 °C zbog slabe pokrivenosti umjetnim materijalima. Najniže vrijednosti u svim godinama predstavlja površina rijeke Save, dok su najviše za 2000./2001. godinu vezane uglavnom za poslovni centar kao tada najveću izgrađenu površinu. Izgradnjom, 2019./2020. godine dolazi do značajnih promjena. Vrijednosti variraju u većem rasponu, 23 – 37 °C za ljetno razdoblje te 6 – 21 °C zbog čega je krivulja položenija. U odnosu na 2000./2001. godinu primjetan je veći broj piksela s visokim vrijednostima LST-a gdje najviše od njih predstavljaju središta većih građevina.



Sl. 15. Broj piksela po temperaturnim razredima (veličina razreda je 1 °C) za ljetno i zimsko razdoblje cijelog područja *Arena centra*

Statistički pokazatelji u znatnijoj mjeri potvrđuju dosadašnje rezultate analize promjene LST-a (tab. 7, tab. 8). Rezultati se odnose na područje u kojemu je došlo do promjene, koje je ostalo neizmijenjeno te na ukupno analizirano područje *Arena centra*.

Za ljetno razdoblje 2000. godine minimalne i maksimalne vrijednosti LST-a su očekivano niže za sva tri područja u odnosu na 2019. godinu (tab. 7). Doduše, za neizmijenjena područja vrijednosti LST-a su sličnije nego za područje promjene i cijelo područje. To se vidi i prema rasponu koji je za samo 0,4 °C veći 2019. godine. Srednja vrijednost LST-a računa se prema svim pikselima rastera te daje reprezentativnu vrijednost LST-a kroz istraživano razdoblje. Za ljetno razdoblje se LST u cijelom području povećao za 3,5 °C. U samom području promjene ta je vrijednost izraženija te iznosi 5,9 °C, a u neizmijenjenom području 1,7 °C.

Kao i u ljetnom razdoblju, zimske minimalne i maksimalne vrijednosti su niže za sva tri izdvojena područja (tab. 8). Razlika u rasponima LST-a u zimskom razdoblju je naglašenija te iznosi 4,6 °C za cijelo područje. Srednja vrijednost LST-a u cijelom području povećala se za 6,8 °C. U području promjene ta je vrijednost 8 °C, a u neizmijenjenom 6 °C. Zbog malog broja satelitskih snimaka vrijednosti LST-a su znatno veće u zimskom razdoblju 2019./2020. godine. Prema rezultatima referentnih područja porast LST-a zbog malog broja satelitskih snimaka iznosi oko 4 °C. Sve iznad toga predstavlja utjecaj promjene podloge.

Upravo standardna devijacija govori o tome kako LST nekog područja ovisi o njegovim morfološkim karakteristikama. Primjerice, 2000. godine površina je većinom bila prirodnih

obilježja uz manji udio izgrađenih površina i male standardne devijacije, dok 2019. LST značajnije varira zbog guste pokrivenosti umjetnim materijalom koji je suprotnost rijeci Savi i okolnom prostoru obiteljskih kuća. Također, ljeti je standardna devijacija veća jer se umjetni materijali brže i više zagriju u odnosu na postojeću vegetaciju i vodene površine. Izgrađenija obilježja podloge 2000./2001. doprinose ujednačenijem LST-u i standardna devijacija je manja.

Tab. 7. Statistički pokazatelji LST-a (°C) područja *Arena centra* za ljetno razdoblje 2000. i 2019. godine

Statistički pokazatelj	**2000.**			**2019.**		
	Područje promjene	**Neizmijenjeno područje**	**Cijelo područje**	**Područje promjene**	**Neizmijenjeno područje**	**Cijelo područje**
Minimum	23,8	21,5	21,5	28,4	23,2	23,2
Maksimum	28,6	30,4	30,4	36,6	32,5	36,6
Raspon	4,8	8,9	8,9	8,2	9,3	13,4
Srednja vrijednost	25,8	26,2	26,0	31,5	27,9	29,5
Standardna devijacija	0,8	1,1	1,0	1,8	1,8	2,52

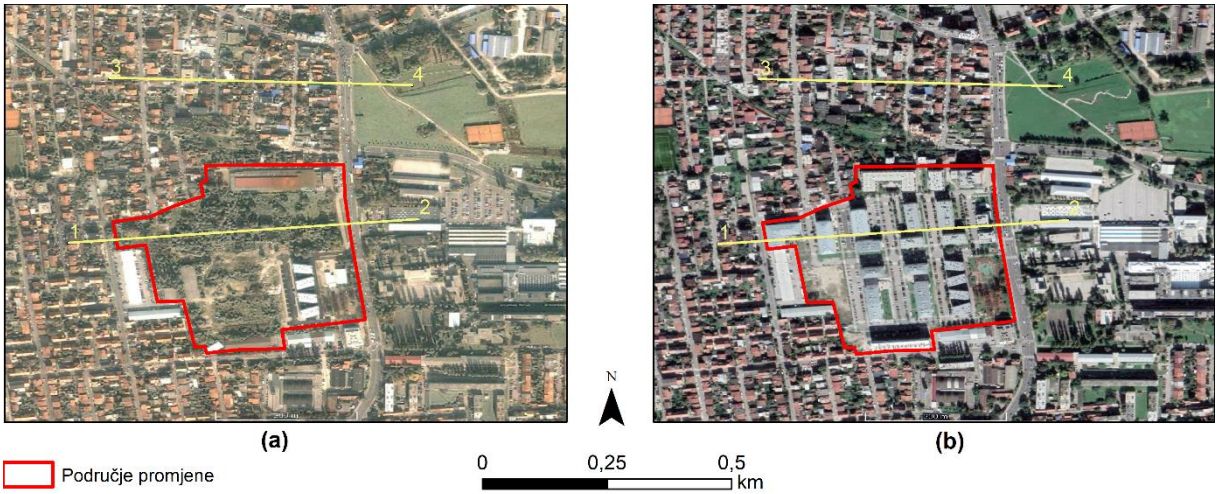
Tab. 8. Statistički pokazatelji LST-a (°C) područja *Arena centra* za zimsko razdoblje 2000./2001. i 2019./2020. godine

Statistički pokazatelj	**2000./2001.**			**2019./2020.**		
	Područje promjene	**Neizmijenjeno područje**	**Cijelo područje**	**Područje promjene**	**Neizmijenjeno područje**	**Cijelo područje**
Minimum	2,9	0,9	0,9	7,3	6,8	6,8
Maksimum	7,3	7,3	7,3	20,8	17,8	20,8
Raspon	4,4	6,4	6,4	13,5	11,0	14,0
Srednja vrijednost	3,7	3,6	3,7	11,7	9,6	10,5
Standardna devijacija	0,4	0,8	0,7	2,7	1,4	2,3

6.1.3. Stambene zgrade Selska

Za potrebe rada pokušalo se odabrati područje što bliže središtu grada, a gdje je došlo do velike promjene u obilježjima podloge. Jedan od takvih primjera je područje u blizini Selske ulice u zagrebačkoj gradskoj četvrti Trešnjevka. Analizirana područja u radu pokazuju različita morfološka obilježja, koja djelomičnno uvjetuju vrijednosti LST-a. Odabirom ovog primjera pokušava se doprinijeti prikazu vrijednosti LST-a u kompaktnije izgrađenom dijelu Zagreba.

Prije izgradnje većinu površine činile su zbijene kuće niskogradnje na zapadnoj i industrijska postrojenja na istočnoj strani područja (sl. 16a). Međutim, priličan je i udio vegetacije koji prekriva otprilike petinu područja. Dominantno je središnje područje vegetacije prekriveno drvećem, koje je 2000. godine stanovnicima vrlo vjerojatno koristio za rekreativne svrhe i rashlađivanje u vrućim mjesecima. Doduše, upravo je pozicija te površine atraktivna zbog čega je došlo do izgradnje visokih stambenih zgrada, tj. uklanjanja površine pod vegetacijom (sl. 16b). Ostatak područja je do danas ostao većinom nepromijenjen.



Sl. 16. Opća morfološka obilježja područja *Stambene zgrade Selska*: (a) prikaz 2005. godine; (b) prikaz 2019. godine

Napomena: žute linije predstavljaju toplinske profile na sl. 19

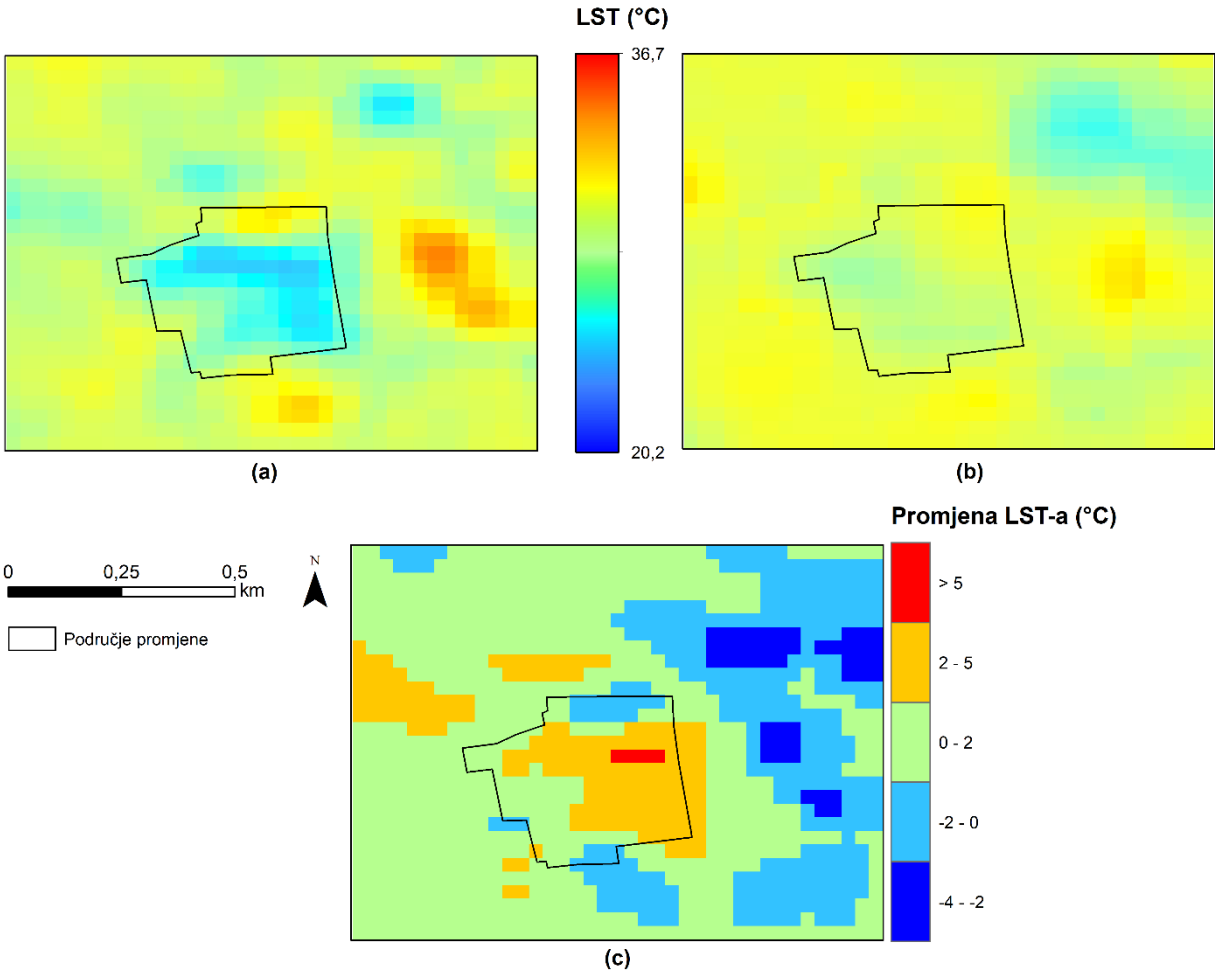
Sama promjena obilježja podloge područja počela je nakon 2003. godine s izgradnjom četiri manje zgrade, da bi nakon 2005. u cijelom području došlo do uklanjanja starih baraka i drveća te izgradnje stambenih zgrada. Bitno je napomenuti da je na sl. 16a područje prikazano za 2005. godinu, zbog neadekvatnih snimaka na *Google Earth Pro*-u 2000. godine. Tako su četiri zgrade u donjem desnom kutu područja promjene izgrađene 2004. godine. Navedeno je potrebno imati na umu tijekom usporedbe satelitske snimke s toplinskom kartom iz 2000. godine (sl. 17a, sl. 18a) kako ne bi došlo do njene pogrešne interpretacije.

Vrijednosti LST-a za ljetno razdoblje 2000. godine pokazuju podudaranje zona s najgušćom vegetacijom i niskih vrijednosti LST-a, odnosno industrijskih građevina i najviših vrijednosti LST-a (sl. 17a). U središnjem dijelu gdje je najviše vegetacije LST ima najniže vrijednosti, oko 24 – 25 °C. S druge strane, u industrijskoj zoni vrijednosti rastu do 34,5 °C. Najviše vrijednosti LST-a su na krovovima velikih površina, a usto i tamnijih boja. Na ovome primjeru jasno se uočava odnos LST-a i urbanih zelenih površina (engl. *urban green space*, UGS). UGS u središnjem dijelu analiziranog područja ima prosječno 6 – 7 °C niže vrijednosti LST-a od okolnog izgrađenog prostora i kao takav predstavlja hladni „otok". Gotovo identične vrijednosti su uočene i za referentna područja (sl. 9c,d, sl. 10c,d) i *Arena centar* (sl. 12a,b). Molnar (2016) je proučavajući LST u Budimpešti ustanovio niži LST UGS-a u odnosu na kompaktno urbano područje srednje visokih zgrada. LST je iznosio između 9 i 12 °C tijekom dana s velikom zagrijanošću u kolovozu. Ipak, kako je LST u ovom radu srednjak ljetnog razdoblja, proučena je jedna snimka 2. kolovoza 2000. godine. Uočena je najveća razlika od 8 – 9 °C između središnjeg UGS-a i okolnog nepromijenjenog prostora. Time se potvrđuje izraženiji ohlađujući učinak zelenih površina u danima s velikom zagrijanošću. Nadalje, UGS-ovi imaju znatan utjecaj na ublažavanje UHI-a. Na primjer, studija za Beč pokazala je da povećanje udjela zelene površine za 20% može dovesti do značajnog smanjenja toplinskog stresa u gradu, tj. umanjiti negativne posljedice UHI-a ljeti (Zuvela-Aloise, 2013). U Zagrebu bi se dobrim urbanim planiranjem mogle implementirati brojne mjere ublažavanja UHI-a.

U ljetnom razdoblju 2019. godine najhladnija je zelena površina na sjeveroistoku analiziranog područja na sl. 17b. Unutar područja promjene primjetno je kako je zamjena prirodne površine s visokim stambenim zgradama doprinijela višem LST-u. No, zgrade su međusobno udaljene što mjestimično, ovisno o položaju zgrada, stvara sjenu među njima. Sjena djelomično snižava LST, a primjetan je i mali udio vegetacije pa su vrijednosti LST-a novoizgrađenog područja niže u usporedbi s okolnim prostorom. Naglašeno je i smanjenje maksimalnih vrijednosti LST-a u odnosu na 2000. godinu, koje su za 2019. iznosile između 31 - 32 °C. Mogući razlog je povećanje albeda krovova industrijskih zgrada.

Promjena je ponovno najuočljivija za samo područje promjene, a vrijednosti su najvećim dijelom u razredu porasta 2 – 5 °C (sl. 17c). Uspoređujući s *Arena centrom* može se uočiti kako je promjena na ovom primjeru više nego upola manja. Kod *Arena centra* riječ je bilo o površini u potpunosti prekrivenoj umjetnim materijalima, a stambene zgrade su bile orijentirane većinom u smjeru sjever-jug. Za *Stambene zgrade Selska* dio zgrada orijentiran je u smjeru istok-zapad što u vrijeme prolaska satelita (oko 11:30) stvara veću sjenu nego kod zgrada

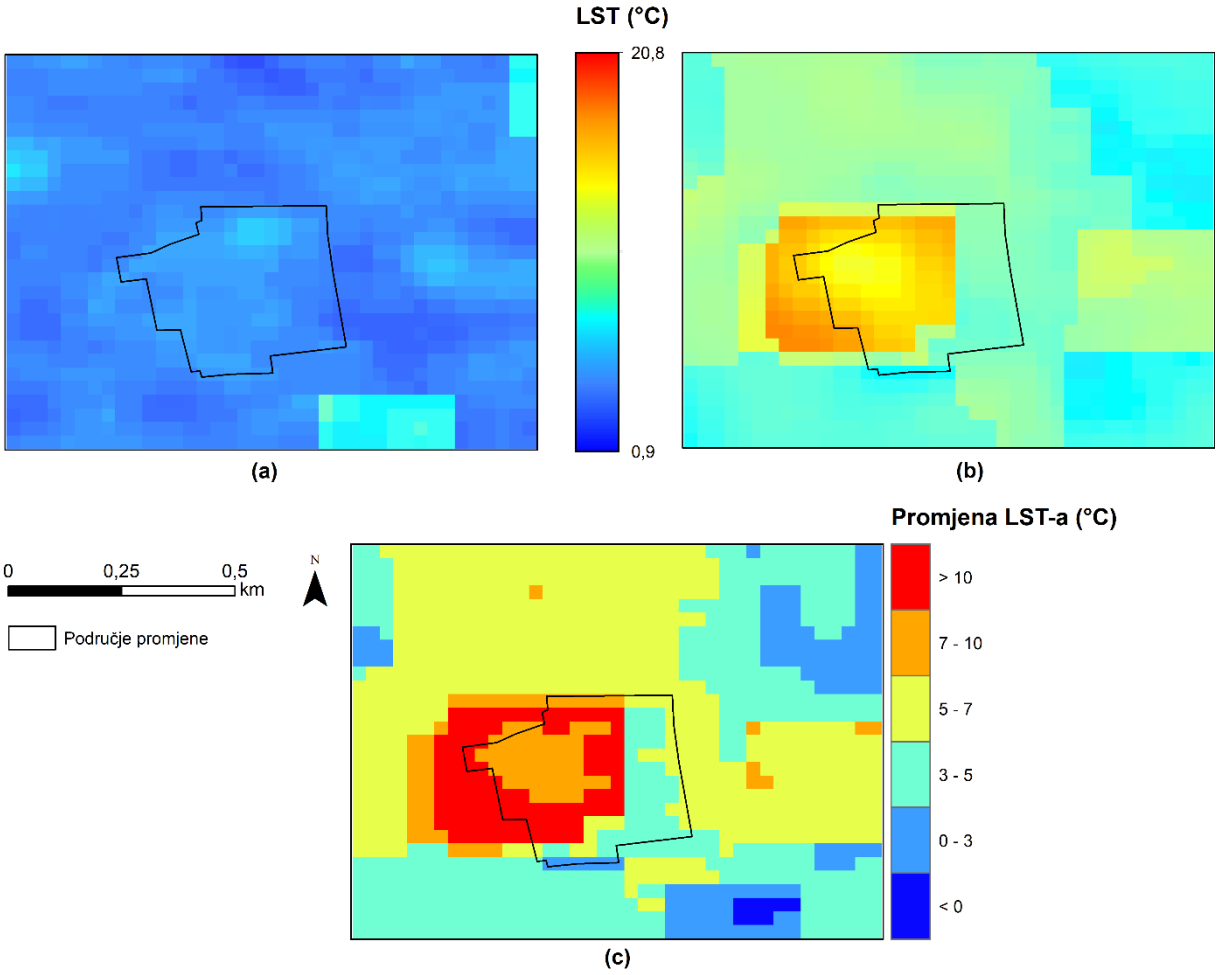
orijentacije sjever-jug, a naposljetku i niži LST. Samim time, širenju izgrađenih površina može se pristupiti kontrolirano i promišljeno, poštujući pravila urbane morfologije čime se pogoduje smanjenju negativnog utjecaja UHI-a (Srivanit i Kazunori, 2011).



Sl. 17. Toplinska obilježja područja *Stambene zgrade Selska* za ljetno razdoblje: (a) LST 2000. godine; (b) LST 2019. godine; (c) promjena LST-a

Za zimsko razdoblje uočene su nepouzdane vrijednosti, a razlog je promjenjiv broj odgovarajućih satelitskih snimaka u ovisnosti o prekrivenosti područja oblacima. Rezultati su pogotovo nepovoljni za zimsko razdoblje 2019. godine (sl. 18b). Tada je na većem dijelu područja LST izračunat na osnovu podataka tek dviju snimaka zbog čega se javljaju neočekivano visoke vrijednosti LST-a. U okolnom području korištene su uglavnom tri snimke, no razultati također nisu zadovoljavajući te ne prikazuju stvarno stanje LST-a. S druge strane, zimsko razdoblje 2000. godine ima poneke greške, no nisu velike, a zapaža se podudarnost viših vrijednosti LST-a s rasporedom zgrada veće površine. Tako je 2000. godine u sjevernom dijelu područja promjene stajala niska baraka (sl. 18a) te su i vrijednosti LST-a više. Viši LST zabilježen je i istočno od područja promjene, u industrijskoj zoni, gdje LST doseže do 6 °C.

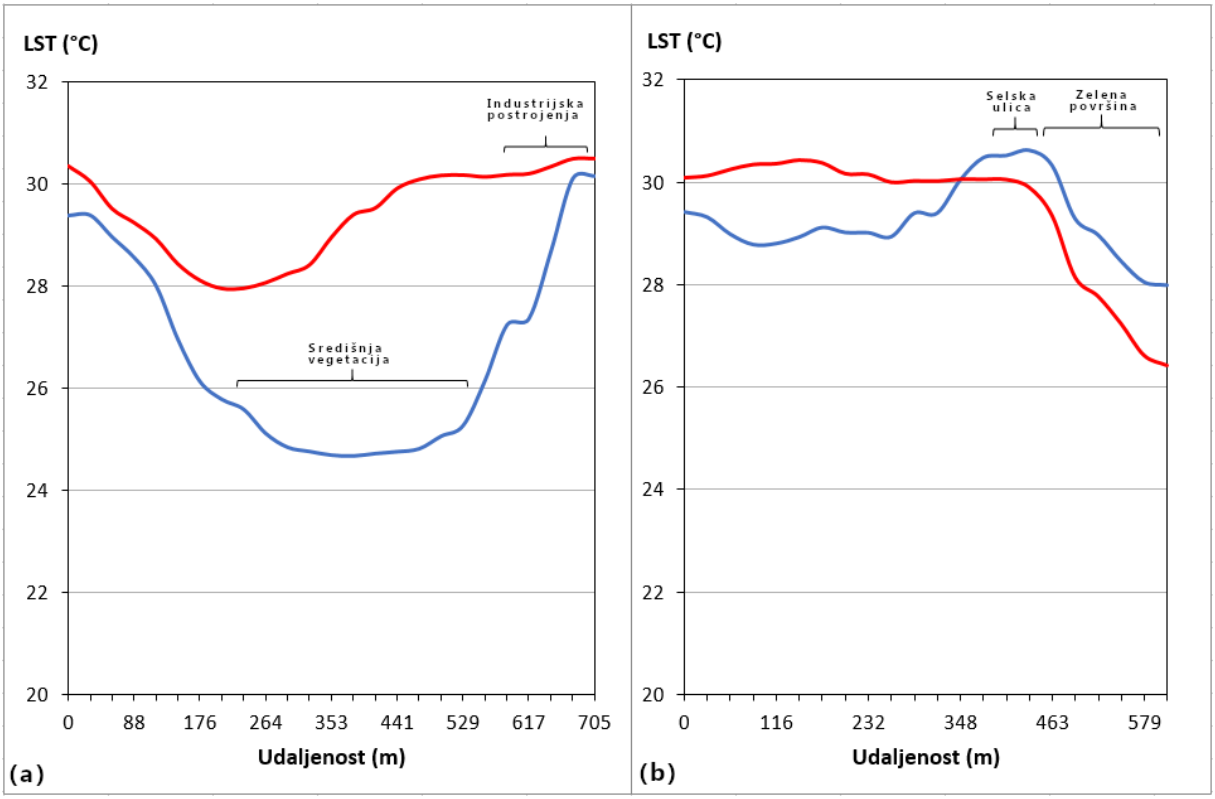
Zbog neodgovarajućih vrijednosti LST-a za 2019. godinu promjena je prenaglašena (sl. 18c). Njezinom analizom nije moguće dobiti odgovarajući uvid u stvarne promjene do kojih je došlo zbog promjene obilježja podloge te stoga ona za zimsko razdoblje područja *Stambene zgrade Selska* ne može biti provedena.



Sl. 18. Toplinska obilježja područja *Stambene zgrade Selska* za zimsko razdoblje: (a) LST 2000./2001. godine; (b) LST 2019./2020. godine; (c) promjena LST-a

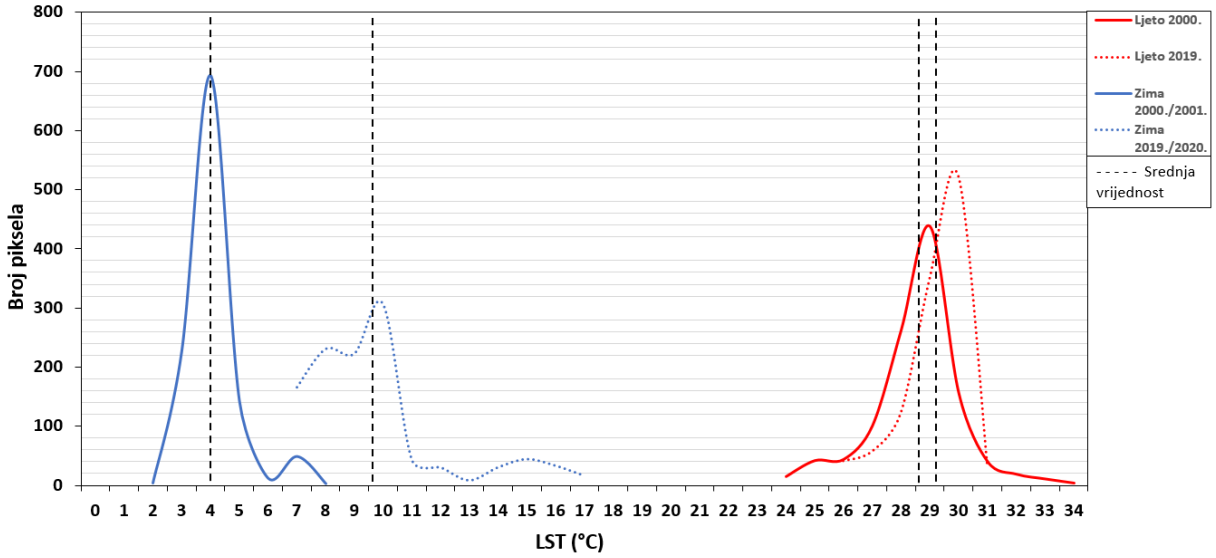
Horizontalni toplinski profili za ljetno razdoblje ponovno vrlo dobro vizualno prikazuju kako se LST mijenja. Na sl. 19a prikazan je profil između točaka 1 i 2 sa sl. 16. Za ljetno razdoblje 2000. godine UGS je vrlo jasno izražen nižim vrijednostima LST-a. Također jasno se uočava postupno povišenje vrijednosti LST-a približavanjem širokoj Selskoj ulici, a zatim i površinama pod industrijskim postrojenjima. Nakon izgradnje, 2019. godine profil je ujednačeniji. Niže vrijednosti LST-a bilježe se u početnom dijelu linije što se poklapa s manjim neizgrađenim dijelom područja. Drugi profil između točaka 3 i 4 ne kreće se područjem promjene (sl. 19b), već je odabran kako bi prikazao ujednačenost LST-a nepromijenjenih područja između dviju odabranih godina. LST ne varira značajno, maksimalno 1 – 1,5 °C, a

vrijednosti se mijenjaju usporedno. Također, vrlo se dobro uočava utjecaj prometnice, tj. Selske ulice, kao i nagli pad LST-a nad zelenom površinom.



Sl. 19. Horizontalni profili LST-a za ljetno razdoblje 2000. (plave linije) i 2019. godine (crvene linije): (a) između točaka 1 i 2; (b) između točaka 3 i 4 (sl. 16)

Analiza raspodjele piksela prema temperaturnim razredima (sl. 20) pokazuje nepouzdanost podataka za zimsko razdoblje 2019./2020. Obzirom na značajnu izgrađenost područja krivulja bi trebala biti oblikom sličnija ljetnom razdoblju 2019. godine što nije primijećeno. S druge strane, za zimsko razdoblje 2000./2001. veći dio površine ima vrijednosti LST-a između 3 – 5 °C, dok je manji dio između 7 – 8 °C što se povezuje s industrijskim postrojenjima i drugim izgrađenim površinama prisutnim u analiziranom području. Za ljetno razdoblje 2000. godine temperatura piksela pokazuje širi raspon temperatura nego 2019. godine. Najniže vrijednosti LST-a vežu se za UGS, a najviše za kompaktne izgrađene površine, dok je ostali veći dio područja u rasponu 28 – 31 °C. Nakon izgradnje stambenih zgrada na području UGS-a, više nisu primjetne niske vrijednosti kao 2000. godine, a najveći broj piksela nalazi se u rasponu 29 – 32 °C.



Sl. 20. Broj piksela po temperaturnim razredima (veličina razreda je 1 °C) za ljetno i zimsko razdoblje cijelog područja *Stambene zgrade Selska*

Prosječna vrijednost LST-a ljetnog razdoblja porasla je između 2000. i 2019. godine za 0,7 °C za cijelo područje (tab. 9). U području promjene ta je vrijednost naglašenija i iznosi 2,1 °C, dok je za neizmijenjeno područje razlika samo 0,3 °C. Ta je razlika slična onima za referentna područja koje su iznosile 0,3 i 0,5 °C. Minimalne, ali i maksimalne vrijednosti LST-a u ljetnom razdoblju zabilježene su 2000. godine. Minimalne radi prisustva UGS-a, a maksimalne vjerojatno radi tamnijih krovova industrijskih postrojenja. Na primjeru *Arena centra* vrijednosti standardne devijacije bile su izraženije za 2019. godinu. Međutim, u ovom slučaju situacija je suprotna. Zbog prisutnosti UGS-a 2000. godine veće su i vrijednosti standardne devijacije nego 2019. godine kada je većina područja prekrivena izgrađenom površinom. Može se utvrditi kako je standardna devijacija pokazatelj koji djelomično ukazuje na raznovrsnost tipova podloge ili na njihovu homogenost.

Rezultati zimskog razdoblja neće se međusobno uspoređivati zbog već spomenutih nepouzdanih rezultata 2019./2020. godine. Srednje vrijednosti za sva tri izdvojena područja 2000./2001. godine su gotovo iste (tab. 10). Područje promjene ima najmanji raspon, a ujedno i standardnu devijaciju. Tako niske vrijednosti sugeriraju i na niski utjecaj UGS-a na LST tijekom zime za razliku od utjecaja ljeti. Vrlo visoke vrijednosti standardne devijacije za zimsko razdoblje 2019./2020. posljedica su greške u podacima.

Tab. 9. Statistički pokazatelji LST-a (°C) područja *Stambene zgrade Selska* za ljetno razdoblje 2000. i 2019. godine

Statistički pokazatelj	2000.			2019.		
	Područje promjene	Neizmijenjeno područje	Cijelo područje	Područje promjene	Neizmijenjeno područje	Cijelo područje
Minimum	24,5	25,3	24,5	27,9	26,1	26,1
Maksimum	31,8	34,4	34,4	31,0	32,0	32,0
Raspon	7,3	9,1	9,9	3,1	5,9	5,9
Srednja vrijednost	27,2	29,4	29,1	29,3	29,7	29,7
Standardna devijacija	1,9	1,2	1,5	0,7	1,1	1,1

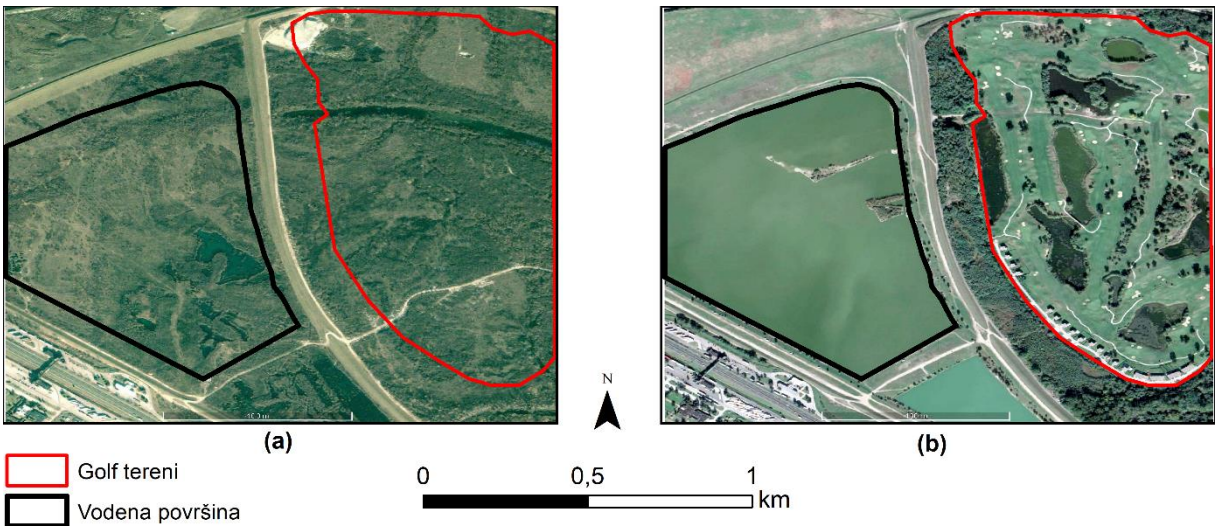
Tab. 10. Statistički pokazatelji LST-a (°C) područja *Stambene zgrade Selska* za zimsko razdoblje 2000./2001. i 2019./2020. godine

Statistički pokazatelj	2000./2001.			2019./2020.		
	Područje promjene	Neizmijenjeno područje	Cijelo područje	Područje promjene	Neizmijenjeno područje	Cijelo područje
Minimum	3,3	2,6	2,6	7,4	7,1	7,1
Maksimum	6,3	9,0	9,0	16,8	17,8	18,0
Raspon	3,0	6,4	6,4	9,4	10,7	10,9
Srednja vrijednost	4,8	4,5	4,6	12,6	9,8	10,1
Standardna devijacija	0,5	0,9	0,9	3,0	2,0	2,3

6.1.4. Kanal Sava-Odra

Treći primjer znatno se razlikuje u odnosu na *Arena centar* i *Stambene zgrade Selska* gdje je prvenstveno bilo riječ o promjeni prirodne podloge u izgrađenu. Na primjeru *Kanala Sava-Odra* interpretirat će se promjena jednog tipa prirodne podloge u drugi tip prirodne podloge, ali i u ovom slučaju pod antropogenim utjecajem. Naime 2000. godine područje je bilo gotovo u potpunosti prekriveno vegetacijom i djelomično vodenim površinama, ovisno o vodostaju rijeke Save (sl. 21a), no kasnije je uvedena stalna vodena površina. Uz nju, krenula je i izgradnja golf terena koji zauzima veliki dio područja (sl. 21b). Radovi su krenuli 2005./2006. godine, a

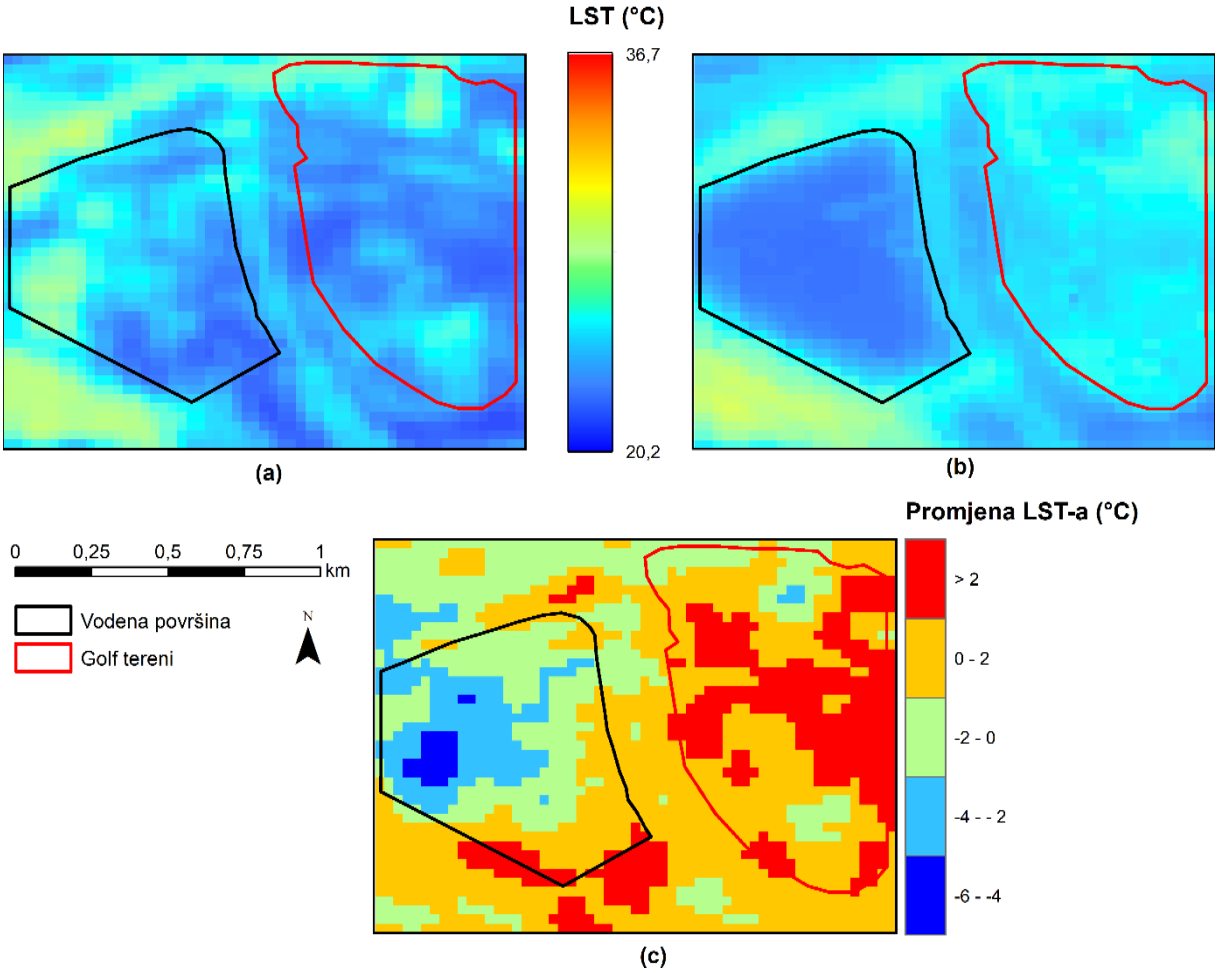
u većoj su mjeri završeni 2009. godine. Rezultati će se prikazati za dva područja. Prvo gdje je novi tip podloge kontinuirana vodena površina, a drugo za golf terene.



Sl. 21. Opća morfološka obilježja područja *Kanal Sava-Odra*: (a) prikaz 2001. godine; (b) prikaz 2019. godine

Za ljetno razdoblje 2000. godine najviše vrijednosti LST-a povezuju se s autocestom i odmorištem u jugozapadnom dijelu prikaza (sl. 22a). Najniži LST vezan je za vodene površine prisutne u području te gušću vegetaciju. Travnata područja okružena drvećem imaju više vrijednosti LST-a. Toplinska obilježja znatno se mijenjaju 2019. godine (sl. 22b). Do izražaja dolazi vodena površina za koju je LST niži, kao i područje golf terena gdje je LST u prosjeku viši. Dobro je vidljiv i pojas drveća koji okružuje golf terene, ali i manja jezera u sklopu njih sa nižim vrijednostima LST-a. Bitno je objasniti zašto je LST vodene površine niži od ostalih prirodnih površina. Naime, vodene površine imaju niski albedo, između 0,05 i 0,1, tj. svega se 5 do 10 % Sunčevog zračenja reflektira s njihove površina, a ostatak biva apsorbiran. Prema tome i vodene površine bi trebale imati visoku vrijednost LST-a. Međutim, voda posjeduje obilježja zbog kojih se apsorbirana toplinska energija manje troši na zagrijavanje vode, a većinom na evaporaciju te prelazi u latentnu toplinu i vodenu paru (Gunawardena i dr., 2017). Također, vodene površine mogu pohraniti velike količine energije zbog visokog specifičnog toplinskog kapaciteta i entalpije isparavanja. Zbog toga imaju visoku termičku inerciju, tj. sporije se hlade i sporije zagrijavaju (Oke, 1987). Stoga, vodene površine imaju značajno sniženi LST te sposobnost ublažavanja okolnih temperatura zraka ljeti. Ipak, zbog problema

tehničke prirode više se primijenjuje ozelenjivanje gradova, nego uvođenje vodenih površina kao poseban način kojim se može umanjiti negativan utjecaj UHI-a.

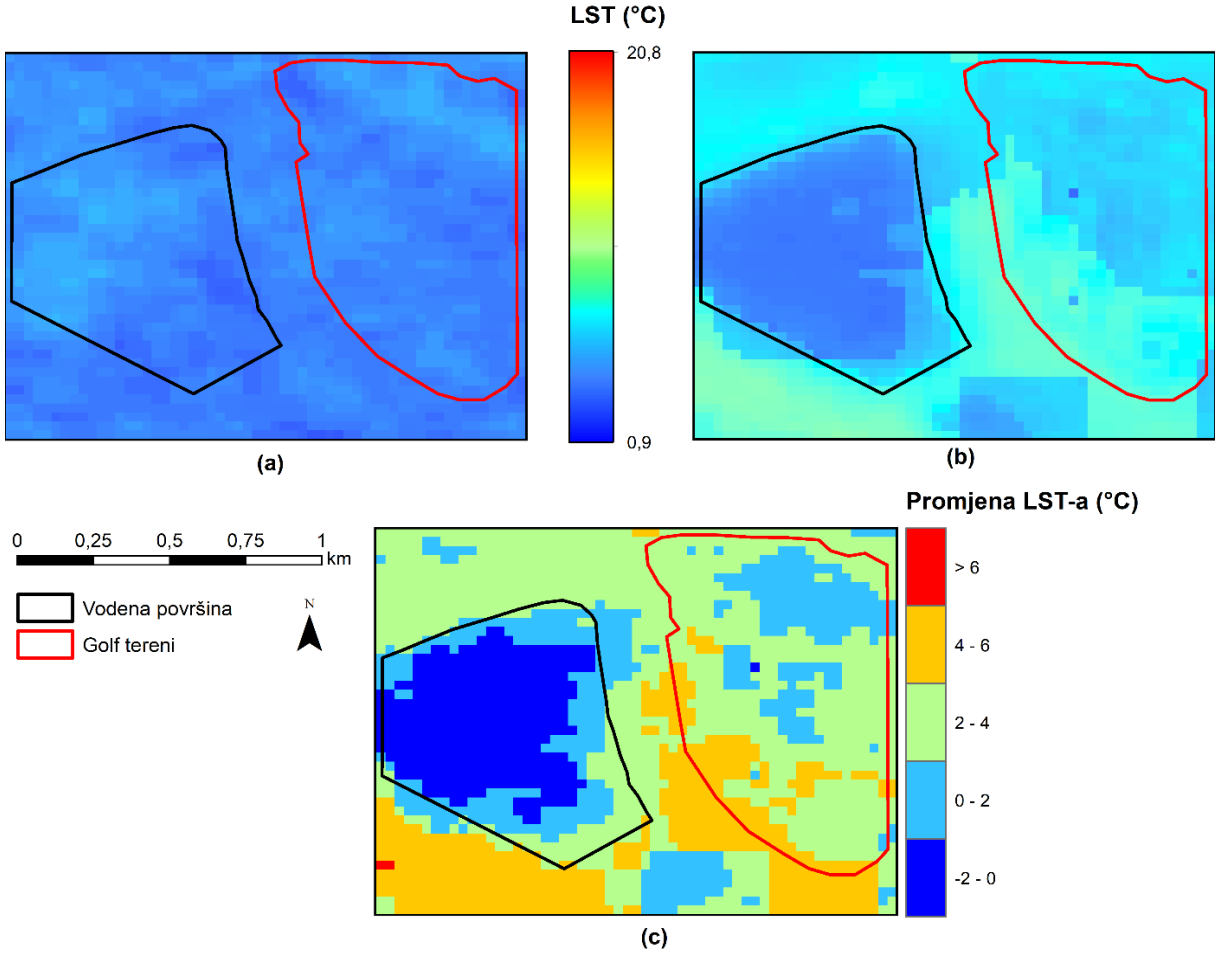


Sl. 22. Toplinska obilježja područja *Kanal Sava-Odra* za ljetno razdoblje: (a) LST 2000. godine; (b) LST 2019. godine; (c) promjena LST-a

Uočeno povišenje LST-a zbog izgradnje golf terena vezano je za niske travnjake koji su zamijenili drvenastu vegetaciju. Albedo travnjaka viši je od albeda drvenaste vegetacije i varira između 0,15 i 0,25. Također se manje apsorbirane energije troši na evapotranspiraciju, a više na samo zagrijavanje površine što dovodi do viših vrijednosti LST-a.

Promjena LST-a između ljetnog razdoblja 2019. i 2000. godine pokazala je očekivane rezultate (sl. 22c). U području koje je pretvoreno u vodenu površinu tokom cijele godine došlo je do snižavanja vrijednosti LST-a od maksimalno 6 °C. Ipak, snižavanje LST-a većinom je u razredima između -4 do -2 °C te -2 do 0 °C. Rezultati potvrđuju očekivano i za novoizgrađene golf terene gdje je porast vrijednosti LST-a iznad 2 °C. Primjetno je i smanjenje LST-a tamo gdje su uvedene vodene površine unutar kompleksa golf terena.

Zimsko razdoblje 2000./2001. godine pokazuje male razlike u cijelom području (sl. 23). Najviše vrijednosti LST-a su oko 6 °C u dijelu područja pokrivenog travnjacima. Najniže su tamo gdje se nalaze pojedine manje površine prekrivene vodom, no temperatura im se ne spušta ispod 3 °C. Za zimsko razdoblje 2019./2020. temperatura vodene površina je najniža. Razlog je vjerojatno što se plitka masa vode zimi dosta ohladi u odnosu na tlo u okolici.

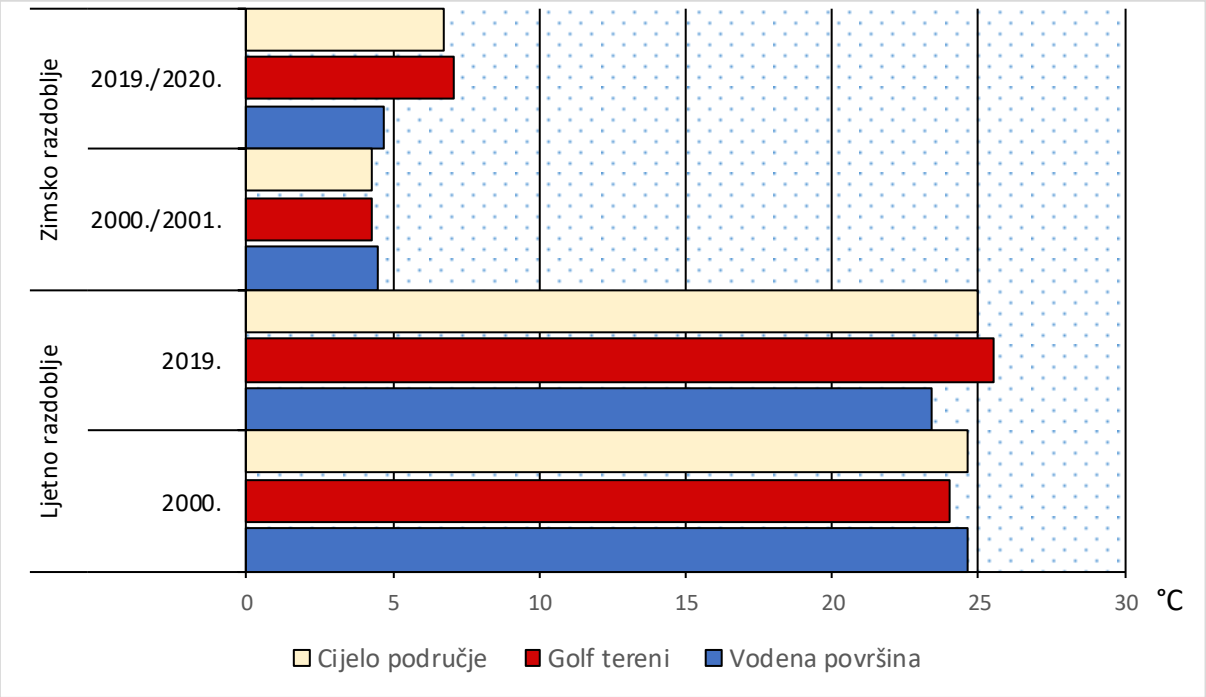


Sl. 23. Toplinska obilježja područja *Kanal Sava-Odra* za zimsko razdoblje: (a) LST 2000./2001. godine; (b) LST 2019./2020. godine; (c) promjena LST-a

Promjena LST-a pokazala je manje razlike u odnosu na ljetno razdoblje. Niži LST za vodenu površinu vrlo je dobro uočljiv i odgovara promjeni obilježja podloge. Međutim, vrijednosti promjene LST-a su u razredu od -2 do 0 °C, što je nešto niže nego za ljetno razdoblje. To se može objasniti toplinskom inercijom vodene površine. Za područje golf terena LST je porastao većinom između 2 do 4 °C.

Srednje vrijednosti LST-a za izdvojena područja prikazane su na sl. 24. Za zimsko razdoblje najveća je promjena za golf terene dok je izdvojeno područje vodene površine gotovo identične

vrijednosti LST-a. Porast za cijelo područje iznosi 2,4 °C. U ljetnom razdoblju jasnije je primijećen pad temperature uzrokovan uvođenjem vodene površine u područje, a smanjenje LST-a iznosi 1,2 °C. Iako je promjena relativno mala, bitno je napomenuti kako je 2000. godine većina tog područja bila prekrivena šumom koja je već tada utjecala na niske vrijednosti LST-a. Uvođenje vodene površine dodatno je naglasilo niske vrijednosti. U cijelom području prosječni LST je porastao za 0,4 °C u ljetnom razdoblju, a na golf terenima za 1,5 °C. Usporedba je pokazala da je 2019./2020. godine vodena površina prosječno hladnija za 3,7 °C u ljetnom razdoblju i 2,0 °C u zimskom u odnosu na cijelo okolno područje.

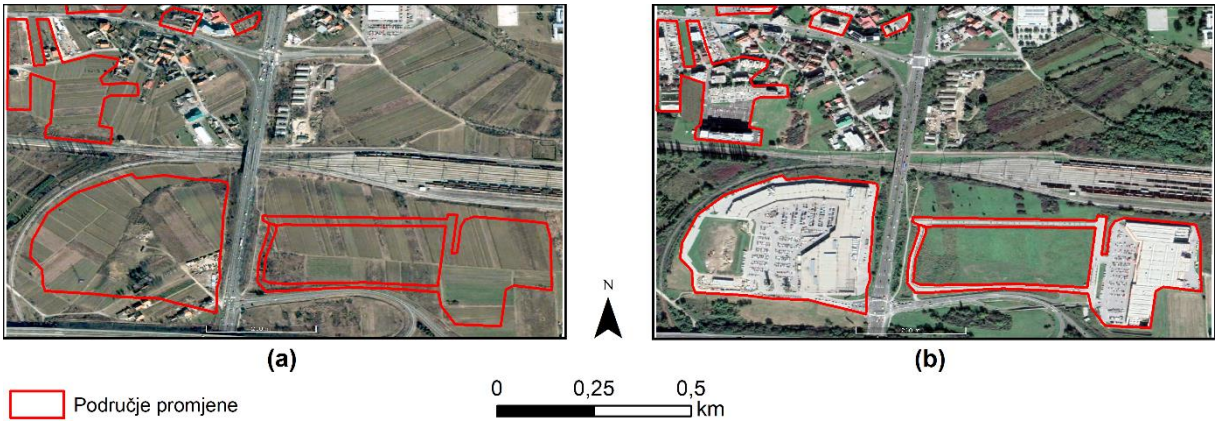


Sl. 24. Srednje vrijednosti LST-a prema izdvojenim područjima

6.1.5. Supernova i Bauhaus Buzin

Promjena obilježja podloge za ovaj primjer može se poistovjetiti s onom *Arena centra*. Također je riječ o području na rubu grada kod kojeg je došlo do izgradnje dva velika trgovačka centra, a u blizini i širenja stambeno-poslovnih zgrada gradskog naselja Sloboština. Izgradnja Supernove trajala je između 2009. i 2014., a zgrade Bauhausa između 2014. i 2016. godine. Morfološka obilježja prije izgradnje pokazuju da većinu područja čine poljoprivredne površine ili druge površine prekrivene vegetacijom (sl. 25a). Površina prekrivenih drvećem nema puno, a vegetaciju osim travnjaka mjestimično čini grmolika vegetacija. U analiziranom području nalaze se kolosijeci ranžirnog kolodvora, kao i prometnica koja spaja Novi Zagreb s Velikom

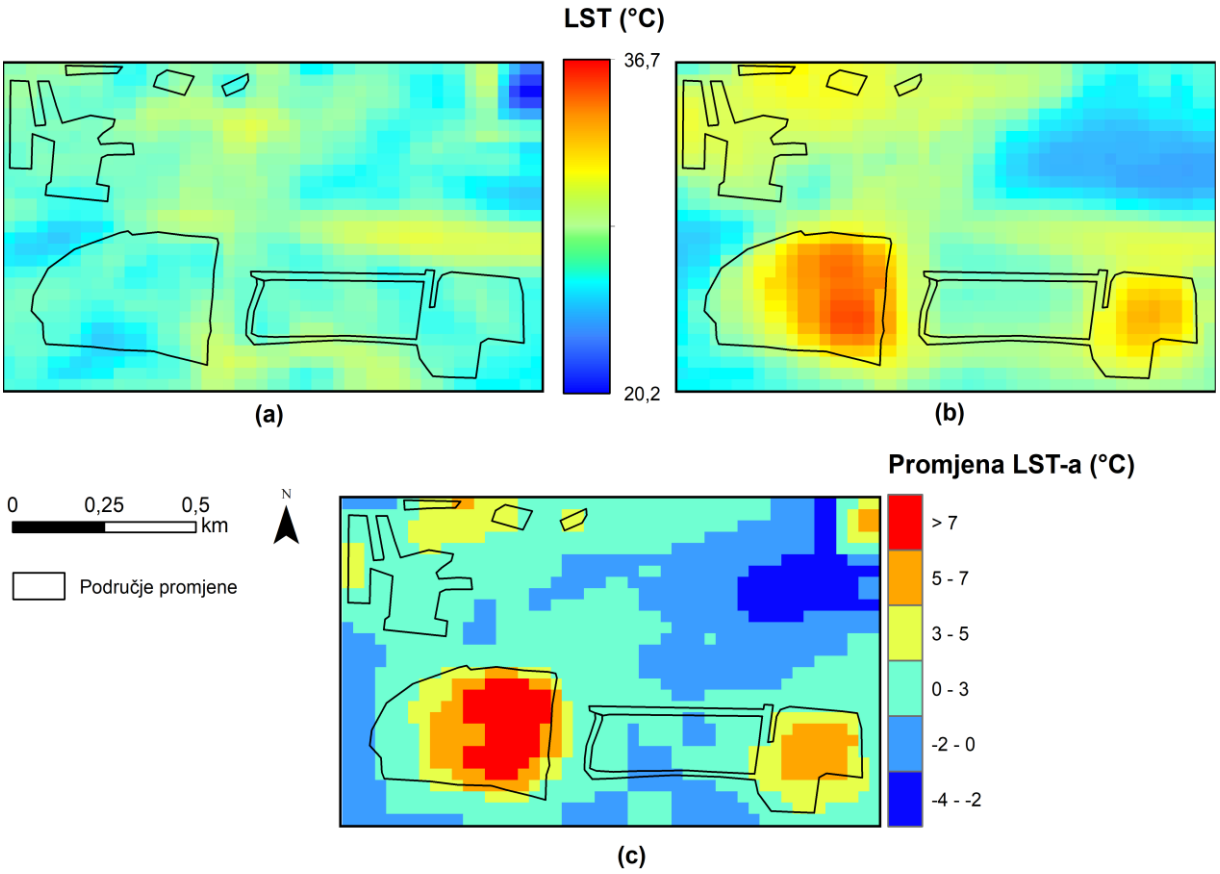
Goricom te obilaznicom. Od drugih izgrađenih površina to su većinom obiteljske kuće, ali i poslovno-industrijske građevine. Objekti koji se izdvajaju svojom veličinom 2019. godine su Supernova i Bauhaus. Blizina obilaznice, ali i Novog Zagreba čini ovu lokaciju atraktivnom za izgradnju ovakvih objekata, koji slično kao i *Arena centar* imaju velike dnevne cirkulacije ljudi. Zbog toga je, primjerice, parkiralište Supernove gotovo iste površine kao i sama zgrada trgovačkog centra. U sjeverozapadnom dijelu prikaza primjetno je širenje stambeno-poslovnih zgrada (sl. 25b). Širenje površine obrasle drvećem vidljivo je sjeverno od željezničkih kolosijeka. Na primjerima u prethodnim poglavljima dokazan je značajan utjecaj vegetacije na smanjenje vrijednosti LST-a. Tako će se i ovdje provjeriti do kakvih je toplinskih promjena došlo širenjem površine prekrivene drvećem nauštrb poljoprivrednih površina i travnjaka.



Sl. 25. Opća morfološka obilježja područja *Supernova i Bauhaus Buzin*: (a) prikaz 2002. godine; (b) prikaz 2019. godine

Za ljetno razdoblje 2000. godine (sl. 26a) najviša vrijednost LST-a vezana je za ranžirni kolodvor te iznosi nešto iznad 30 °C. Vrlo se dobro uočavaju prometnice kao najzagrijanije površine, a ističu se velika prometna raskrižja. Niske vrijednosti LST-a uočavaju se cijelim područjem zbog naglašenih prirodnih obilježja podloge. Doduše, grmolika vegetacija bilježi najniži LST, između 20 i 25 °C. Kao i u slučaju *Arena centra* mogu se uočiti zone višeg LST-a unutar poljoprivrednih površina koje vjerojatno odgovaraju golom tlu koje je prisutno dio ljeta. Dvadesetak godina poslije, toplinska obilježja podloge znatno su izmijenjena (sl. 26b). Maksimalne vrijednosti dosežu 36 °C na području Supernove i predstavljaju vrlo ugrijanu izgrađenu površinu. Bauhaus ima slična obilježja, no nešto nižeg LST-a, s maksimumom do 33,5 °C, a većinom između 32 i 33 °C. LST ranžirnog kolodvora je između 29 i 30 °C, kao i za 2000. godinu. Dakle, u sličnim uvjetima nepromijenjena površina kroz relativno duži niz godina pokazuje slična toplinska obilježja. Kao što je već napomenuto došlo je do proširenja površine

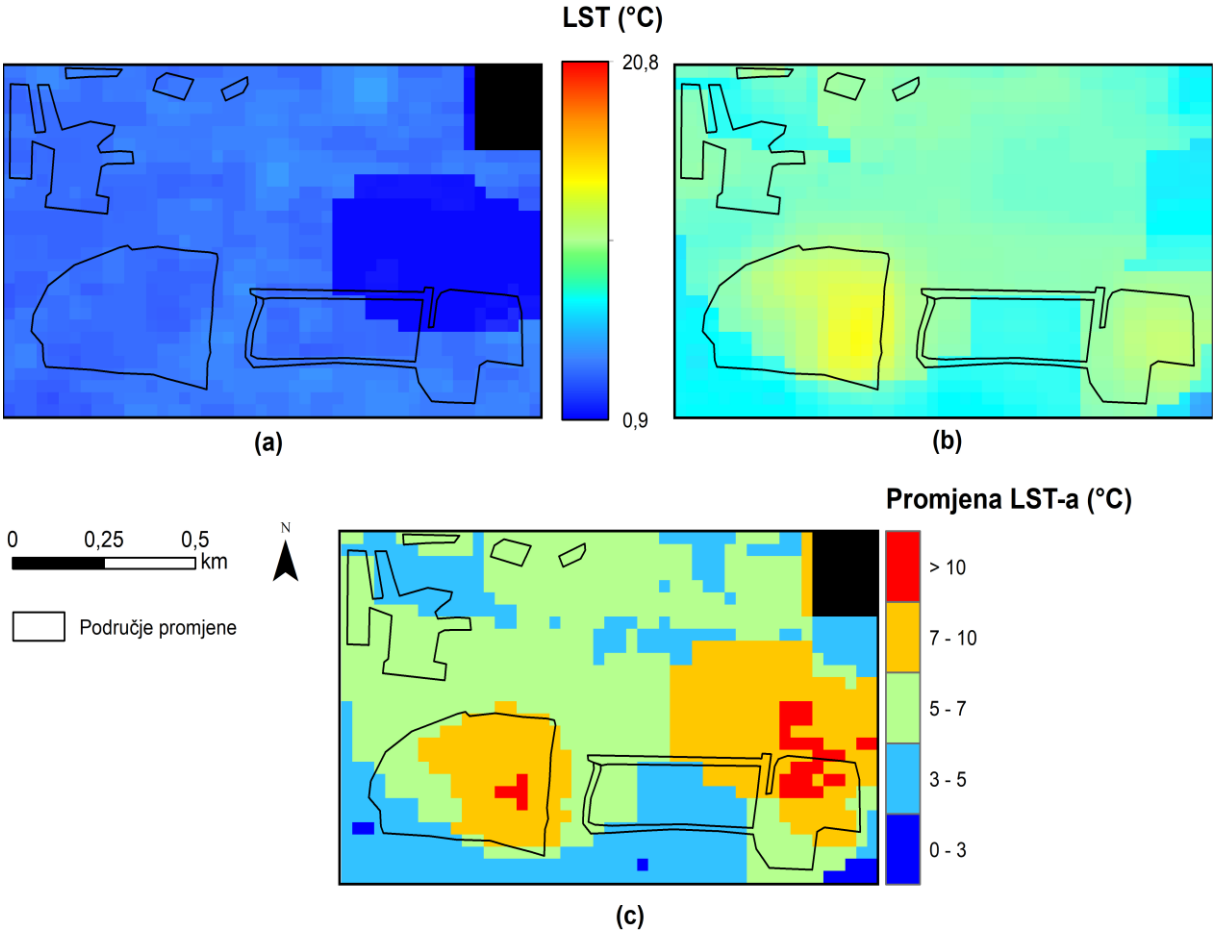
prekrivene drvećem sjeverno od ranžirnog kolodvora, što se vidi na sl. 25. Njeno širenje vjerojatno je potaknuto slabijom poljoprivrednom aktivnošću te se može očekivati da će trenutno prisutna grmolika vegetacija kroz određeni broj godina također poprimiti obilježja površine prekrivene drvećem. Širenje te površine podudara se s padom LST-a, koji iznosi oko 2 °C. Iako je riječ o prirodnom procesu širenja vegetacije, on dobro prikazuje kakav bi učinak bio kada bi čovjek primijenio ozelenjivanje u gradovima. Uvođenjem što više zelenih površina utječe se ne samo na smanjenje LST-a već i na kvalitetniji život građana u vidu manjeg toplinskog stresa, više prostora za rekreaciju te boljeg osjeta ugode.



Sl. 26. Toplinska obilježja područja *Supernova i Bauhaus Buzin* za ljetno razdoblje: (a) LST 2000. godine; (b) LST 2019. godine; (c) promjena LST-a

Promjena LST-a u ljetnom razdoblju vrlo jasno ukazuje na „otoke“ gdje je došlo do promjene obilježja podloge (sl. 26c). Ona je veća za Supernovu gdje porast iznosi i preko 7 °C za veći dio njene površine. Za Bauhaus je također zabilježen porast temperature, no za 2 – 3 °C niži u odnosu na Supernovu. Uočava se i pad temperature do kojeg je došlo zbog širenja površine prekrivene šumom, a on iznosi od -4 do -2 °C. Za područje stambeno-poslovnih zgrada na sjeveroistoku prikaza također je zabilježen porast vrijednosti LST-a.

Kao što je već naglašeno tokom rada, zimski su podaci nepouzdani, što se djelomično vidi i na ovom primjeru (sl. 27). Za dio područja 2000./2001. godine nije bilo dostupnih snimaka za izračun srednje vrijednosti LST-a (gornji desni kut na sl. 27a), dok je dio područja sjeverno od Bauhausa također pokazivao neočekivano niske vrijednosti. U ostatku područja ne uočavaju se

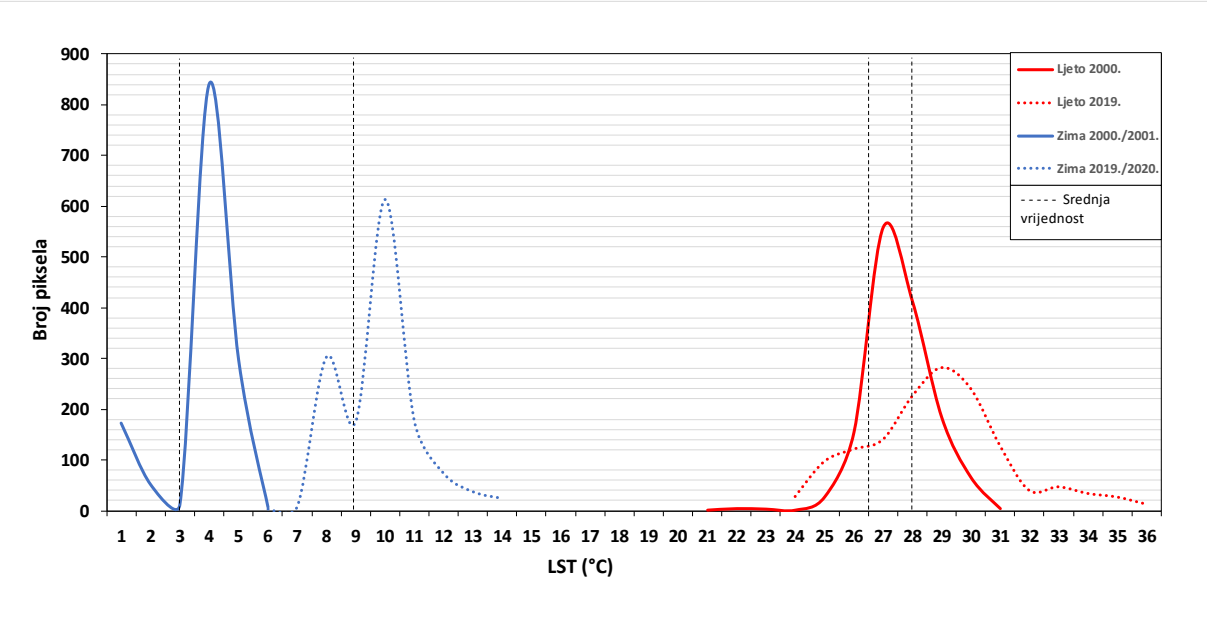


Sl. 27. Toplinska obilježja područja *Supernova i Bauhaus Buzin* za zimsko razdoblje: (a) LST 2000./2001. godine; (b) LST 2019./2020. godine; (c) promjena LST-a

velike razlike LST-a te se on kreće između 3 i 5 °C. Za 2019./2020. godinu prikaz je djelomično nejasan, no uočavaju se više temperature Supernove i Bauhausa. Tako je vrijednost LST-a za Supernovu oko 13 °C, a za Bauhaus oko 11 °C. Promjena LST-a pokazuje porast za Supernovu i Bauhaus, većinom u razredu porasta 7 – 10 °C, a za ostatak područja rezultati su nepouzdani.

Raspodjela piksela po temperaturnim razredima pokazuje da je za zimsko razdoblje 2000./2001. godine gotovo cijelo područje u razredu 3 – 5 °C (sl. 28). Pikseli s vrijednostima od 1 i 2 °C su pikseli s greškom, što se jasno vidi na sl. 27a. Za 2019./2020. vrijednosti variraju između 7 i 14 °C, a najviše vrijednosti u području vezane su za Supernovu i Bauhaus. Za 2000.

godinu veći dio područja je u razredu 26 – 30 °C, a manji u nižim i višim razredima. Za 2019./2020. ljetno razdoblje vrijednosti su u rasponu 24 – 36 °C zbog različitih tipova podloge s različitim toplinskim obilježjima. Tada se bilježe i najviše vrijednosti LST-a gdje su pretežno sve vrijednosti između 32 i 36 °C vezane za Supernovu i Bauhaus.



Sl. 28. Broj piksela po temperaturnim razredima za ljetno i zimsko razdoblje cijelog područja *Supernove i Bauhaus Buzin*

Prema statističkim pokazateljima prosječni porast LST-a za područje promjene u ljetnom razdoblju iznosi 5,6 °C (tab. 11). Neizmijenjeno područje ima tek blagi porast od 0,5 °C koji se pripisuje toplijem ljetu 2019. godine. Porast vrijednosti LST-a cijelog područja je 1,4 °C. On je, između ostalog, ublažen širenjem površine prekrivene drvećem čime se snizio LST u dijelu područja. Najveća apsolutna promjena dogodila se za maksimalnu temperaturu u iznosu 6,5 °C, a potaknuta je izgradnjom Supernove. Standardne devijacije su zbog većinom prirodnih obilježja podloge 2000. godine vrlo niske, a 2019. vrijednosti su znatno veće što je posljedica izgrađenih površina visokog LST-a.

Zimsko razdoblje pokazuje porast od 6,0 °C za cijelo područje (tab. 12). Veći dio tog porasta odnosi se na zimsko razdoblje 2019./2020. godine koje je bilo toplije od zimskog razdoblja 2000./2001. godine, ali i na problem prekrivenosti snimaka oblacima. Za područje promjene porast LST-a je 7,0 °C, a za neizmijenjeni dio područja 5,8 °C. Standardne devijacije su identične za cijelo područje za oba zimska razdoblja, dok su dvostruko veće za zimsko razdoblje 2019./2020. u području promjene.

Tab. 11. Statistički pokazatelji LST-a (°C) područja *Supernova i Bauhaus Buzin* za ljetno razdoblje 2000. i 2019. godine

Statistički pokazatelj	2000.			2019.		
	Područje promjene	Neizmijenjeno područje	Cijelo područje	Područje promjene	Neizmijenjeno područje	Cijelo područje
Minimum	24,7	20,2	20,2	27,5	23,7	23,7
Maksimum	29,2	30,3	30,3	35,7	33,5	35,7
Raspon	4,5	10,1	10,1	8,2	9,8	12
Srednja vrijednost	26,6	27,1	27,0	31,2	27,6	28,4
Standardna devijacija	0,7	1,2	1,2	2,1	1,9	2,4

Tab. 12. Statistički pokazatelji LST-a (°C) područja *Supernova i Bauhaus Buzin* za zimsko razdoblje 2000./2001. i 2019./2020. godine

Statistički pokazatelj	2000./2001.			2019./2020.		
	Područje promjene	Neizmijenjeno područje	Cijelo područje	Područje promjene	Neizmijenjeno područje	Cijelo područje
Minimum	0,4	0,9	0,9	7,5	5,3	5,1
Maksimum	4,7	5,1	5,1	14,0	13,0	14,0
Raspon	4,3	4,2	4,2	6,5	7,7	8,9
Srednja vrijednost	3,5	3,2	3,3	10,5	9,0	9,3
Standardna devijacija	0,8	1,4	1,3	1,6	1,0	1,3

6.2. Usporedba LST-a s NDVI-om

Vegetacija znatno utječe na vrijednosti LST-a što se vizualno pokazalo i u dosadašnjim rezultatima ovog rada. Usporedbom morfoloških i toplinskih obilježja za sva analizirana područja uočilo se podudaranje nižih vrijednosti LST-a s područjem gušće vegetacije. No, osim vizualne analize potrebno je provesti i detaljniju koja uključuje NDVI kao pokazatelja udjela vegetacije čime se može otkriti koliki je njen utjecaj na LST. Korelacija LST-a i NDVI-a najčešće je snažno negativna, tj. porastom NDVI-a dolazi do pada u vrijednostima LST-a (Gabor i Jombach, 2009; Guha i dr., 2018; Guha i Govil, 2020; Yue i dr., 2007). Ovaj obrazac

odnosa pokazao se točnim na svim analiziranim područjima upotrebom Pearsonovog koeficijenta korelacije te regresijske analize srednjih vrijednosti LST-a i NDVI-a.

U tab. 13 prikazane su srednje vrijednosti NDVI-a i LST-a svih analiziranih područja za ljetna razdoblja 2000. i 2019. godine. Najniže vrijednosti NDVI-a 2000. godine pokazuju *Gornji grad* i *Stambene zgrade Selska* koji su ujedno i područja s najhomogenijim obilježjima izgrađene podloge. Zbog manjeg udjela vegetacije, vrijednosti LST-a za ova dva područja su najviše u odnosu na druga analizirana područja. Prosječni LST iznosi 28,5 °C za *Gornji grad*, odnosno 29,1 °C za *Stambene zgrade Selska*. Uzrok više vrijednosti LST-a za *Stambene zgrade Selska* jesu obilježja vegetacije gdje je većinom riječ o travnjacima i nešto rjeđoj prekrivenosti stablima naspram *Gornjeg grada* gdje je većinom riječ o gustim stablima (visok NDVI), što utječe na snižavanje srednje vrijednosti LST-a. S druge strane, područja najviših vrijednosti NDVI-a su *Kanal Sava-Odra i ruralna okolica*. Za *Kanal Sava-Odra* zabilježena je najniža vrijednost LST-a (24,6 °C) od svih zabilježenih, dok *ruralna okolica* unatoč visokoj vrijednosti NDVI-a vjerojatno ima viši LST zbog golog poljoprivrednog tla kroz veći dio ljeta. Slične vrijednosti NDVI-a 2000. godine imaju *Arena centar* i *Supernova i Bauhaus Buzin*. Njihova su morfološka obilježja također vrlo slična, a 2000. godine oba područja su bila pretežito poljoprivredne namjene (sl. 11, sl. 25), kao i analizirano područje *ruralne okolice*, zbog čega su im vrijednosti LST-a vrlo slične. Razlika *ruralne okolice* i *Supernove i Bauhaus Buzin* iznosi svega 0,1 °C, a *ruralne okolice* i *Arena centra* 1,1 °C.

Gornji grad i *Stambene zgrade Selska* i 2019. godine ponovno pokazuju najniže vrijednosti NDVI-a (tab. 13). Iako se prema promjeni u obilježjima podloge očekivao pad u vrijednostima NDVI-a za *Stambene zgrade Selska*, on je ostao gotovo isti. Mogući razlog je relativno mala površina na kojoj je došlo do promjene obilježja podloge koja stoga nije imala veliki utjecaj na srednju vrijednost NDVI-a. Vrijednosti LST-a i NDVI-a u obje godine su vrlo slične za *Gornji grad*, a djelomično i za *Stambene zgrade Selska* gdje je LST 2019. godine veći za 0,6 °C u usporedbi s 2000. i time predstavlja najvišu zabilježenu vrijednost LST-a od svih analiziranih područja (29,7 °C). U usporedbi s 2000. godinom, *ruralnoj okolici* se povećao NDVI za 0,1. Vjerojatan razlog tomu je povećanje poljoprivredne aktivnosti, tj. veća kultivirana površina čemu je posljedica niža vrijednost LST-a za 0,5 °C, što se razlikuje od svih ostalih analiziranih područja za koje je zabilježen porast LST-a. Područje *Kanala Sava-Odra* 2019. godine ima nižu vrijednost NDVI-a za 0,22. Smanjenje odgovara promjenama podloge gdje je veći dio područja pod gušćom vegetacijom zamijenjen vodenom površinom i travnjacima. Bitno je naglasiti da je NDVI niži 2019. godine zbog negativnih vrijednosti NDVI-a vodene površine. Stoga se može

činiti da su zbog nižeg NDVI-a umanjena prirodna obilježja podloge, što nije točna tvrdnja. Iako bi se na osnovu smanjenja NDVI-a očekivale puno više vrijednosti LST-a, zabilježen je tek blagi porast LST-a od 0,4 °C, a to je posljedica toplinskih svojstava različitih podloga. Naime, ljeti je naglašeniji utjecaj visokog LST-a travnjaka na srednju vrijednost cijelog područja, nego ohlađujućeg utjecaja vodene površine. *Arena centar* doživjela je drugo najveće smanjenje NDVI-a od 0,12, a u isto vrijeme porast LST-a za 3,5 °C. *Supernova i Bauhaus Buzin* ima vrlo sličan NDVI za obje godine što se ne podudara s izgradnjom novih površina od umjetnih materijala. No, 2019. godine gotovo se ne primijećuju poljoprivredne površine koje su 2000. godine prekrivale veći dio područja (sl. 25). Danas su te površine uglavnom zarasle pa je riječ o travnjacima, grmolikoj vegetaciji i površinom pod drvećem. Najveći doprinos povećanju NDVI-a ima širenje površine pod drvećem, no nipošto ne u tolikoj mjeri da nadoknadi smanjenje uzrokovano zamjenom poljoprivredne površine izgrađenom. Stoga se može pretpostaviti da su promjena poljoprivredne površine u izgrađenu s jedne strane (smanjenje NDVI-a) i poljoprivredne površine u zapušteno zemljište s druge strane (povećanje NDVI-a) međusobno „poništile“ jednu drugu te je NDVI ostao približno isti.

Tab. 13. Vrijednosti NDVI-a i LST-a za ljetno razdoblje 2000. i 2019. godine te njihova promjena

Analizirana područja	**NDVI**			**LST (°C)**		
	2000.	**2019.**	**Promjena**	**2000.**	**2019.**	**Promjena**
Gornji grad	0,37	0,38	0,01	28,5	28,8	0,3
Ruralna okolica	0,60	0,70	0,10	27,1	26,6	-0,5
Arena centar	0,53	0,41	-0,12	26,0	29,5	3,5
Stambene zgrade Selska	0,37	0,36	-0,01	29,1	29,7	0,6
Kanal Sava-Odra	0,66	0,44	-0,22	24,6	25,0	0,4
Supernova i Bauhaus Buzin	0,50	0,53	0,03	27,0	28,4	1,4

Provedena analiza srednjih vrijednosti LST-a i NDVI-a pruža dobar uvid u njihovu međuovisnost. Međutim, potrebna je dodatna statistička analiza kako bi se ona detaljnije objasnila. U tu svrhu analizirana je korelacija LST-a i NDVI-a korištenjem Pearsonovog koeficijenta korelacije [r] čije se vrijednosti kreću od -1 do +1. Vrijednost od -1 govori o potpunoj negativnoj povezanosti dviju varijabli, od 0 da povezanosti nema te od +1 o potpunoj pozitivnoj povezanosti varijabli.

Dobiveni koeficijenti korelacije (tab. 14) pokazuju negativan odnos LST-a i NDVI-a, osim za područje *Kanala Sava-Odra* 2019. godine. Prosječna apsolutna vrijednost koeficijenta 2000. godine za sva područja iznosi 0,78 što se nalazi na granici razreda srednje jake korelacije ($0,5 \leq |r| \leq 0,8$) i jake korelacije ($0,8 \leq |r| \leq 1,0$). Prosječna apsolutna vrijednost koeficijenta 2019. godine iznosi 0,69 i spada u razred srednje jake korelacije. Primjerice Guha i dr. (2018) dobili su korelaciju od -0,71 za Firencu i -0,56 za Napulj.

Jaku negativnu korelaciju 2000. godine pokazuju sva područja osim *ruralne okolice* i *Supernove i Bauhaus Buzin* kod kojih je korelacija srednje jaka (tab. 14). Samo *Gornji grad* i *Supernova i Bauhaus Buzin* imaju jaku korelaciju 2019. godine dok sva ostala područja imaju srednje jaku korelaciju. Nije u potpunosti jasno koji sve faktori utječu na razlike u korelaciji, no jedan od glavnih su morfološka obilježja podloge analiziranog područja. Naime, Guha i dr. (2018) uočili su na primjeru Firence i Napulja da je LST-NDVI korelacija jača u prirodnom području u odnosu prema gušće izgrađenom urbanom. Tvrde da je razlog tomu složenost podloge urbanih područja, tj. različitih materijala kojima su NDVI vrijednosti relativno slične. Ipak, u ovom radu se za 2000. godinu pokazalo da *ruralna okolica* ima najnižu LST-NDVI korelaciju. Unatoč prirodnim obilježjima podloge riječ je o antropogeno izmijenjenom području poljoprivredne namjene gdje je riječ o ogoljelom poljoprivrednom tlu koje nema obilježja tla prekrivenog vegetacijom. Stoga je LST-NDVI korelacija slabija nego u drugim istraživanim područjima. No, iste godine *Kanal Sava-Odra* imao je vrlo jaku korelaciju, visok NDVI te ujedno slabo antropogeno izmijenjeno područje što znači da u neizmijenjenim prirodnim područjima postoji vrlo jaka LST-NDVI korelacija. Također, područje *Arena centra* 2000. godine, kada ima većinom prirodna obilježja podloge, ima i veću vrijednost korelacije nego 2019. godine. Dakle, uvođenjem kompaktne urbane podloge vrijednost korelacije se smanjila što ide u prilog saznanjima iz Guha i dr. (2018). Isto je primijećeno i za *Stambene zgrade Selska* gdje je vrijednost korelacije manja 2019. Ali, za *Gornji grad* koji ima kompaktnu urbanu podlogu vrijednost korelacije iznosi vrlo blizu 1 u obje godine, a za *Supernovu i Bauhaus Buzin* vrijednost korelacije raste između godina. Temeljem malog broja istraživanih područja teško je donijeti konkretne zakonitosti o odnosu LST-a i NDVI-a te je potrebno provesti sveobuhvatnije istraživanje koje bi pokrilo veće područje.

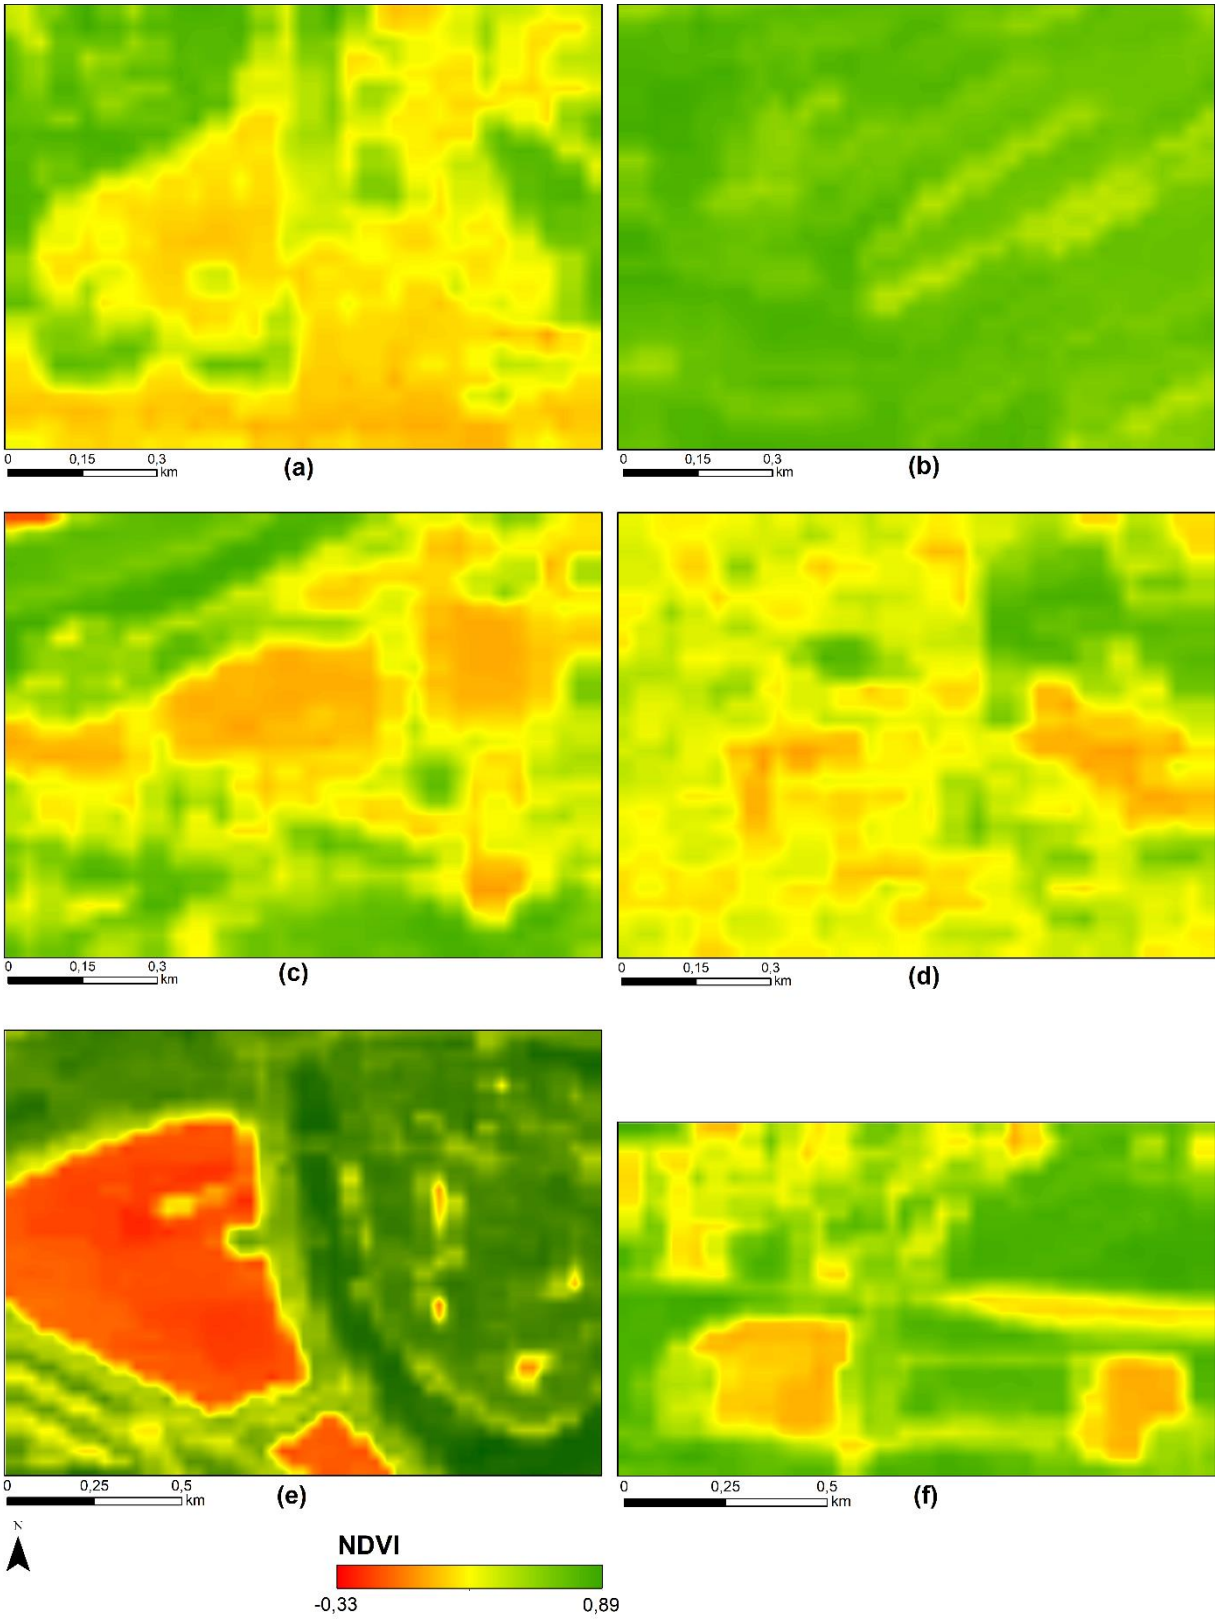
Iznimka od pravila uočena je za *Kanal Sava-Odra* 2019. godine što je posljedica prisustva površine prekrivene vodom. Naime, NDVI vodene površine je negativan zbog čega je vrijednost LST-NDVI korelacije 2019. godine pozitivna. Ova posebnost detaljnije je analizirana regresijskom analizom (sl. 30).

Tab. 14. Pearsonov koeficijent korelacije srednjih vrijednosti LST-a i NDVI-a 2000. i 2019. godine za sva analizirana područja

Godina	Gornji grad	Ruralna okolica	Arena centar	Stambene zgrade Selska	Kanal Sava-Odra	Supernova i Bauhaus Buzin
2000.	-0,93	-0,58	-0,81	-0,81	-0,87	-0,66
2019.	-0,87	-0,67	-0,59	-0,67	0,52	-0,81

Kako bi se provjerio utjecaj vegetacije na vrijednosti LST-a u što recentnijim uvjetima izgrađenosti, za ljetno razdoblje 2019. godine provedena je analiza prostorne raspodjele NDVI-a te regresijska analiza ovisnosti LST-a o NDVI-u.

Prostorna raspodjela NDVI-a 2019. godine prikazana je na sl. 29. Najniža vrijednost NDVI-a iznosi -0,33 i vezana je za vodenu površinu jezera pri početku *Kanala Sava-Odra*. Na istom se području nalazi i najviša vrijednost NDVI-a, 0,89. Za *Gornji grad* (sl. 29a) NDVI vrlo dobro ističe razliku izgrađenih i prirodnih površina prema sl. 8. Najviše vrijednosti NDVI-a su između 0,75 i 0,80 te se vežu za UGS površine poput *Parka šume Tuškanac*, *Parka Ribnjak*, *Parka Grič* i drugih zelenih površina. Izgrađene površine najnižih su vrijednosti NDVI-a te ne prelaze 0,2 što potvrđuje tab. 2. Ovaj se prag vrijednosti NDVI-a često koristi u istraživanjima prilikom klasifikacije područja pod vegetacijom (Hashim i dr., 2019). Dakle, vrijednosti ispod 0,2 najčešće predstavljaju sve površine bez vegetacije, a iznad 0,2 površine s vegetacijom. *Ruralna okolica* (sl. 29b) i vizualno ima istaknut visoki NDVI. Najniža vrijednost NDVI-a iznosi 0,43, a najviša 0,86. Vidljiv je uzorak izduženih parcela poljoprivredne namjene zemljišta (sl. 10). Za *Arena centar* obilježja su slična kao i za *Gornji grad*. Međutim, za *Gornji grad* riječ je o nešto heterogenijim obilježjima umjetnih podloga pa je NDVI bio i blago viši, uglavnom između 0,1 – 0,2. Za *Arena centar* površinom prevladavaju krovovi zgrada (sl. 11), a njihov je LST stoga i bliži 0, tj. većinom je između 0,05 – 0,1. Minimalni NDVI je -0,13, koji odgovara površini rijeke Save. Za razliku od toplinske karte *Arena centra* (sl. 12) gdje su zelene površine među izgrađenim površinama bile slabo vidljive, ovdje su one jasno izdvojene. Za *Stambene zgrade Selska* uočljivi su „otoci“ niskih NDVI vrijednosti, koje odgovaraju krovovima visokih stambenih zgrada (sl. 17). Slično je i za industrijske zgrade koje imaju vrlo velike površine krovova i pokazuju najniži NDVI, između 0,05 i 0,1. S druge strane, niski stambeni objekti u većem dijelu područja imaju NDVI između 0,3 i 0,4 što je posljedica vegetacije među objektima zbog čega dolazi do miješanja signala koje prima satelit.



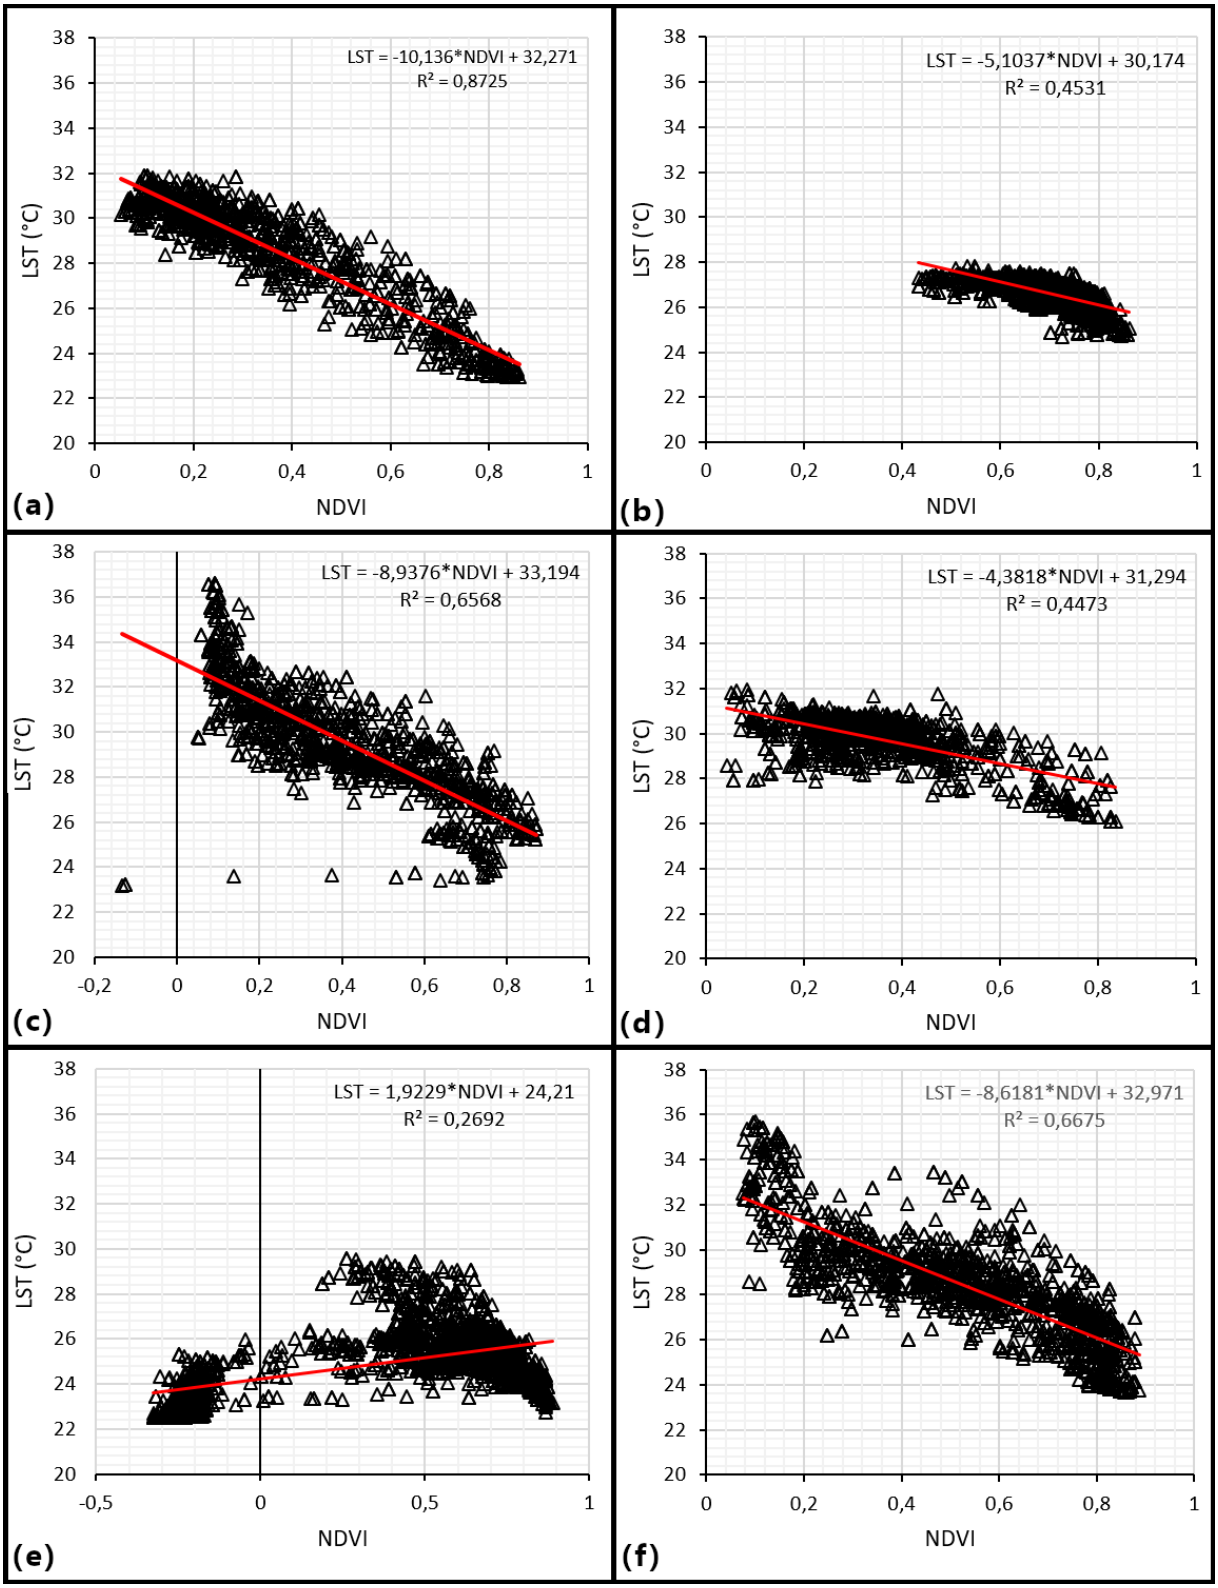
Sl. 29. Prostorna raspodjela NDVI-a 2019. godine za: (a) *Gornji grad*; (b) *ruralna okolica*; (c) *Arena centar*; (d) *Stambene zgrade Selska*; (e) *Kanal Sava-Odra*; (f) *Supernova i Bauhaus Buzin*

Kanal Sava-Odra primjer je gdje NDVI ima negativne vrijednosti, što je uzrokovano površinom prekrivenom vodom (sl. 21). Vrijednosti NDVI-a velikog jezera su između -0,30 i -0,20, dok manja jezera u sklopu golf terena imaju vrijednosti NDVI-a između -0,05 i -0,15. Pojas gustog drveća koji okružuje golf terene ima najveći NDVI, između 0,85 i 0,89.

Iako su i pomoću toplinskih karata LST-a površine pod vegetacijom bile dobro vidljive, za njihovo su izdvajanje korisnije karte NDVI-a koje bolje ističu sama svojstva podloge. Također, negativne vrijednosti vodenih površina doprinose njihovom isticanju te se stoga pomoću metode pragova NDVI vrijednosti mogu klasificirati tri osnovna tipa podloge: vodena površina, površina pod vegetacijom te površina bez vegetacije.

Provedenom linearnom regresijskom analizom za 2019. godinu dobiveni su koeficijenti determinacije i jednadžbe modela linearne regresije koji su prikazani na grafičkim prikazima linearne regresije (sl. 30). Najveća vrijednost R^2 je 0,8725 za područje *Gornji grad*, a najmanja za *Kanal Sava-Odra* (0,2692). Prema dobivenim koeficijentima determinacije (R^2) pomoću NDVI-a kao nezavisne varijable objašnjava se prosječno 56 % varijabilnosti LST-a za svih šest područja. Ukoliko se izostavi *Kanal Sava-Odra*, tada se prosječno objašnjava 62 % varijabilnosti LST-a. R^2 pokazatelj je reprezentativnosti linearnog modela koji je predstavljen jednadžbom za svako analizirano područje (sl. 30). Tom jednadžbom se mogu predviđati vrijednosti LST-a ukoliko je poznat NDVI. Primjerice, u slučaju da za dio piksela nisu dostupne vrijednosti LST-a, ali jesu NDVI-a, moguće je primijeniti jednu od iznesenih jednadžbi kako bi se izračunale odgovarajuće vrijednosti LST-a. Međutim, ukoliko je R^2 nizak i reprezentativnost modela je niska. Stoga, vrijednost R^2 bliže vrijednosti 1 povećava točnost i pouzdanost predviđenih vrijednosti LST-a.

Pravci linearnih modela slično su položeni za sva područja osim za *Kanal Sava-Odra*. Oni potvrđuju negativnu korelaciju LST-a i NDVI-a uočenu i u tab. 14. Niže vrijednosti NDVI-a odgovaraju višim vrijednostima LST-a, a vrijedi i obratno. U slučajevima gdje je veći dio površine izgrađen od umjetnih materijala vrijednosti su grupirane u lijevom dijelu dijagrama (nizak NDVI, visok LST) što je dobro vidljivo za *Gornji grad* i *Stambene zgrade Selska* (sl. 30a, sl. 30d). S druge strane, za *ruralnu okolicu* gdje je površina gotovo u potpunosti prirodna, vrijednosti modela su grupirane u desnom dijelu dijagrama (visok NDVI, nizak LST). Temeljem raspodjele podataka u modelu može se pretpostaviti veći ili manji udio vegetacije u pojedinom analiziranom području. Primjerice, za *Gornji grad* vrijednosti modela su gušće za visoke vrijednosti NDVI-a što govori o gušćoj i bujnijoj vegetaciji.



Sl. 30. Regresijska analiza LST-NDVI 2019. godine: (a) *Gornji grad*; (b) *ruralna okolica*; (c) *Arena centar*; (d) *Stambene zgrade Selska*; (e) *Kanal Sava-Odra*; (f) *Supernova i Bauhaus Buzin*

Arena centar i *Kanal Sava-Odra* jedina su analizirana područja koja imaju dio površine prekriven vodom. Sukladno tome, dio piksela bilježi negativne vrijednosti NDVI-a (sl. 30c, sl. 30e). One mogu značajno utjecati na rezultate modela. Međutim, model za *Kanal Sava-Odra* ima specifičan izgled. On se u pravilu može razdvojiti u dva segmenta. Prvi segment za negativne vrijednosti NDVI-a i drugi za pozitivne. Iz prikaza sl. 30e primjetno je da porast vrijednosti NDVI-a dovodi do porasta vrijednosti LST-a za prvi segment, dok je za drugi segment vidljiv sličan uzorak kao i za druga područja bez negativnih vrijednosti NDVI-a, tj. da porastom NDVI dolazi do pada LST-a. Stoga se postavlja pitanje u kojoj mjeri negativan NDVI, tj. površina prekrivena vodom utječe na rezultate modela. Prema modelu linearne regresije za cijelo područje se također očekuje porast vrijednosti LST-a s porastom vrijednosti NDVI-a, što nije očekivan odnos. On vrijedi iznimno za područje prekriveno vodenom površinom. Stoga je model linearne regresije modificiran pod utjecajem negativnog NDVI-a, što je vidljivo ne samo grafički već i prema koeficijentu korelacije, r = 0,52 (tab. 14), koji je jedini pozitivan, dok je za sva druga analizirana područja on negativan. Prema koeficijentu determinacije objašnjava se tek 27 % varijabilnosti LST-a te je model za *Kanal Sava-Odra* niske reprezentativnosti. Prema tome, utjecaj vodene površine je značajan u vidu korelacijske analize LST-a i NDVI-a te bi se njenim izdvajanjem dobili kvalitetniji rezultati.

7. Rasprava

Antropogeno izgrađene površine su jedan od glavnih uzroka visokih vrijednosti LST-a, dok prirodne podloge, tj. vegetacija i vodene površine imaju ohlađujući utjecaj te snižavaju LST (Gunawardena, 2017; Zhou i dr., 2013). Vuckovic i dr. (2017) u istraživanju UHI-a Beča naglašavaju da UHI može značajno varirati u ovisnosti o faktorima poput gustoće zgrada, tipa materijala, raširenosti vegetacije, itd. Isto se pokazalo i za svih šest analiziranih područja u radu, od kojih su dva referentna bez promjena u obilježjima podloge. Važno je istaknuti da male promjene LST-a ljeti za referentna područja ukazuju na stabilnost LST-a u dužem vremenskom razdoblju, tj. s druge strane da su upravo promjene u obilježjima podloge dovele do povećanja LST-a za ostala istraživana područja. Međutim, vrijednosti LST-a za zimsko razdoblje 2019./2020. godine bile su oko 4 °C veće nego 2000./2001. godine za oba referentna područja. Ta se vrijednost pripisuje vremenskim prilikama u trenucima snimanja satelitskih snimaka. Stoga je u istraživanjima ovakvog tipa poželjno provesti analizu stanja atmosfere u istraživanom razdoblju kako bi se time mogle objasniti eventualne nepravilnosti u rezultatima, kao što je i ovdje bio slučaj.

Lemus-Canovas i dr. (2020) i Zhou i dr. (2014) primijetili su veće raspone LST-a ljeti nego zimi. Raspon je definiran kao razlika minimalnog i maksimalnog LST-a. Zbog velike nepouzdanosti podataka, u ovom poglavlju nisu komentirani rasponi zimskog razdoblja 2019./2020. godine. Za sva analizirana područja u ovom radu raspon je, kao i u spomenutim radovima, bio veći ljeti. Razlog tomu je velika apsorpcija topline izgrađenih površina ljeti, a s druge strane i jači ohlađujući utjecaj vegetacije. Iz tog razloga ljeti izgrađene površine mogu imati ekstremno visoke vrijednosti LST-a koje su kontrast niskim vrijednostima LST-a površine s gustom vegetacijom iz čega proizlazi puno veći raspon nego zimi. Zimi je glavni uzrok manjeg raspona činjenica da listopadno drveće gubi lišće, a i općenito je manja aktivnost vegetacije zimi (Zhou i dr., 2014). Tako su Lemus-Canovas i dr. (2020) utvrdili raspon zimi između 4 – 6 °C, a ljeti 8 – 11 °C. U ovom je radu za zimsko razdoblje raspon većinom 3 – 7 °C, a za ljetno 7 – 10 °C.

Srednje vrijednosti LST-a pokazale su podudarnost među područjima sličnih obilježja podloge. Primjerice, područja *Arena centar, Supernova i Bauhaus Buzin* te *ruralna okolica* 2000. godine imaju većinom prirodnu podlogu te su im srednje vrijednosti LST-a u ljetnom (26 – 27,1 °C) i zimskom razdoblju (3,3 – 5,5 °C) slične. S druge strane, utjecaj umjetnih materijala za područja *Gornji grad* i *Stambene zgrade Selska* povećava prosječan LST, koji je ljeti 28,5 °C, odnosno 29,1 °C te zimi 4,5 °C, odnosno 4,6 °C. Također, *Kanal Sava-Odra* i prije i poslije promjene podloge ima naglašena prirodna obilježja podloge koja su razlog što to područje ima najniži LST u svim razdobljima osim zimskog 2000./2001. godine. Područja koja imaju veći udio izgrađene površine 2019./2020. godine ponovno pokazuju da su im vrijednosti LST-a slične, ljeti (28,4 – 29,7 °C) i zimi (8,4 – 10,5 °C). Također, vrijednosti LST-a su veće od područja s prirodnim obilježjima podloge (*ruralna okolica* i *Kanal Sava-Odra*). Zanimljivo je da je srednja vrijednost LST-a *Arena centra* i *Stambene zgrade Selska* veći od onog za *Gornji grad* unatoč tome što je riječ o središtu Zagreba. Time se ističe činjenica da su pojedini LUHI izraženiji od LUHI-a samog središta grada, no to ne znači da isto vrijedi i za temperature zraka koje imaju primarni utjecaj na osjet ugode građana. Međutim, mali je broj meteoroloških postaja na području gradova kojima bi se mogle usporediti temperature zraka različitih LUHI-a. Alternativa tomu je postavljanje automatskih meteoroloških instrumenata koji mogu mjeriti temperature zraka na točno odabranim lokacijama u određenom razdoblju čime bi se detaljnije mogle analizirati razlike u toplinskim obilježjima.

Uspoređujući izdvojena neizmijenjena područja primijećene su slične vrijednosti LST-a 2000./2001. i 2019./2020. godine što je potvrđeno i za referentna područja. Međutim, unutar

područja promjene zabilježen je porast vrijednosti LST-a, iako su se oni razlikovali intenzitetom. Tako je najveći porast zabilježen za *Arena centar* i *Supernovu i Bauhaus Buzin*, ljeti oko 5 °C, a zimi oko 7,5 °C. To je posljedica izgradnje građevina velike površine. No, za *Stambene zgrade Selska* ljeti je porast 2,1 °C, a zimi 7,8 °C. Veliki porast zimi je ipak posljedica nepouzdanih vrijednosti LST-a. Za ljeto je porast LST-a manji u odnosu na porast *Arena centra* i *Supernove i Bauhaus Buzin* jer su novoizgrađene zgrade visoke i međusobno udaljene jedne od drugih zbog čega se stvara sjena te se bilježe niže vrijednosti LST-a.

Ono što se ističe u izgrađenim područjima jesu razlike u albedu. Bonafoni i dr. (2016) primijećuju za grad Terni u Italiji da smanjenje albeda dovodi do povećanja LST-a. Mackey i dr. (2012) smatraju da uvođenje vegetacije manje utječe na smanjenje LST-a nego promjena refleksivnosti površine, tj. povećanje albeda. U ovom su radu na nekoliko primjera uočene razlike u albedu koje su rezultirale nižim LST-om na bjelijim površinama. To je dobro uočljivo za područje *Arena centra* gdje je LST sportske dvorane niži za 3 – 4 °C u odnosu na LST trgovačkog centra iako su obje građevine velikih dimenzija. Nadalje, povećanje površine pod vegetacijom primijećeno za *Supernovu i Bauhaus Buzin* smanjilo je LST za oko 2 °C. Time je načelno potvrđena pretpostavka prema Mackey i dr. (2012), ali budući da nisu korišteni točni podaci o albedu i porastu površine pod vegetacijom potrebno je detaljnije istraživanje koje bi analiziralo navedenu problematiku u Zagrebu.

Hipoteza da vegetacija u urbanim područjima smanjuje LST potvrđena je u nekoliko radova. Također, on je uglavnom istraživan ljeti kada je utjecaj vegetacije na LST najizraženiji zbog jake evapotranspiracije, snižavanja albeda te sjena koje stvaraju drveća (Zhou i dr., 2014). Majkowska i dr. (2016) u Poznanu ljeti određuju niži LST u UGS-u za oko 7 °C u odnosu na okolno urbano područje. Molnar (2016) za Budimpeštu dobiva vrijednost oko 10 °C. U ovom radu pokazala se sličnost s navedenim istraživanjima za ljetno razdoblje. U područjima gdje uz izgrađene površine postoje i prirodne, LST površina prekrivenih vegetacijom je niži između 3 – 8 °C. Međutim, ne utječu sve površine pod vegetacijom jednako na vrijednosti LST-a (Xiao i dr., 2018). Površine prekrivene gusto zasađenim drvećem imaju niži LST za oko 7 – 8 °C, a travnjaci za 3 – 4 °C. Također, poljoprivredne površine imaju specifična obilježja koja se tokom godine izmijenjuju, a s njima i vrijednosti LST-a. Primjerice, u radu je porastom vrijednosti NDVI-a *ruralne okolice* za 0,1 smanjena vrijednost LST-a ljetnog razdoblja za 0,5 °C. Budući da je NDVI pokazatelj zastupljenosti vegetacije, njegova je korelacija s vrijednostima LST-a statistički značajna za sva ljetna razdoblja što se podudara sa većinom istraživanja koji proučavaju ovu vezu. Isto je pokazala i linearna regresija za ljetno razdoblje 2019. godine. Ona

također pokazuje da vodene površine svojim negativnim vrijednostima NDVI-a smanjuju reprezentativnost linearnog modela. Tako je za *Arena centar* svega 10-ak od 1200 piksela prekriveno vodenom površinom rijeke Save. Radi provjere njihovog utjecaja na model, uklonjeni su iz linearne regresije nakon čega se koeficijent determinacije povećao za gotovo 0,1. Stoga je upitna potreba ispitivanja utjecaja NDVI-a na LST u slučaju vodenih površina. Ako se provodi, LST-NDVI korelaciju trebalo bi ispitati odvojeno za površine prekrivene vodom i površine bez prekrivenosti vodom. Za prve se očekuje pozitivna korelacija LST-NDVI, a za druge negativna, što je između ostalog dokazano i u rezultatima ovog rada.

Promjene obilježja podloge dovele su do promjene LST-a. Do najvećeg porasta LST-a došlo je na novoizgrađenim površinama s umjetnim materijalima dok je za pojedine primjere, poput *Kanala Sava-Odra*, promjena podloge u vodenu površinu dovela do sniženja LST-a. Sniženju LST-a doprinijelo je i širenje površine pod vegetacijom za *Supernovu i Bauhaus Buzin*. Time su potvrđene prve dvije postavljene hipoteze, H1 i H2. Područja su većinom prirodnih obilježja podloge 2000. godine, osim *Gornjeg grada* i *Stambene zgrade Selska,* te za njih tada nije vidljiv LUHI. Međutim, smanjenjem površina pod vegetacijom te povećanjem izgrađenih LUHI je postao vidljiv za sva područja osim *Kanala Sava-Odra* i *ruralna okolica*, koje imaju naglašena prirodna obilježja podloge, čime se potvrđuje H3. Također, LUHI je vidljiviji u ljetnom razdoblju, a slabije u zimskom što je posljedica malog broja satelitskih snimaka te nepouzdanosti LST-a. Potrebno je naglasiti da zimi za pojedina područja LUHI uopće nije uočen zbog malog broja snimaka na kojima bi se mogao detektirati. Zbog toga H4 ne može biti u cjelosti potvrđena.

8. Zaključak

U ovom radu ostvarena su sva četiri cilja i ispitane sve četiri hipoteze definirane u uvodnom dijelu rada. Metodom satelitske detekcije te upotrebom *Google Earth Engine*-a uspješno su izrađene toplinske karte i karte NDVI-a grada Zagreba prema kojima su ispitana toplinska obilježja izabranih referentnih područja i područja s promjenom u obilježjima podloge.

Landsat se pokazao vrlo koristan svojom prostornom rezolucijom, no istraživanje je ograničeno satelitskim snimkama prosječno svakih osam dana te isključivo oko 11:30 sati po lokalnom vremenu. Stoga, nije bilo moguće analizirati UHI u najtoplijem dijelu dana ili noću kada bi on trebao biti najizraženiji, što se u budućim istraživanjima može provesti upotrebom

podataka s drugih satelita, no lošije prostorne rezolucije. Također, u budućnosti se mogu očekivati bolje prostorne rezolucije satelita koje će doprinijeti kvalitetnijih analizama UHI-a.

Izračun srednje vrijednosti LST-a za ljetno razdoblje pokazao se pouzdanim zbog zadovoljavajućeg broja satelitskih snimaka bez prekrivenosti oblacima. Međutim, za zimsko razdoblje mali broj snimaka bez prekrivenosti oblacima uvjetovao je smanjenje pouzdanosti LST-a zbog čega je primijenjen kritički pristup tijekom analize rezultata zimskog razdoblja. Rezultati istraživanja pokazali su da je u ljetnom razdoblju UHI Zagreba najizraženiji, dok je u zimskom razdoblju on slabije izražen. U slučaju lokalne prostorne razine, u ljetnom i u zimskom razdoblju uočavaju se LUHI izgrađenih područja u gradu, no u zimskom razdoblju za poneke primjere nije mogao biti uočen zbog male pouzdanosti LST-a.

Pokazalo se da su toplinska obilježja za referentna područja *Gornji grad* i *ruralna okolica* ostala slična. Može se zaključiti da se u slučaju nepromijenjenosti u obilježjima podloge pojedinog područja mogu očekivati slične vrijednosti LST-a u uvjetima istovjetnih atmosferskih prilika. Za ostala analizirana područja novoizgrađene površine dovele su do povećanja vrijednosti LST-a. Tu se međuostalom ističe i potreba diferencijacije promjene obilježja podloge jer ne utječe svaka novoizgrađena površina jednako na porast LST-a. Primjerice, za *Arena centar* te *Supernovu i Bauhaus Buzin* porast LST-a zbog izgradnje parkirališta i trgovačkih/sportskih građevina bio je veći nego za *Stambene zgrade Selska* gdje je izgrađen niz međusobno udaljenih stambenih zgrada. Za *Kanal Sava-Odra* uvođenje vodene površine dovelo je do snižavanja LST-a, posebno za ljetno razdoblje, dok je izgradnja golf terena utjecala na porast LST-a. Prema tome, za sva analizirana područja, osim *Kanala Sava-Odra* došlo je do stvaranja, odnosno jačanja LUHI-a. Isto tako, temeljem uočenih promjena LST-a analiziranih područja može se pretpostaviti da su i ostala neanalizirana područja grada izgrađena u razdoblju 2000. do 2020. dovela do porasta LST-a, a tako i jačanja intenziteta UHI-a Zagreba.

Značajnim se pokazao utjecaj vegetacije na vrijednosti LST-a. Utjecaj je naglašeniji ljeti kada su zbog jake evapotranspiracije, snižavanja albeda te sjena koje stvara drveća primjetne niže vrijednosti LST-a površine pod vegetacijom u odnosu na izgrađena područja. Područje prekriveno drvećom ima jači ohlađujući utjecaj u odnosu na travnjake, dok su poljoprivredne površine pokazale nešto više vrijednosti LST zbog utjecaja golog tla tijekom dijela ljeta.

NDVI kao pokazatelj udjela vegetacije pokazao je negativnu korelaciju s LST-om u ljetnom razdoblju, osim za područje *Kanala Sava-Odra*. Pearsonovim koeficijentom korelacije

utvrđena je srednje jaka korelacija između LST-a i NDVI-a 2000. i 2019. godine, dok je regresijska analiza pokazala statistički značajnu ovisnost LST-a o NDVI-u 2019. godine.

Rezultati ovog rada mogu biti prošireni istraživanjem dužeg vremenskog perioda, bez ograničenja na pojedina ljetna ili zimska radzbolja. Također, UHI je pojava koji se javlja tijekom cijele godine zbog čega je potrebno analizirati njegova obilježja i u godišnjim dobima poput proljeća i jeseni. Usto, istraživanje UHI-a i toplinskih obilježja se može proširiti i na druge gradove u Hrvatskoj kako bi se doprinijelo saznanjima gradskih klima u Hrvatskoj.

Za kraj, potrebno je ukazati na važnost razvoja urbane klimatologije kao jedne od osnova za pametno planiranje gradskog prostora. Odabirom toplinski prihvatljivijih umjetnih materijala, ozelenjivanjem, ali i uvođenjem vodenih površina, boljim prostornim rasporedom građevina te mnogim drugim mjerama doprinosi se ublažavanju UHI-a gradova, a tako i Zagreba. Time se mogu smanjiti nepovoljne vrijednosti LST-a što se odražava na temperaturu zraka, a naposljetku i na zdravlje i uvjete života građana Zagreba.

Literatura

Alavipanah, S., Wegmann, M., Qureshi, S., Weng, Q., Koellner, T. 2015: The Role of Vegetation in Mitigating Urban Land Surface Temperatures: A Case Study of Munich, Germany during the Warm Season, *Sustainability* 7 (4), 4689-4706.

Anthony, J. B., Quatrocchi D., 2005: Urban Climatology, u *Encyclopedia Of World Climatology*, (ur. Oliver, J.E.), Springer, Dordrecht, 766-779.

Artis, D.A., Carnahan, W.H., 1982: Survey of emissivity variability in thermography of urban areas, *Remote Sensing of Environment* 12 (4), 313-329.

Aslan, N., Koc-San, D., 2016: Analysis Of Relationship Between Urban Heat Island Effect And Land Use/Cover Type Using Landsat 7 ETM+ and Landsat 8 OLI Images, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLI-B8, 821-828.

Babić, A., 2016: *Ispitivanje mogućnosti slobodnog softvera za određivanje temperature tla na temelju Lnadsat 8 satelitskih snimaka*, diplomski rad, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb

Bonacci, O., Roje-Bonacci, T., 2018: Analyses of the Zagreb Grič observatory air temperatures indices for the period 1881 to 2017, *Acta Hydrotechnika* 31, 67-85.

Bonafoni, S., Baldinelli, G., Verducci, P., 2016: Sustainable strategies for smart cities: Analysis of the town development effect on surface urban heat island through remote sensing methodologies, *Sustainable Cities and Society* 29 (1), 211-218.

Bonafoni, S., Baldinelli, G., Verducci, P., Presciutti, A., 2017: Remote Sensing Techniques for Urban Heating Analysis: A Case Study of Sustainable Construction at District Level, *Sustainability* 9 (8), 1-12.

Brunori, E., Salvati, L., Mancinelli, R., Smiraglia, D., Biasi, R., 2017: Multi-temporal land use and cover changing analysis: The environmental impact in Mediterranean area, *International Journal Of Sustainable Development & World Ecology*, 24 (3), 276-288.

Carlson, T.N., Ripley, D.A., 1997: On the relation between NDVI, fractional vegetation cover, and leaf area index, *Remote Sensing of Environment* 62 (3), 241-252.

Crippen, R.E., 1990: Calculating the vegetation index faster, *Remote sensing of Enviromnment*, 34 (1), 71-73.

Čmrlec, K., 2019: *Određivanje i kartiranje toplinskih otoka u Gradu Zagrebu pomoću satelitskih podataka*, diplomski rad, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb

Duplančić Leder, T., Leder, N., Hećimović, Ž., 2016: Određivanje površinske temperature tla područja Splita metodom daljinske detekcije, *Građevinar 68* (11), 895-905.

Duplančić Leder, T., Leder, N., 2018: Određivanje površinske temperature tla grada Mostara satelitskim metodama, *Elektronički zbornik radova Građevinskog fakulteta* 15 (8), 66-75.

Estoque, R. C., Murayama, Y., Myint, S.W., 2016: Effects of landscape composition and pattern on land surface temperature: An urban heat island study in the megacities of Southeast Asia, *Science of the Total Environment* 577, 1-11.

Gabor, P., Jombach, S., 2009: The relation between the biological activity and the land surface temperature in Budapest, *Applied Ecology and Environmental Research* 7 (3), 241-251.

Gill, S.E., Handley, J.F., Ennos, A.R., Pauleit, S., 2007: Adapting cities for climate change: the role of the green infrastructure, *Built Environment* 33 (1), 113-115.

Gorelick, N., Hnacher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017: Google Earth Engine: Planetary-scale geospatial analysis for everyone, *Remote Sensing of Environment* 202 (1), 18-27.

Guha, S., Govil, H., Dey, A., Gill, N., 2018: Analytical study of land surface temperature with NDVI and NDBI using Landsat 8 OLI and TIRS data in Florence and Naples city, Italy, *European Journal of Remote Sensing* 51 (1), 667-678.

Guha, S., Govil, H., 2020: An assessment on the relationship between land surface temperature and normalized difference vegetation index, *Environment, Development and Sustainability* 22 (4), 1-20.

Gunawardena, K.R., Wells, M.J., Kershaw, T., 2017: Utilising green and bluespace to mitigate urban heat island intensity, *Science of the total environment* 584-585, 1040-1055.

Gutman, G., Masek, J. G., 2012: Long-term time series of the Earth's land-surface observations from space, *International Journal of Remote Sensing* 33 (15), 4700–4719.

Hashim, H., Abd Latif, Z., and Adnan, N. A., 2019: Urban vegetation classification with NDVI threshold value method with very high resolution (VHR) Pleiades imagery, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XLII-4/W16, 237–240.

Hidalgo, J., Masson, V., Baklanov, A., Pigeon, G., Gimeno, L., 2008: Advances in urban climate modeling, *Annals of the New York Academy of Sciences* 1146, 354-374.

Hofierka, J., Gallay, M., Onačillova, K., Hofierka Jr., J., 2020: Physically-based land surface temperature modeling in urban areas using a 3-D city model and multispectral satellite data, *Urban Climate* 31 (1), 1-16.

Howard, L., 1833: *Climate of London Deduced from Meteorological Observations*, Harvey & Darton, London

Hrabak-Tumpa, G., 1988: Neke klimatske karakteristike toplinskog otoka Zagreba, *Republički hidrometeorološki zavod SR Hrvatske*, Zagreb, Jugoslavija

Hu, Y., Jia, G., 2009: Influence of land use change on urban heat island derived from multi-sensor data, *International Journal of Climatology* 30 (9), 1382-1395.

Huete, A.R., 2004: Remote sensing for environmental monitoring, u: *Environmental Monitoring and Characterization* (ur. Artiola, J.F. i dr.), Burlington, USA, Elsevier Academic Press, 183-206.

Hui, L., 2016: Literature Review on Cool Pavement Research, u: *Pavement Materials for Heat Island Mitigation* (eds. Hui, L.), Butterworth-Heinemann, Oxford, 15-42.

Kovačić, F., 2014: *Urbani toplinski otoci Grada Zagreba*, diplomski rad, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb

Kovačić, F., 2015: *Obrada i analiza temperature površine tla na temelju Landsat 8 podataka*, studentski rad nagrađen Rektorovom nagradom, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb

Landsberg, H.E., 1981: The Urban Climate, *International Geophysics Series* 28, University of Maryland, Academic Press Incorporation, New York

Lemus-Canovas, M., Martin-Vide, J., Moreno-Garcia, M. C., Lopez-Bustins, J. A., 2020: Estimating Barcelona's metropolitan daytime hot and cold poles using Landsat-8 Land Surface Temperature, *Science of the Total Environment* 699, 1-12.

Li, Z.L., Huazhong, R., Tang, B., Yan, G., 2013: Satellite-Derived Land Surface Temperature: Current Status and Perspective 131, 14-37.

Mackey, C. W., Lee, X., Smith, R. B., 2012: Remotely sensing the cooling effects of city scale efforts to reduce urban heat island, *Building and Environment* 49, 348–358.

Majkowska, A., Kolendowicz, L., Półrolniczak, M., Hauke, J., Czernecki, B., 2016: The urban heat island in the city of Poznań as derived from Landsat 5 TM, *Theoretical and Applied Climatology* 128 (3-4), 1-15.

Malakar, N.K., Hulley, G.C., Hook, S.J., Laraby, K., Cook, M., Schott, J.R., 2018: An Operational Land Surface Temperature Product for Landsat Thermal Data: Methodology and Validation, *IEEE Transactions on Geoscience and Remote Sensing* 56 (10), 5717-5735.

Maradin, M., Filipčić, A., 2018: Urban heat island intensity of Zagreb in summer and winter season, u: *Proceedings Geobalcanica 2018* (ur. Radevski, I. i dr.), *Geobalcanica Society, Skopje*, 3-13.

Masek, J.G., Vermote, E.F., Saleous N.E., Wolfe, R., Hall, F.G., Huemmrich, K.F., Gao, F., Kutler, J., and Lim, T-K., 2006: A Landsat surface reflectance dataset for North America, 1990–2000, *IEEE Geoscience and Remote Sensing Letters* 3 (1), 68-72.

Mateo-García, G., Gómez-Chova, L., Amorós-López, J., Muñoz-Marí, J., Camps-Valls, G. 2018: Multitemporal Cloud Masking in the Google Earth Engine, *Remote Sensing* 10 (7), 1079.

Mills, G., 2014: Urban Climate: History, Status And Prospects, *Urban Climate* 10 (3), 479-489.

Molnar, G., 2016: Analysis of land surface temperature and NDVI distribution for Budapest using Landsat 7 ETM+ data, *Acta Climatologica et Chorologica* 49-50, 49-61.

Mutanga, O., Kumar, L., 2019: Google Earth Engine Applications, u: *Google Earth Engine Applications* (eds. Kumar, L., Mutanga, O.), MDPI, 1-5.

Ogrin, D., 2015: Long-term air temperature changes in Ljubljana (Slovenia) in comparison to Trieste (Italy) and Zagreb (Croatia), *Moravian Geographical Reports* 23 (3) 17-26.

Ogrin, D., Krevs, M., 2015: Assessing Urban Heat Island Impact on Long-Term Trends of Air Temperatures in Ljubljana, *Dela* 43, 41-59.

Oke, T.R., 1969: Toward a more Rational Understanding of the Urban Heat Island, *Mcgill Climate Bulletin* 3 (1), 1-20.

Oke T.R. 1973: City size and the urban heat island, *Atmospheric Environment* 7, 769-779.

Oke, T.R., 1976: The Distinction between Canopy and Boundary Layer Urban Heat Islands, *Atmosphere* 14 (4), 268-277.

Oke T.R. 1982: The energetic basis of the urban heat island, *Quarterly Journal of the Royal Meteorological Society* 108, 1-24.

Oke, T.R., 1987: *Boundary Layer Climates*, Routledge, New York

Parastatidis, D., Mitraka, Z., Chrysoulakis, N., Abrams, M., 2017: Online Global Land Surface Temperature Estimation from Landsat, *Remote Sensing* 9 (12), 1-16.

Roy, D.P., Kovalskyy, V., Wulder, M.A., Loveland, T. R., Vogelmann, J., Woodcock, C.E., Kennedy, R., Zhu, Z., Allen, R.G., Trezza, R., Anderson, M.C., Helder, D., Irons, J.R., Johnson, D.M., Scambos, T.A., Schaaf, C.B., Lee, Z.P., Schott, J.R., Sheng, Y., Vermote, E.F., Belward, A.S., Bindschadler, R., Cohen, W.B., Gao, F., Hipple, J.D., Hostert, P., Huntington, J., Justice, C.O., Kilic, A., Lymburner, L., Masek, J.G., McCorkel, J., Shuai, Y., Wynne, R.H., 2014: Landsat-8: Science and product vision for terrestrial global change research, *Remote Sensing of the Environment* 145 (1), 154-172.

Sobrino, J. A., Raissouni, N., 2000: Toward remote sensing methods for land cover dynamic monitoring: application to Morocco, *International Journal of Remote Sensing* 21 (2), 353-366.

Sobrino, J.A., Jiménez-Muñoz, J.C., Paolini, L., 2004: Land surface temperature retrieval from LANDSAT TM 5, *Remote Sensing of Environment* 90 (4), 434-440.

Srivanit, M., Kazunori, H., 2011: The Influence of Urban Morphology Indicators on Summer Diurnal Range of Urban Climate in Bangkok Metropolitan Area, Thailand, *International Journal of Civil & Environmental Engineering* 11 (5), 34-46.

Šegota T., 1986: Srednja temperatura zraka u Zagrebu, *Geografski glasnik* 48, 13-25.

Šegota T., 1987: Maksimalne temperature zraka u Zagrebu, *Radovi* 22, 5-18.

Šegota T., 1988: Minimalne temperature zraka u Zagrebu, *Geografski glasnik* 50, 8-21.

USGS (United States Geological Survey), 2019a: *Landsat 7 (L7) Data Users Handbook*, Version 2.0, EROS Sioux Falls, South Dakota.

USGS (United States Geological Survey,) 2019b: *Landsat 8 (L8) Data Users Handbook*, Version 5.0, EROS Sioux Falls, South Dakota.

Vuckovic, M., Kiesel, K., Mahdavi, A., 2017: The Extent and Implications of the Microclimatic Conditions in the Urban Environment: A Vienna Case Study, *Sustainability* 9 (2), 1-16.

Wang, J. S., Zhan, Q., Ouyang, W., 2017: Impact of Urban Climate Landscape Patterns on Land Surface Temperature in Wuhan, China, *Sustainability* 9 (10), 1-16.

Xiao, H., Kopecká, M., Guo, S., Guan, Y., Cai, D., Zhang, C., Zhang, X., Yao, W., 2018: Responses of urban land surface temperature on land cover: a comparative study of Vienna and Madrid, Sustainability 10 (2), 1-19.

Yue, W., Xu, J., Tan, W., Xu. L., 2007: The relationship between land surface temperature and NDVI with remote sensing: application to Shanghai Landsat 7 ETM+data, *International Journal of Remote Sensing* 28 (15), 3205-3226.

Zhou,W., Qian, Y., Li, X., Li,W., Han, L., 2014: Relationships between land cover and the surface urban heat island: Seasonal variability and effects of spatial and thematic resolution of land cover data on predicting land surface temperatures, *Landscape Ecology* 29 (1), 153-167.

Izvori

DHMZ, 2000: *Meteorološki i hidrološki bilten, lipanj – rujan*; prosinac, Državni hidrometeorološki zavod, Zagreb, https://meteo.hr/proizvodi.php?section=publikacije&param=publikacije_publikacije_dhmz&el=bilteni, (5.5.2020.)

DHMZ, 2001: *Meteorološki i hidrološki bilten, siječanj - ožujak*, Državni hidrometeorološki zavod, Zagreb, https://meteo.hr/proizvodi.php?section=publikacije&param=publikacije_publikacije_dhmz&el=bilteni, (5.5.2020.)

DHMZ, 2019a: *Meteorološki i hidrološki bilten, lipanj – rujan*; prosinac, Državni hidrometeorološki zavod, Zagreb, https://meteo.hr/proizvodi.php?section=publikacije&param=publikacije_publikacije_dhmz&el=bilteni, (5.5.2020.)

DHMZ, 2019b: *Analiza ljeta 2019. godine po tipovima vremena*, Državni hidrometeorološki zavod, Zagreb, https://klima.hr/razno/publikacije/ljeto2019_tipovi.pdf, (5.5.2020.)

DHMZ, 2020a: *Meteorološki i hidrološki bilten, siječanj - veljača*, Državni hidrometeorološki zavod, Zagreb, https://meteo.hr/proizvodi.php?section=publikacije&param=publikacije_publikacije_dhmz&el=bilteni, (5.5.2020.)

DHMZ, 2020b: *O indeksu osjeta ugode*, https://meteo.hr/prognoze.php?section=prognoze_model&param=osjet_ugode&el=twh_opis (19.5.2020.)

Grad Zagreb: *Kretanje ukupnog stanovništva Zagreba nakon popisa 2011. do 2018., 2019*: https://www.zagreb.hr/userdocsimages/demografija/Kretanje%20ukupnog%20stanovni%C5%A1tva%20Zagreba%20od%20popisa%202011.%20do%202018.pdf (25.4.2020.)

Radio Student: *Novi prosvjedi na Laništu*, 2016: http://www.radiostudent.hr/novi-prosvjedi-na-lanistu/ (7.5.2020.)

USGS (United States Geological Survey), *Landsat – Earth Observation Satellites*, 2020: https://pubs.usgs.gov/fs/2015/3081/fs20153081_ver1.2.pdf (17.4.2020.).

ESRI World Imagery, 2018: Sources: Esri, DigitalGlobe, GeoEye, i-cubed, USDA FSA, USGS, AEX, Getmapping, Aerogrid, IGN, IGP, swisstopo, and the GIS User Community (pristupljeno putem ArcMap-a 23.4.2020.)

CORINE Land Cover Hrvatska (CLC Hrvatska), HAOP (Hrvatska agencija za okoliš i prirodu), 2015: http://www.haop.hr/hr/corine-land-cover-hrvatska-clc-hrvatska/corine-land-cover-hrvatska-clc-hrvatska (5.5.2020.)

ImageCollection Reductions, https://developers.google.com/earth-engine/reducers_image_collection (3.5.2020.)

Trends.Earth, 2020: *Trends.Earth Documentation*, Conservation International, http://trends.earth/docs/en/pdfs/Trends.Earth.pdf (4.5.2020.)

UN Population division, 2011: *World population prospects: The 2010 revision*, https://www.un.org/en/development/desa/population/publications/pdf/trends/WPP2010/WPP2010_Volume-I_Comprehensive-Tables.pdf (25.4.2020.)

Kshetri, T., 2018: NDVI, NDBI & NDWI Calculation Using Landsat 7, 8, https://www.linkedin.com/pulse/ndvi-ndbi-ndwi-calculation-using-landsat-7-8-tek-bahadur-kshetri/ (4.5.2020.)

Zuvela-Aloise, M., 2013: Future of Climatic Urban Heat Stress Impacts – Adaption and mitigation of the climate change impact on urban heat stress based on model runs derived with an urban climate model, https://www.klimafonds.gv.at/wp-content/uploads/sites/6/03032015FOCUSZuvela-AloiseEBACRP2B060373.pdf (11.5.2020.)

World bank, Urban population (% of total population), 2019: https://data.worldbank.org/indicator/SP.URB.TOTL.in.zs (25.4.2020.)

Popis akronima i kratica

API	Application Programming Interface
ETM+	Enhanced Thematic Mapper Plus
GEE	Google Earth Engine
LSE	Land Surface Emmisivity
LST	Land Surface Temperature
LUHI	Local Urban Heat Island
NDVI	Normalized Difference Vegetation Index
OLI	Operational Land Imager
SLC	Scan Line Corrector
TIRS	Thermal Infrared Sensor
UGS	Urban Green Space
UHI	Urban Heat Island
USGS	United States Geological Survey
UTC	Coordinated Universal Time
WRS	World Reference System

Popis slika

Sl. 1. Satelitske snimke istraživanih područja u Zagrebu 2019. godine: (a) *Stambene zgrade Selska*; (b) *Gornji grad*; (c) *ruralna okolica*; (d) *Kanal Sava-Odra*; (e) *Arena centar*; (f) *Supernova i Bauhaus Buzin*. Napomena: na slikama (a), (d), (e) i (f) crvene linije označuju novoizgrađeno područje u odnosu na 2000.; slike (b) i (c) prikazuju referentna područja 5
Sl. 2. Metodologija korištena u radu 9
Sl. 3. Primjer prekrivenosti scene 190/28 oblacima: (a) Landsat 8 RGB kompozit 19.6.2019.; (b) Landsat 8 RGB kompozit 25.10.2019.; (c) Landsat 8 RGB kompozit 29.1.2020. 13
Sl. 4. Modifikacija NDVI vrijednosti zbog utjecaja oblaka, 6.8.2019.; (a) prije uklanjanja oblaka; (b) nakon uklanjanja oblaka 14
Sl. 5. Google Earth Engine sučelje 15
Sl. 6. Ilustracija primjene *ee.Reducer* na *ImageCollection* 16
Sl. 7. Izgrađene površine šireg područja grada Zagreba od 2000. do 2015. godine 21
Sl. 8. Toplinske karte s vrijednostima LST-a na području grada Zagreba za: (a) ljetno razdoblje 2000.; (b) ljetno razdoblje 2019.; (c) zimsko razdoblje 2000./2001.; (d) zimsko razdoblje 2019./2020. *(Napomena: crni pixeli predstavljaju no_data vrijednosti* 24
Sl. 9. Opća morfološka obilježja i toplinska obilježja područja *Gornjeg grada*: (a) prikaz 2005. godine; (b) prikaz 2019. godine; (c) LST za ljetno razdoblje 2000. godine; (d) LST za ljetno razdoblje 2019. godine; (e) LST za zimsko razdoblje 2000./2001. godine; (f) LST za zimsko razdoblje 2019./2020. godine. 28
Sl. 10. Opća morfološka obilježja i toplinska obilježja područja *ruralne okolice*: (a) prikaz 2002. godine; (b) prikaz 2019. godine; (c) LST za ljetno razdoblje 2000. godine; (d) LST za ljetno razdoblje 2019. godine; (e) LST za zimsko razdoblje 2000./2001. godine; (f) LST za zimsko razdoblje 2019./2020. godine. 30
Sl. 11. Opća morfološka obilježja područja *Arena centra*: (a) prikaz 2005. godine; (b) prikaz 2019. godine 32
Sl. 12. Toplinska obilježja područja *Arena centra* za ljetno razdoblje: (a) LST 2000. godine; (b) LST 2019. godine; (c) promjena LST-a 33
Sl. 13. Toplinska obilježja područja *Arena centra* za zimsko razdoblje: (a) LST 2000./2001. godine; (b) LST 2019./2020. godine; (c) promjena LST-a 35
Sl. 14. Horizontalni profili LST-a za ljetno razdoblje 2000. (plave linije) i 2019. (crvene linije); (a) između točaka 1 i 2; (b) između točaka 3 i 4 (sl. 11) 37

Sl. 15. Broj piksela po temperaturnim razredima (veličina razreda je 1 °C) za ljetno i zimsko razdoblje cijelog područja *Arena centra*.....38
Sl. 16. Opća morfološka obilježja područja *Stambene zgrade Selska*: (a) prikaz 2005. godine; (b) prikaz 2019. godine.....40
Sl. 17. Toplinska obilježja područja *Stambene zgrade Selska* za ljetno razdoblje: (a) LST 2000. godine; (b) LST 2019. godine; (c) promjena LST-a 42
Sl. 18. Toplinska obilježja područja *Stambene zgrade Selska* za zimsko razdoblje: (a) LST 2000./2001. godine; (b) LST 2019./2020. godine; (c) promjena LST-a 43
Sl. 19. Horizontalni profili LST-a za ljetno razdoblje 2000. (plave linije) i 2019. godine (crvene linije): (a) između točaka 1 i 2; (b) između točaka 3 i 4 (sl. 16).....44
Sl. 20. Broj piksela po temperaturnim razredima (veličina razreda je 1 °C) za ljetno i zimsko razdoblje cijelog područja *Stambene zgrade Selska*.....45
Sl. 21. Opća morfološka obilježja područja *Kanal Sava-Odra*: (a) prikaz 2001. godine; (b) prikaz 2019. godine 47
Sl. 22. Toplinska obilježja područja *Kanal Sava-Odra* za ljetno razdoblje: (a) LST 2000. godine; (b) LST 2019. godine; (c) promjena LST-a 48
Sl. 23. Toplinska obilježja područja *Kanal Sava-Odra* za zimsko razdoblje: (a) LST 2000./2001. godine; (b) LST 2019./2020. godine; (c) promjena LST-a.....49
Sl. 24. Srednje vrijednosti LST-a prema izdvojenim područjima.....50
Sl. 25. Opća morfološka obilježja područja *Supernova i Bauhaus Buzin*: (a) prikaz 2002. godine; (b) prikaz 2019. godine 51
Sl. 26. Toplinska obilježja područja *Supernova i Bauhaus Buzin* za ljetno razdoblje: (a) LST 2000. godine; (b) LST 2019. godine; (c) promjena LST-a.....52
Sl. 27. Toplinska obilježja područja *Supernova i Bauhaus Buzin* za zimsko razdoblje: (a) LST 2000./2001. godine; (b) LST 2019./2020. godine; (c) promjena LST-a 53
Sl. 28. Broj piksela po temperaturnim razredima za ljetno i zimsko razdoblje cijelog područja *Supernove i Bauhaus Buzin* 54
Sl. 29. Prostorna raspodjela NDVI-a 2019. godine za: (a) *Gornji grad*; (b) *ruralna okolica*; (c) *Arena centar*; (d) *Stambene zgrade Selska*; (e) *Kanal Sava-Odra*; (f) *Supernova i Bauhaus Buzin* 60
Sl. 30. Regresijska analiza LST-NDVI 2019. godine: (a) *Gornji grad*; (b) *ruralna okolica*; (c) *Arena centar*; (d) *Stambene zgrade Selska*; (e) *Kanal Sava-Odra*; (f) *Supernova i Bauhaus Buzin* 62

Popis tablica

Tab. 1. Vremena snimanja Landsat 7 i Landsat 8 scena korištenih u radu za Zagreb za zimsko i ljetno razdoblje 12
Tab. 2. Vrijednosti NDVI-a i odgovarajuća obilježja podloge 18
Tab. 3. Broj satelitskih snimaka Zagreba u ovisnosti u stupnju prekrivenosti oblacima 22
Tab. 4. Odstupanja srednjih mjesečnih temperatura zraka (°C) u zimskim i ljetnim razdobljima od prosječnih vrijednosti (1961.-1990.) za meteorološku postaju *Zagreb-Grič* 25
Tab. 5. Osnovni statistički pokazatelji LST-a (°C) šireg područja grada Zagreba 26
Tab. 6. Statistički pokazatelji LST-a (°C) referentnih područja za zimsko i ljetno razdoblje 31
Tab. 7. Statistički pokazatelji LST-a (°C) područja *Arena centra* za ljetno razdoblje 2000. i 2019. godine 39
Tab. 8. Statistički pokazatelji LST-a (°C) područja *Arena centra* za zimsko razdoblje 2000./2001. i 2019./2020. godine 39
Tab. 9. Statistički pokazatelji LST-a (°C) područja *Stambene zgrade Selska* za ljetno razdoblje 2000. i 2019. godine 46
Tab. 10. Statistički pokazatelji LST-a (°C) područja *Stambene zgrade Selska* za zimsko razdoblje 2000./2001. i 2019./2020. godine 46
Tab. 11. Statistički pokazatelji LST-a (°C) područja *Supernova i Bauhaus Buzin* za ljetno razdoblje 2000. i 2019. godine 55
Tab. 12. Statistički pokazatelji LST-a (°C) područja *Supernova i Bauhaus Buzin* za zimsko razdoblje 2000./2001. i 2019./2020. godine 55
Tab. 13. Vrijednosti NDVI-a i LST-a za ljetno razdoblje 2000. i 2019. godine te njihova promjena 57
Tab. 14. Pearsonov koeficijent korelacije srednjih vrijednosti LST-a i NDVI-a 2000. i 2019. godine za sva analizirana područja 59