

MODELOVANIE VPLYVU VYBRANÝCH FYZICKOGEOGRAFICKÝCH CHARAKTERISTÍK NA POVRCHOVÚ TEPLITU V BRATISLAVE

Hana Bobáľová¹, Andrej Bruška², Vladimír Faltan^{1,3}

¹ *Univerzita Komenského v Bratislave, Prírodovedecká fakulta, Katedra fyzickej geografie a geoinformatiky, e-mail: hana.bobalova@uniba.sk, vladimir.faltan@uniba.sk*

² *Račice 157, 972 22 Nitrícia, e-mail: andrej.bruska@gmail.com*

³ *Univerzita Komenského v Bratislave, Vedecký park, e-mail: vladimir.faltan@uniba.sk*

Abstract: The spatial distribution of land surface temperature (LST) is an important source of information about urban heat islands, which have recently become an increasingly serious problem in connection with global warming and the increase in the number of urban populations. LST is influenced by various physical-geographical factors, including land cover, and the analysis of their interrelationships allows a better understanding of surface heating in cities, especially in summer. In the article, we analyze the relationship between the LST and altitude, amount of green vegetation and built-up area in the city of Bratislava, with a relatively significant range of altitudes, both lowland and highland relief, occurrence of urbanized surfaces, waters and vegetation of protected areas. Landsat satellite images, digital elevation model, land cover layer and the imperviousness density layer were used as input data to the statistical models. The amount of green vegetation is represented by the Normalized Difference Vegetation Index (NDVI) vegetation index, and the vegetation fraction and woody vegetation fraction derived from the land cover layer. The built-up surface is presented in the form of the built-up spectral index and the degree of imperviousness. The Landsat 8 satellite images were used to calculate LST and spectral indices. The relationship between the LST and selected geographical variables was investigated using the statistical indicators of simple linear regression, multiple linear regression, and geographically weighted regression. The results confirmed the key influence of vegetation on the land surface temperature. While the amount of vegetation represented by the NDVI played the most important role in the summer months, the proportion of woody vegetation proved to be a more stable factor, on which the LST strongly to moderately depended throughout the year. LST layer predicted by the multiple regression model provides a more detailed description of the temperature distribution in the city than the LST data derived from satellite images.

Keywords: land cover, land surface temperature, vegetation, altitude, multiple linear regression, Bratislava

1 ÚVOD

Prejavy klimatickej zmeny narastajú aj v strednej Európe a zasahujú všetky regióny vrátane ich lesných porastov (Seidl et al., 2014). Zväčšuje sa počet extrémnych meteorologických udalostí, búrok, víchric, povodňových situácií, lejakov spôsobujúcich eróziu pôdy a tiež vln horúčav. V súčasnosti sa zmena klímy prejavuje častejším výskytom letných a tropických dní a veľký význam majú predikcie týchto meteorologických javov (Esmailnejad, 2022). Vlny horúčav majú významné dosahy i v urbánnom prostredí (Lijelin et al., 2018). Tieto udalosti majú vplyv nielen na obyvateľstvo, ale aj na rastlinstvo a živočíšstvo. Vegetácia na druhej strane môže efektívne pôsobiť proti ich prejavom. Lesné spoločenstvá predstavujú areály krajinnej pokrývky s významnou ekostabilizačnou funkciou. V rámci urbanizovaného prostredia majú podobný význam parky, záhrady a iná mestská zeleň. Tá dokáže zmenšovať výkyvy teploty vzduchu počas dňa.

Teplota povrchu (Land Surface Temperature, LST) predstavuje kľúčový parameter fyzikálnych vlastností Zeme (Yu et al., 2014). Môže poskytovať dôležité informácie o podnebí a vlastnostiach povrchu, ktoré zohrávajú mimoriadne významnú úlohu v mnohých environmentálnych procesoch (Mallick et al., 2008). Zmena LST má neblahé účinky na ľadovce, permafrost a vegetáciu, čo vedie k narušeniu zemských ekosystémov. LST je takisto významným parametrom z hľadiska výmeny povrchovej hmoty, rovnováhy povrchovej energie a fyzikálno-chemických procesov. Teplota povrchu je riadená povrchovou energetickou rovnováhou, atmosférickým stavom, tepelnými vlastnosťami povrchu a podpovrchovým prostredím (Becker a Li, 1990).

Nadmorská výška reprezentuje hlavný globálny faktor, ktorý výrazne ovplyvňuje teplotu povrchu (Deng et al., 2018). Krajinná pokrývka, reprezentujúca materiálny prejav prírodných a socioekonomických procesov na zemskom povrchu (Feranec a Ořáhel, 1999), ako biofyzikálny stav je záchytným pre väčšinu materiálových a energetických pohybov medzi geosférou a biosférou. Zmeny v oblasti krajinnej pokrývky a využitia pôdy zahŕňajú zmeny v biotickej rozmanitosti, kvalite pôdy či sedimentácie materiálov. Z hľadiska využitia pôdy, najvyššie hodnoty teploty povrchu dosahujú nepriepustné povrchy. Na miestach s vysokým podielom nepriepustných povrchov sa najčastejšie formujú mestské ostrovy tepla (Feranec et al., 2019). Medzi povrchy vyznačujúce sa akumuláciou tepla zaradujeme aj holé pôdy a poľnohospodárske pôdy s vysokou intenzitou ľudskej činnosti. Najnižšie teploty sú späté s vodnými plochami, trávnatými plochami a lesmi (Deng et al., 2018). Vegetácia ako základná súčasť ekosystému ovplyvňuje fyzické prostredie prostredníctvom selektívnej absorpcie a odrazu dopadajúceho žiarenia. Prítomnosť vegetácie v mestských oblastiach silno ovplyvňuje akumuláciu tepelnej energie na povrchu (Yue et al., 2007). Veľký význam pri znižovaní dopadov klimatickej zmeny má lesná vegetácia. Dôležitým faktorom ovplyvňujúcim teplotu povrchu na lokálnej úrovni je sklon svahu a orientácia svahu voči svetovým stranám. Deng et al. (2018) udávajú, že juhovýchodný slnečný svah môže vykazovať až o 1,92 °C vyššiu hodnotu teploty povrchu ako tienený severozápadný svah.

Získavanie dát o teplote povrchu Zeme je možné pomocou pozemných i diaľkových metód. Pozemné merania sa môžu uskutočňovať stacionárne na meteorologických staniciach, avšak LST nie je štandardne sledovanou veličinou. Štandardne sa zaznamenáva teplota vzduchu, s ktorou LST koreluje, avšak ich hodnoty sú rozdielne. Takisto hustota rozmiestnenia meteorologických staníc je príliš nízka na rozoznanie priestorových teplotných vzorov, preto sa okrem stacionárnych meraní niekedy používajú mobilné pozemné merania s vyššou hustotou (Dobrovolný a Krahula, 2015). Výhodou materiálov diaľkového prieskumu Zeme je poskytovanie súvislých plošných údajov o teplote povrchu. Princíp diaľkového merania teploty spočíva v snímaní množstva emitovaného žiarenia v tepelnom infračervenom pásme s vlnovou dĺžkou 8 – 12 μm . Termálne snímky v pravidelných intervaloch poskytujú napr. družice Landsat, MODIS alebo ASTER, priestorové rozlíšenie takýchto dát je však relatívne nízke (100 m alebo menej). Alternatívou je snímanie termálnymi kamerami namontovanými na leteckých alebo UAV nosičoch, ktoré je však finančne náročnejšie, a preto limitované na menšie územia a jeden vybraný časový úsek.

V rámci projektu ESA „Urban Heat Islands and Urban Thermography“ sa hodnotili satelitné produkty s rôznym priestorovým a časovým rozlíšením na vzorke 10 európskych miest (Keramitsoglou et al., 2012). Výsledky ukázali, že distribúcia tepla závisí od kombinovaného vplyvu nadmorskej výšky a charakteristík povrchu. Satelitné snímky s priestorovým rozlíšením 1 km (MODIS, AVHRR) sú dostatočné na teplotné mapovanie miest v regionálnej mierke a pozorovanie rozdielov medzi dennými a nočnými teplotnými vzormi, avšak na mapovanie v lokálnej mierke sú najvhodnejšie snímky Landsat s priestorovým rozlíšením 100 m.

Skúmaniu vzťahu medzi LST a geografickými premennými sa venovalo viacero štúdií. Najčastejšie sa skúmal vzťah medzi LST a vegetačnými indexami, predovšetkým NDVI (Normalized Difference Vegetation Index), a to buď prostredníctvom štatistických analýz, alebo pomocou tzv. TVX (Thermal-Vegetation Index) prístupu (Weng, 2009). Keďže vzťah medzi NDVI a LST nie je lineárny a je silno ovplyvnený ročným obdobím, boli navrhnuté tiež iné ukazovatele množstva vegetácie. V štúdiách Wenga et al. (2004) a Li et al. (2011) sa preukázala silnejšia negatívna korelácia medzi podielom vegetácie Fv (Vegetation Fraction) a LST než medzi NDVI a LST. Yuan a Bauer (2007) zaznamenali silnú lineárnu závislosť medzi LST a podielom nepriepustného povrchu ISA (Impervious Surface Area). Li a Liu (2008) s použitím termálnych produktov MODIS preukázali, že spektrálny index zastavaného povrchu NDBI (Normalized Difference Built-Up Index) má silnejší a stabilnejší vzťah s LST počas roka ako NDVI. V detailnejšej štúdií z Brna Dobrovolný a Krahula (2015) odvodili hustotu budov a ciest z digitálnej vektorovej databázy ZABAGED a porovnávali ju s povrchovou teplotou nameranou mobilným zariadením počas bezoblačného dňa. Ukázalo sa, že hustota budov a vegetácia sú najdôležitejšími faktormi pôsobiacimi na teplotu vzduchu.

Analýza vzťahu jednotlivých geografických faktorov a LST neumožňuje posúdiť spoločné pôsobenie faktorov na formovanie teplotných vzorov. Preto sa v nedávnom období viacerí autori pokúšali vytvoriť viacnásobný regresný model s LST ako závislou premennou. Yuvaraj (2020) predpovedal LST zo snímok Landsat 8 na zá-

klade NDVI, NDBI a sklonu územia. Peng et al. (2020) skúmali vzťah LST a topografických parametrov, pričom zistili významný lineárny vzťah medzi LST a tieňovaným reliéfom. Wicki a Parlow (2017) vyvinuli regresný model s viacerými nezávislými premennými vrátane NDVI, tried krajinej pokrývky a využitia zeme, albeda a oslnenia. Kým v letných mesiacoch mala na LST najväčší vplyv vegetácia, v chladnejších mesiacoch vzrástol vplyv albeda a topografie. Zeng et al. (2021) tak tiež kvantifikovali vzťah medzi LST a triedami krajinej pokrývky, pričom najviac teplotu znižovala voda a vegetácia, kým zastavané plochy s vysokým albedom ju naopak zvyšovali.

Vzťahy medzi LST a geografickými faktormi sú však často priestorovo nestacionárne (Su et al., 2012) a na ich modelovanie je vhodnejšia metóda geograficky váženej regresie (GWR). GWR pracuje na predpoklade, že väzby medzi premennými nemusia byť rovnaké v celej sledovanej oblasti (Spurná 2008). Kalota (2015) použila GWR na modelovanie vzťahu medzi LST, vegetačným indexom VARI (Visible Atmospherically Resistant Index), indexom zastavaného územia BUI (Built-Up Index) a nadmorskou výškou. Jia et al. (2020) simulovali LST na základe NDVI, NDBI a vodného indexu NDWI (Normalized Difference Water Index) pomocou GWR modelu, pričom zaznamenali vyššiu presnosť modelu v oblastiach nepriepustných povrchov a vodných plôch než v oblastiach s vegetáciou. Zhao et al. (2018) zase preukázali, že GWR model lepšie charakterizuje priestorovú nestacionaritu vzťahu medzi LST a vysvetľujúcimi premennými, avšak len vo väčšom priestorovom rozlíšení (do 480 m). V menších rozlíšeníach sú jednoduché regresné modely rovnako vhodné ako GWR.

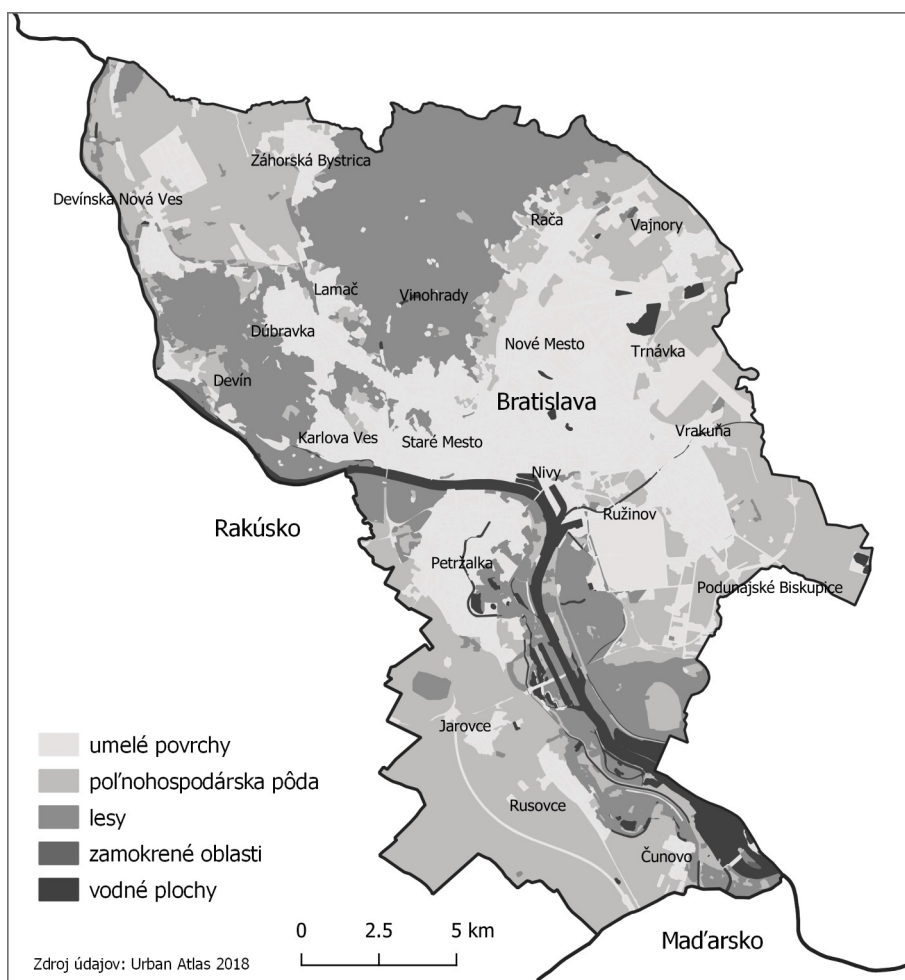
Bratislava ako hlavné a najväčšie mesto Slovenskej republiky vzhľadom ku svojim geografickým podmienkam, ako napr. značnému rozpätiu nadmorských výšok, zastúpeniu nížinného i vrchovinového reliéfu, výskytu urbanizovaných povrchov, vôd, nelesnej vegetácie i lesov chránených území, predstavuje vhodné modelové územie na sledovanie vplyvu geografických faktorov na teplotu povrchu. V článku na základe regresných modelov analyzujeme vzájomný vzťah medzi teplotou povrchu a nadmorskou výškou, množstvom zelenej vegetácie a zastavaného povrchu vo vybraných katastrálnych územiach mesta Bratislava. Interpretácia teploty povrchu sa uskutočnila s využitím tepelného pásma družicových snímok Landsat 8, pre odvodenie nadmorskej výšky sme využili voľne dostupný výškový model SRTM (Shuttle Radar Topography Mission). Množstvo zelenej vegetácie predstavoval vegetačný index NDVI a vrstva krajinej pokrývky s podielom zelenej vegetácie z roku 2016. Zastavané povrchy reprezentoval index zastavaného povrchu BUI a vrstva nepriepustného povrchu Imperviousness Density z roku 2012.

2 MATERIÁL A METÓDY

2.1 Záujmové územie

Hlavné mesto Slovenskej republiky Bratislava je najväčším a najľudnatejším mestom Slovenska. Administratívne územie Bratislavy zahŕňa 17 mestských častí

a 5 okresov (Bratislava I až V) s populáciou 475 500 v roku 2021 (ŠÚ SR, 2022) a celkovou rozlohou 367,6 km² (Buček a Korec, 2013). Z fyzickogeografického hľadiska sa Bratislava rozprestiera na styku Podunajskej nížiny, Malých Karpát a Záhorskej nížiny, čo odzrkadľuje pomerne značné výškové rozpätie (od 126 m n. m. v Petržalke až po 514 m n. m. na Devínskej Kobyle). Územím katastra Bratislavy preteká európsky veľtok Dunaj s prítokom Morava (obr. 1).



Obrázok 1 Lokalizácia záujmového územia

Bratislava s priemernou ročnou teplotou 9,7 °C sa radí medzi najteplejšie lokality Slovenska. Najvyššie priemerné denné maximá teploty sú v dlhodobom priemere 1991 – 2020 dosahované začiatkom augusta (až 30 °C), pričom denné maximá tep-

loty v roku 2022 viackrát presiahli 35 °C (SHMÚ, 2022). Z hľadiska krajinej pokrývky najväčšiu časť zaberajú umelé povrchy (takmer 35 %) a poľnohospodárska pôda v okolí mesta (34 %) (Urban Atlas, 2018). Pomerne rozsiahlu plochu tvoria lesy (27 %), a to predovšetkým horské lesy Malých Karpát a lužné lesy rastúce pozdĺž Dunaja.

2.2 Vstupné údaje

Základné vstupné údaje tvorili družicové snímky Landsat 8, z ktorých bola vypočítaná LST (obr. 2a) a spektrálne indexy NDVI (obr. 2c) a BUI (obr. 2d). Senzory OLI a TIRS na palube Landsat 8 snímajú v 11 spektrálnych pásmach, z ktorých sme na výpočet indexov využili pásma červené (Red), blízke infračervené (NIR) a krátkovlnné infračervené (SWIR1 a SWIR2) v priestorovom rozlíšení 30 m. LST bola vypočítaná na základe tepelného infračerveného pásma TIR1 v priestorovom rozlíšení 100 m, prevzorkovaného na 30 m. Celkovo sme na analýzu vybrali 10 takmer bezoblačných snímok z rokov 2013 – 2017, reprezentujúcich všetky ročné obdobia (tab. 1).

Tabuľka 1 Vstupné satelitné scény Landsat 8

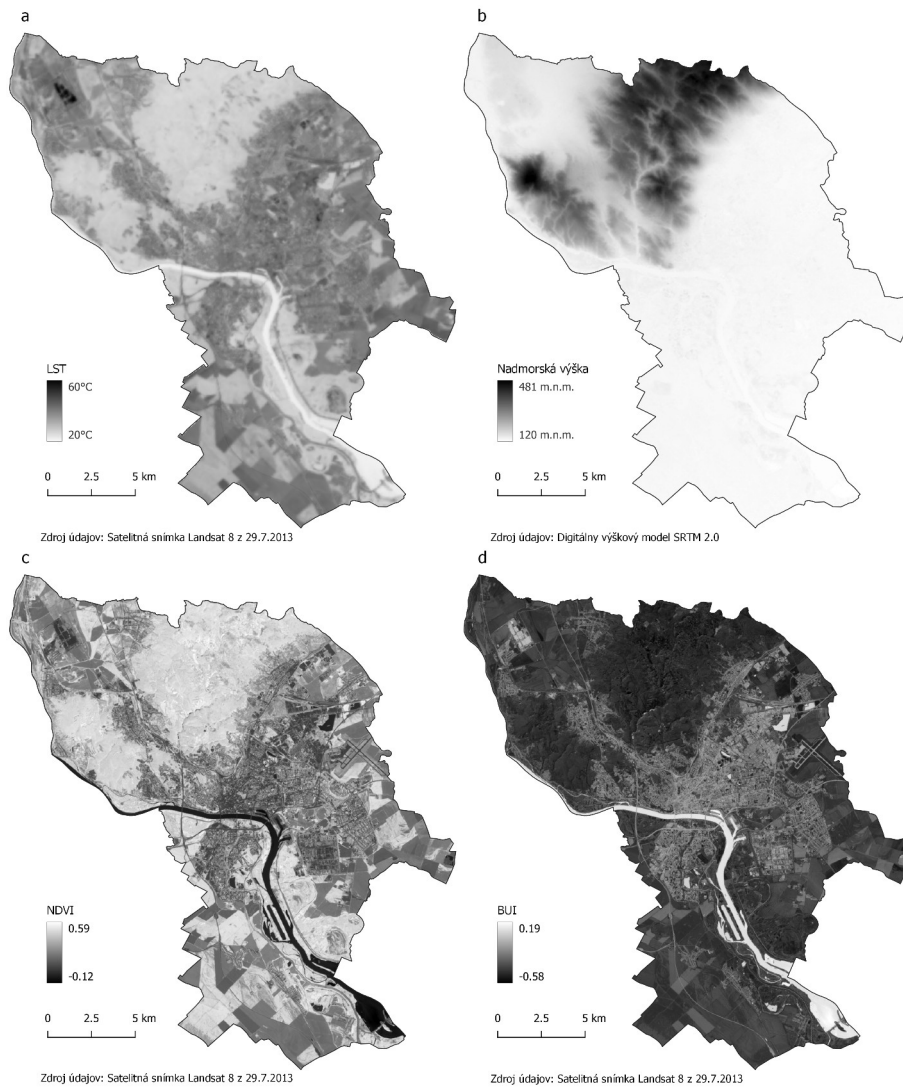
Ročné obdobie	Dátum	Čas (koordinovaný svetový čas)	Výška slnka	Azimut slnka
JAR	24.04.2013	09:41	52,72	151,99
	16.04.2016	09:39	49,91	151,88
	03.04.2017	09:38	45,00	152,94
LETO	29.07.2013	09:41	57,29	145,15
	03.07.2015	09:38	61,15	141,41
	19.07.2015	09:38	59,06	142,48
JESEŇ	05.11.2014	09:39	25,65	165,29
	24.11.2015	09:39	19,49	166,04
ZIMA	28.12.2016	09:39	17,41	162,41
	14.02.2017	09:39	26,69	156,47

Zdroj: Metaúdaje k snímkam Landsat

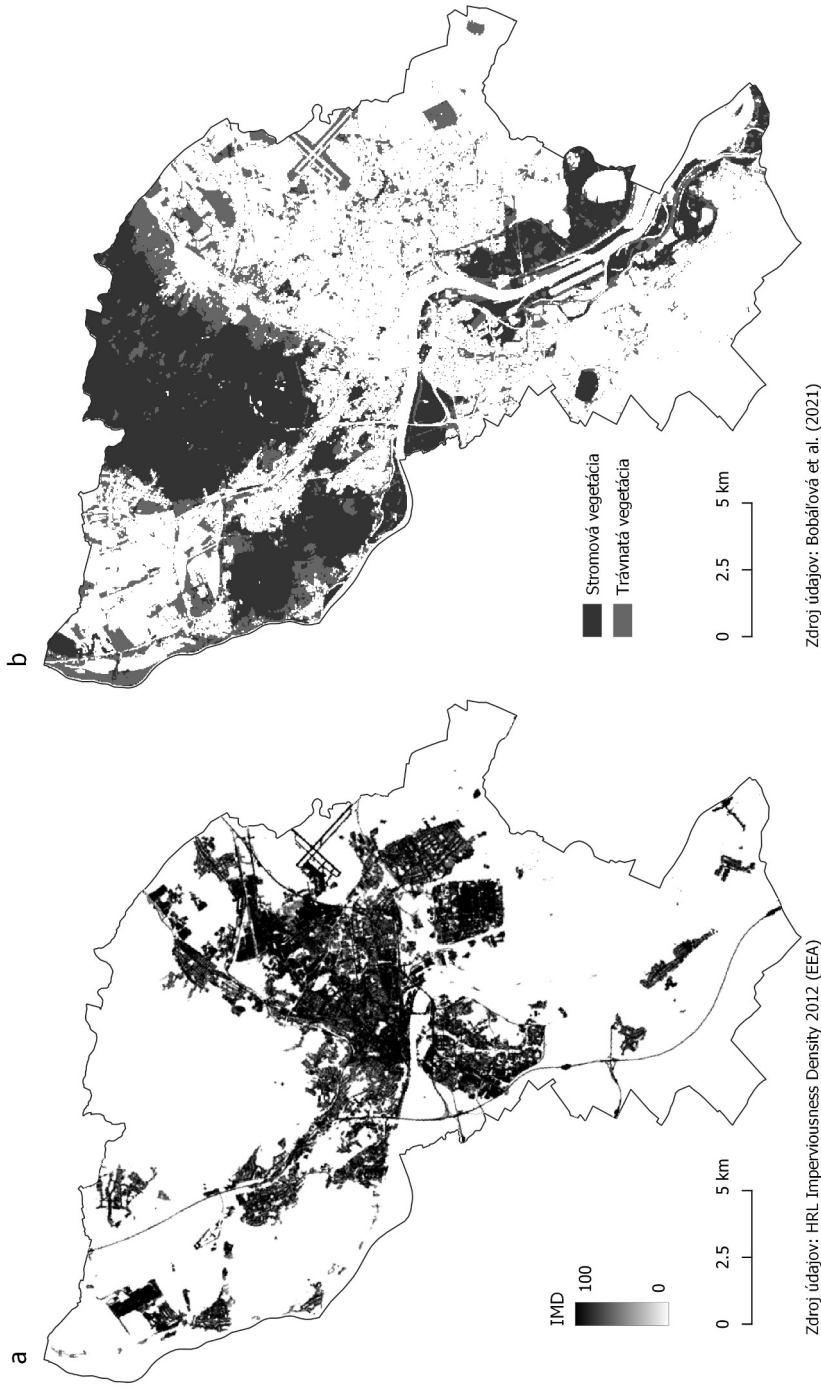
Údaje o nadmorských výškach (obr. 2b) sme získali z globálneho digitálneho výškového modelu SRTM, ktorý vznikol nasnímaním zemského povrchu radarovými systémami na palube raketoplánu Endeavour v roku 2000 (USGS, 2018). Výškový model je voľne dostupný vo forme dlaždíc s rozlíšením 1 oblúkovej sekundy, čo na našom území predstavuje približne 20x30 m. Pre účely analýzy bol prevedený do súradnicového systému UTM a prevzorkovaný na rozlíšenie 30 m.

Údaje o podieli nepriepustných povrchov (obr. 3a) poskytujú vrstvy s vysokým rozlíšením High Resolution Layers Imperviousness Density (IMD) z európskeho programu Copernicus. IMD vrstvy zachytávajú percentuálny podiel (hustotu) zape-

čatených povrchov, ktoré vznikli procesom *soil sealing-u*. Stupeň nepriepustnosti bol odvodený semi-automatizovanou klasifikáciou na základe kalibrovaného NDVI (Copernicus, 2023). Vrstvy sú poskytované v rozlíšeniach 10 m, 20 m a 100 m, v analýze sme použili vrstvu IMD z roku 2012 s rozlíšením 20 m.



Obrázok 2 Povrchová teplota LST (a), nadmorská výška (b), vegetačný index NDVI (c) a index zastavaného povrchu BUI (d) na území Bratislavy



Obrázok 3 Hustota nepriepustnosti IMD (a) a zelená vegetácia (b) na území Bratislavy

Podiel zelenej vegetácie a stromovej vegetácie (obr. 3b) bol odvodený reklasifikáciou vrstvy krajinnej pokrývky Bratislavy, ktorá vznikla hierarchickou objektovo-orientovanou klasifikáciou satelitnej snímky Sentinel-2 s rozlíšením 10 m z 31.8.2016 (Bobáľová et al., 2021). Za zelenú vegetáciu (VF – Vegetation Fraction) boli považované triedy *les*, *stromy/kry*, *zelená tráva* a *suchá/riedka tráva*, za stromovú vegetáciu (WVF – Woody Vegetation Fraction) potom triedy *les* a *stromy/kry*.

2.3 Predspracovanie vstupných údajov

Pracovný postup analýzy pozostával z výpočtu teplotných rastrov a spektrálnych indexov zo satelitných snímok Landsat, prípravy testovacej vzorky a extrakcie hodnôt v miestach vybraných bodov, štatistického modelovania a hodnotenia štatistických modelov (obr. 4).

Metódy výpočtu LST zo satelitných snímok sa v nedávnom období významne rozvinuli, prehľad metód môžeme nájsť napr. v práci Li et al. (2013). Použili sme metódu jedného tepelného pásma (single-channel) s odvodením emisivity na základe klasifikácie krajinnej pokrývky. Metóda využíva inverziu rovnice radiačného prenosu (Radiative Transfer Equation (RTE)), pri ktorej sa tepelné žiarenie namerané satelitným senzorom koriguje o zoslabenie spôsobené prechodom atmosférou a o emisivitu povrchu (Dash, 2001):

$$L_{TOA} = \tau \varepsilon B(T_s) + L_u + \tau(1 - \varepsilon)L_d \quad ,$$

kde: L_{TOA} je spektrálna hustota žiarivého toku na hornej hranici atmosféry (Top Of Atmosphere),

$B(T_s)$ je spektrálna hustota žiarenia čierneho telesa o povrchovej teplote T_s (ground radiance),

L_u je žiarenie atmosféry (upwelling radiance),

L_d je spätné žiarenie atmosféry (downwelling radiance),

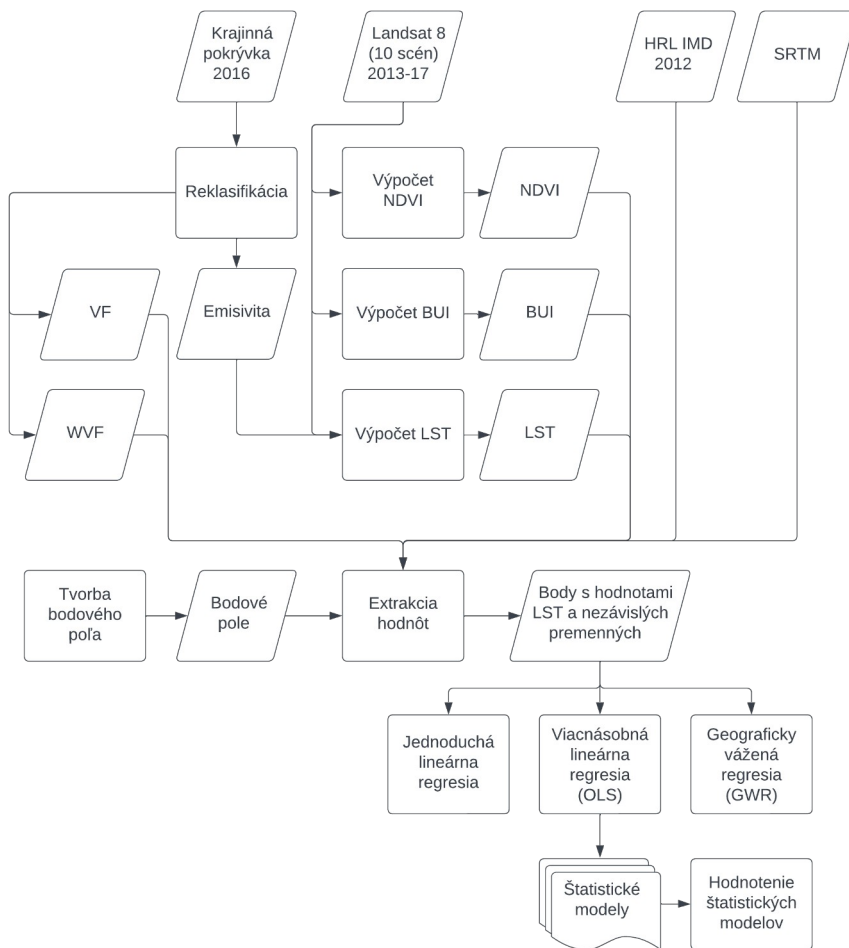
τ je koeficient priepustnosti atmosféry (atmospheric transmissivity),

ε je emisivita povrchu (land surface emissivity).

Metóda vyžaduje údaje z atmosférických profilov, ktoré sa dajú získať napríklad pomocou webového rozhrania <https://atmcorr.gsfc.nasa.gov/>, určeného na atmosférické korekcie tepelných pásiem Landsat (Barsi et al., 2003). Do webovej aplikácie sa zadávajú geografické súradnice miesta, dátum a čas, pre ktorý chceme profil vypočítať. Výstupom sú atmosférické profily a vypočítané hodnoty L_u , L_d a τ . Raster emisivity bol odvodený reklasifikáciou vrstvy krajinnej pokrývky, pri ktorej bola každej triede priradená typická hodnota emisivity na základe meraní z literatúry (Snyder et al., 1998; Mallick et al., 2008).

Záverčným krokom pri výpočte LST je prepočet povrchového žiarenia na teplotu podľa Planckovho zákona, ktorý sa dá s použitím tepelných konštánt Landsat zjednodušiť nasledovne (USGS, 2019):

$$T_s = \frac{K_2}{\ln \left(1 + \frac{K_1}{\varepsilon B(T_s)} \right)} \quad ,$$



Obrázok 4 Vývojový diagram pracovného postupu. Zdroj: spracované autormi

kde: T_s je povrchová teplota (LST) v Kelvinoch,

K_1 , K_2 sú termálne kalibračné konštanty (dostupné v metaúdajoch k satelitnej snímke).

LST bola vypočítaná zo všetkých snímok Landsat a prevedená na stupne Celzia. Nasledovali výpočty spektrálnych indexov NDVI (Rouse et al., 1974) a BUI (Kaimaris a Patias, 2016) z jednotlivých snímok Landsat podľa vzorcov:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}},$$

$$BUI = \frac{\rho_{RED} - \rho_{SWIR1}}{\rho_{RED} + \rho_{SWIR1}} + \frac{\rho_{SWIR2} - \rho_{SWIR1}}{\rho_{SWIR2} + \rho_{SWIR1}},$$

kde: ρ_{RED} , ρ_{NIR} , ρ_{SWIR1} , ρ_{SWIR2} sú odraznosti v červenom, blízkom infračervenom, resp. krátkovlnnom infračervenom pásme spektra.

Všetky vstupné údaje boli prevedené do jednotného súradnicového systému UTM zóna 33N (EPSG 32633) a rozlíšenia 30 m s prevzorkovaním bilineárnou metódou. Následne bola vygenerovaná testovacia vzorka náhodným výberom 5372 bodov na celom záujmovom území, pričom minimálny rozstup medzi bodmi bol 50 m. V procese štatistickej analýzy sa ukázalo, že vodné plochy znižujú mieru lineárnej závislosti LST na skúmaných premenných, predovšetkým NDVI a BUI, čo vyplýva z konštrukcie indexov. Podobný problém sme zaznamenali na ornej pôde v okolí mesta, kde polia s nulovou hodnotou nepriepustnosti dosahovali rôzne hodnoty LST podľa stupňa pokrytia plodinami. Z uvedených dôvodov sme vodné plochy a katastrálne územia s prevládajúcou ornou pôdou z ďalších analýz vylúčili. Výsledná vzorka tak pozostávala z 2579 bodov (Bruška, 2018).

2.4 Štatistická analýza

Vzťahy medzi LST a ďalšími premennými boli testované štatistickými metódami jednoduchej lineárnej regresie, viacnásobnej lineárnej regresie a geograficky váženej regresie. Jednoduchá a viacnásobná lineárna regresia modelujú vzájomné vzťahy medzi premennými pomocou polynómu prvého rádu, pričom počítajú regresnú priamku metódou najmenších štvorcov (Ordinary Least Squares, OLS). Matematické základy regresných metód môžeme nájsť vo viacerých publikáciách (Gregorová a Fillová, 2004; Rimarčík, 2007).

Nevýhodou lineárnej regresie je veľká citlivosť na extrémne hodnoty. Niekedy sú modelované vzťahy nelineárne, v takom prípade sa odporúča aplikovať iný typ regresnej funkcie (Goga a Bobál'ová, 2017). Ak nie je regresný vzťah konzistentný v geografickom priestore, môžeme použiť geograficky váženú regresiu (GWR). GWR modeluje lokálne priestorové vzťahy v tradičnom regresnom rámci, pričom ho rozširuje o pohyblivé parametre (Spurná, 2008):

$$y_i = \beta_0(u_i, v_i) + \sum_p \beta_p(u_i, v_i) X_{ip} + \varepsilon_i,$$

kde: (u_i, v_i) sú parametre označujúce polohu i -teho bodu v priestore,

β_0 je regresná konštanta, závisí od lokalizácie bodu i ,

β_p je regresný koeficient, ktorý závisí od nezávislej premennej X_p a vyjadruje hodnotu spojitej funkcie $\beta_p(u_i, v_i)$ v i -tom bode,

ε_i je reziduálna odchýlka na bode i .

Metóda pracuje na každom bode zvlášť, čím sa získavajú lokálne regresné parametre. Výsledné odhady lokálnych regresných parametrov zobrazené v mape predstavujú prehľadné znázornenie charakteru skúmanej väzby. Výsledky GWR najviac ovplyvňuje šírka pásma b (bandwidth) vážiacej funkcie v okolí bodu. Ak je hodnota b príliš vysoká, bude výsledný model GWR vo veľkej miere zhodný so všeobecným

regresným modelom. Naopak pri nízkej hodnote b sú odhady parametrov viac závislé na vstupných bodoch v blízkosti regresného bodu, čo má za následok nepresnosť výsledného modelu (Spurná, 2008).

Hodnotenie kvality výsledných regresných modelov pozostáva z viacerých krokov (ESRI, 2023):

1. Posúdenie výkonnosti modelu

Najdôležitejšie sú hodnoty koeficientu determinácie R^2 a korigovaného koeficientu determinácie R^2_{adj} . Koeficient determinácie vyjadruje, akú časť celkovej variability závislej premennej vysvetľuje štatistický model. Korigovaný koeficient determinácie je vždy o niečo nižší, pretože odzrkadľuje zložitosť modelu z hľadiska počtu premenných a teda presnejšie určuje mieru výkonnosti modelu.

Ďalším parametrom, ktorým môžeme sledovať výkonnosť regresného modelu je $AICc$ (corrected Akaike Information Criterion). Čím nižšia je hodnota $AICc$, tým lepšie je model prispôbený pozorovaným údajom. $AICc$ je užitočný najmä pri porovnávaní modelov s rôznymi nezávislými premennými vo vzťahu k rovnakej závislej premennej. Ak je rozdiel hodnoty $AICc$ medzi sledovanými modelmi väčší ako 3, model s nižšou hodnotou sa považuje za lepší.

2. Posúdenie stacionárnosti modelu

Stacionárnosť modelu posudzuje Koenker štatistika (Koenkerova študentizovaná Bruesch-Pagan štatistika), ktorá testuje, či nezávislé premenné v modeli majú konzistentný vzťah k závislej premennej v geografickom a dátovom priestore. Regresné modely s významnou nestacionárnosťou modelu sú kandidátmi pre štatistickú analýzu pomocou GWR metódy.

3. Posúdenie významnosti modelu

Celková významnosť modelu sa hodnotí na základe F-štatistiky a Wald štatistiky. Ak sú tieto ukazovatele štatisticky významné, nezávislé premenné boli vhodne vybraté a účinne ovplyvňujú modelovanie hodnôt závislej premennej. Wald štatistika sa používa, ak je Koenker test štatisticky významný (t.z. model je nestacionárny), v opačnom prípade sa berie do úvahy F-štatistika.

4. Posúdenie skreslenia modelu

Jarque-Bera štatistika posudzuje, či sú zvyškové chyby (rezíduá) regresného modelu normálne rozdelené. Ak je tento parameter štatisticky významný, tak vytvorený model môže byť skreslený, čo môže svedčiť o chýbajúcej kľúčovej premennej v modeli. Skreslenie modelu môže spôsobovať aj modelovanie nelineárnych vzťahov, prítomnosť extrémnych hodnôt alebo silná nestacionárnosť dát.

5. Posúdenie každej nezávislej premennej

Takisto je potrebné analyzovať jednotlivé nezávislé premenné v regresnom modeli. Okrem regresného koeficientu a štandardnej odchýlky sa skúma aj pravdepodobnosť, T-štatistika a Inflačný faktor rozptylu (Variance Inflation Factor, VIF). Hodnota pravdepodobnosti vyjadruje štatistickú významnosť nezávislej premennej. T-štatistika meria, ako je nezávislá premenná nápomocná pri tvorbe regresného modelu. Ak je Koenker test štatisticky významný, používajú sa robustné formy štandardnej odchýlky, pravdepodobnosti a T-štatistiky. VIF parameter posudzuje

nadbytočnosť nezávislých premenných v modeli. Platí pravidlo, že premenné, ktoré sú štatisticky nevýznamné, málo nápomocné alebo nadbytočné, by mali byť vylúčené z modelu.

Jednoduchou, viacnásobnou (OLS) a geograficky váženou (GWR) regresiou sme modelovali vzájomné vzťahy medzi LST a nasledovnými premennými:

- nadmorská výška (ELEV),
- vegetačný index (NDVI),
- index zastavaného povrchu (BUI),
- hustota nepriepustnosti povrchu (IMD),
- podiel zelenej vegetácie (VF),
- podiel drevinovej vegetácie (WVF).

Modely boli vypracované pre všetky sledované časové horizonty snímok Landsat, pričom sa menili hodnoty LST, NDVI, BUI, a hodnoty ostatných premenných ostávali konštantné.

3 VÝSLEDKY

3.1 Vplyv jednotlivých fyzickogeografických faktorov na LST

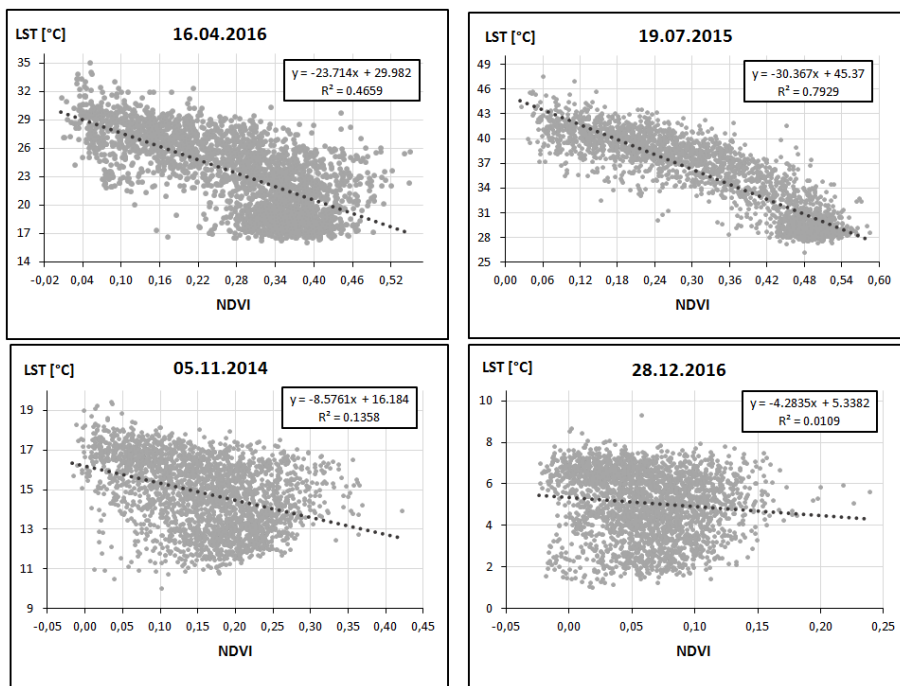
Výsledky jednoduchej lineárnej regresie ukázali, že v letných mesiacoch má na LST ako závislú premennú najväčší vplyv vegetácia, a to jej množstvo reprezentované vegetačným indexom NDVI, ako aj typ reprezentovaný podielom drevinovej vegetácie WVF. NDVI dokáže vysvetliť až takmer 80 % variability LST v letnom období (tab. 2). Naopak v jesenných a zimných mesiacoch medzi LST a NDVI neexistuje prakticky žiadna závislosť (obr. 5). Vzťah LST a NDVI v jarňých mesiacoch závisí od vývoja vegetácie, najmä listovej plochy, takže v neskorších letných mesiacoch sme pozorovali silnejšiu závislosť a body v scatterplote sa viac blížili lineárnej regresnej priamke. Podobne sa počas roka správal ďalší spektrálny index BUI, ktorý taktiež zaznamenal najväčší vplyv na LST v lete a takmer nulový vplyv v jeseni a v zime. Ako najstabilnejší faktor počas roka sa ukázala nadmorská výška, ktorá v priemere vysvetľuje okolo 47 % variability LST. Zvyšné geografické faktory dosiahli najvyššie hodnoty R^2 práve v letných mesiacoch, pričom podiel drevinovej vegetácie WVF mal na LST výrazne silnejší vplyv než podiel zelenej vegetácie VF zahŕňajúcej okrem drevín aj trávne porasty. WVF môžeme považovať za najvýznamnejší faktor ovplyvňujúci povrchovú teplotu počas celého roka.

Pri premenných IMD, VF a WVF je nutné brať do úvahy, že veľké množstvo bodov dosahuje krajné hodnoty 0, resp. 1, a práve tieto body určujú sklon regresnej priamky (obr. 6). Hoci je sklon regresnej priamky pri VF a WVF veľmi podobný, pixle so 100 %-ným podielom drevinovej vegetácie dosahovali v letných dátumoch povrchové teploty do 36 °C, kým pixle pokryté drevinovou a/alebo trávnatou vegetáciou vykazovali povrchové teploty až do 43 °C. Preto sme v ďalších regresných analýzach pracovali už len s premennou WVF.

Tabuľka 2 Výsledky jednoduchovej lineárnej regresie medzi LST a fyzickogeografickými faktormi v jednotlivých ročných obdobiach

Ročné obdobie	Interval hodnôt R ²					
	ELEV	NDVI	BUI	IMD	WVF	VF
Jar	0,41 – 0,52	0,24 – 0,51	0,23 – 0,43	0,44 – 0,67	0,67 – 0,68	0,49 – 0,53
Leto	0,47 – 0,50	0,77 – 0,79	0,52 – 0,63	0,54 – 0,61	0,71 – 0,75	0,50 – 0,53
Jeseň	0,41 – 0,51	0,01 – 0,14	0,02 – 0,08	0,49 – 0,54	0,60 – 0,62	0,41 – 0,42
Zima	0,46 – 0,54	0,01 – 0,07	0,00 – 0,03	0,46 – 0,47	0,56 – 0,63	0,33 – 0,38

Zdroj: spracované autormi

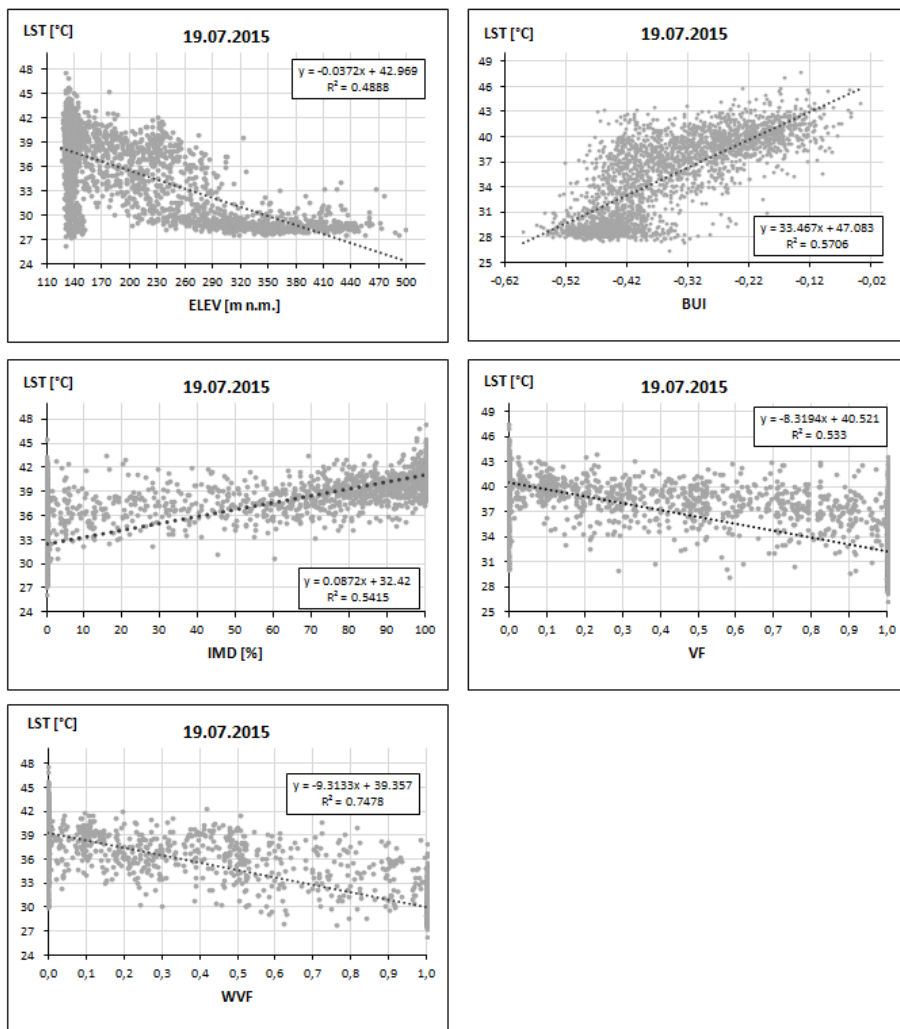


Obrázok 5 Vzťah medzi vegetačným indexom NDVI a povrchovou teplotou LST počas roka. Zdroj: spracované autormi

3.2 Spoločný vplyv vybraných faktorov na LST

Pomocou viacnásobnej OLS regresie sme modelovali spoločný vplyv fyzickogeografických faktorov ELEV, NDVI, BUI, IMD a WVF na LST ako závislú premennú. Výsledky modelovania v jednotlivých dátumoch sumarizuje tab. 3. Najvyššiu hodnotu korigovaného R^2 dosiahol model zo 16.4.2016, avšak takmer rovnako

vysoké hodnoty R^2 nachádzame aj pri všetkých modeloch z letných dní. Vypočítané hodnoty indikujú, že vybrané fyzickogeografické faktory dokážu spolu vysvetliť 86 – 88 % variability LST.



Obrázok 6 Vzťah medzi povrchovou teplotou LST a fyzickogeografickými faktormi nadmorská výška, index zastavaného povrchu BUI, hustota nepriepustnosti povrchu IMD, podiel zelenej vegetácie VF a podiel drevinovej vegetácie WVF dňa 19.7.2015. Zdroj: spracované autormi

V jarných a zimných modeloch sa všetky nezávislé premenné prejavili ako štatisticky významné. V jesennom modeli z 5.11.2014 bol ako štatisticky nevýznam-

ný vyhodnotený NDVI, v modeli z 24.11.2015 zase BUI. Vo všetkých letných modeloch sa BUI ukázal ako nadbytočný, keďže kvôli korelácii s NDVI dosiahol hodnotu VIF nad 7,5. Správny výber vysvetľujúcich premenných potvrdzuje aj hodnota Wald-štatistiky, ktorá bola vo všetkých modeloch štatisticky významná. Dôležitosť jednotlivých premenných a výkonnosť ich vzájomných kombinácií sme skúmali aj prostredníctvom vysvetľujúcej regresie, ktorá hodnotí všetky možné kombinácie premenných v OLS modeli. Najdôležitejšími premennými v letných modeloch sa ukázali NDVI a WVF, čo potvrdzuje kľúčový vplyv vegetácie (predovšetkým drevinovej) na LST.

Tabuľka 3 Výsledky OLS regresie


Ročné obdobie	Dátum	R^2_{adj}	AICc	Nezávislé premenné (v poradí podľa dôležitosti)
JAR	24.04.2013	0,82	10427,67	WVF, NDVI, IMD, ELEV, BUI
	16.04.2016	0,88	8886,07	WVF, IMD, ELEV, NDVI, BUI
	03.04.2017	0,76	9708,91	WVF, NDVI, IMD, ELEV, BUI
LETO	29.07.2013	0,87	10787,74	NDVI, WVF, ELEV, IMD
	03.07.2015	0,86	10985,75	NDVI, WVF, IMD, ELEV
	19.07.2015	0,87	9979,11	NDVI, WVF, ELEV, IMD
JESEŇ	05.11.2014	0,75	6495,89	WVF, IMD, ELEV, BUI, NDVI
	24.11.2015	0,79	6170,26	WVF, IMD, BUI, ELEV, NDVI
ZIMA	28.12.2016	0,81	5278,35	WVF, ELEV, BUI, IMD, NDVI
	14.02.2017	0,79	6683,54	WVF, IMD, BUI, ELEV, NDVI

Zdroj: spracované autormi

Vo všetkých OLS modeloch bola štatisticky významná aj Koenkerova (BP) štatistika, čo svedčí o nestacionarite a/alebo heteroskedasticite modelov. Štatisticky významná Jarque-Bera štatistika zase vyjadruje, že rezíduá jednotlivých modelov nie sú normálne rozdelené, a teda modely môžu byť skreslené. Rezíduá alebo zvyškové chyby modelu predstavujú nevysvetlenú časť variability závislej premennej, v regresnej rovnici figurujú ako náhodná chyba ε . Najviac sa podarilo k neskreslenému modelu priblížiť modelom z 29.7.2013, kde p -hodnota Jarque-Bera štatistiky dosiahla hodnotu 0,045, čo sa blíži k prahovej hodnote pravdepodobnosti 0,05.

Pre interpretáciu výsledkov modelovania je dôležité zobrazit' si graf štandardizovaných rezíduí voči predpovedaným hodnotám LST (obr. 7). Rozdelenie na grafe z 29.7.2013 sa takmer blíži k náhodnému rozdeleniu hodnôt rezíduí. Naopak na väčšine ostatných grafov sa prejavuje heteroskedasticita, teda model vykazuje väčšie zvyškové chyby pri vyšších teplotách. Príčinou heteroskedasticity je najčastejšie povaha samotných dát. Na modelovanom území sa body s nízkymi teplotami nachádzali prevažne v lesných porastoch, ktoré majú nízku variabilitu teplôt, ako aj vysvetľujúcich premenných (s výnimkou nadmorskej výšky v Malých Karpatoch). Na-

opak zastavané oblasti s vysokými teplotami sú veľmi heterogénne a predpovedanie teplôt na základe vysvetľujúcich premenných je oveľa náročnejšie.

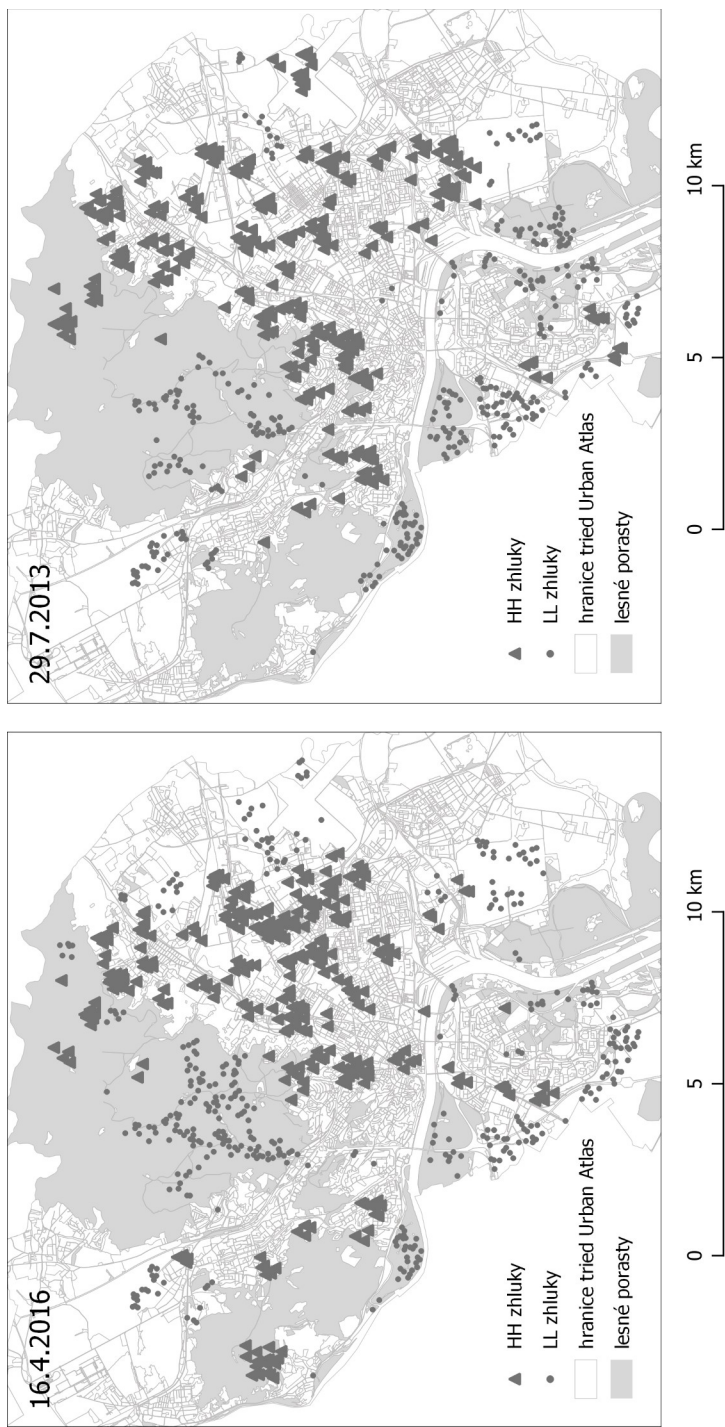


Obrázok 7 Rozdelenie rezíduí v regresnom modeli z 16.4.2016 (vľavo) a z 29.7.2013 (vpravo). Zdroj: spracované autormi

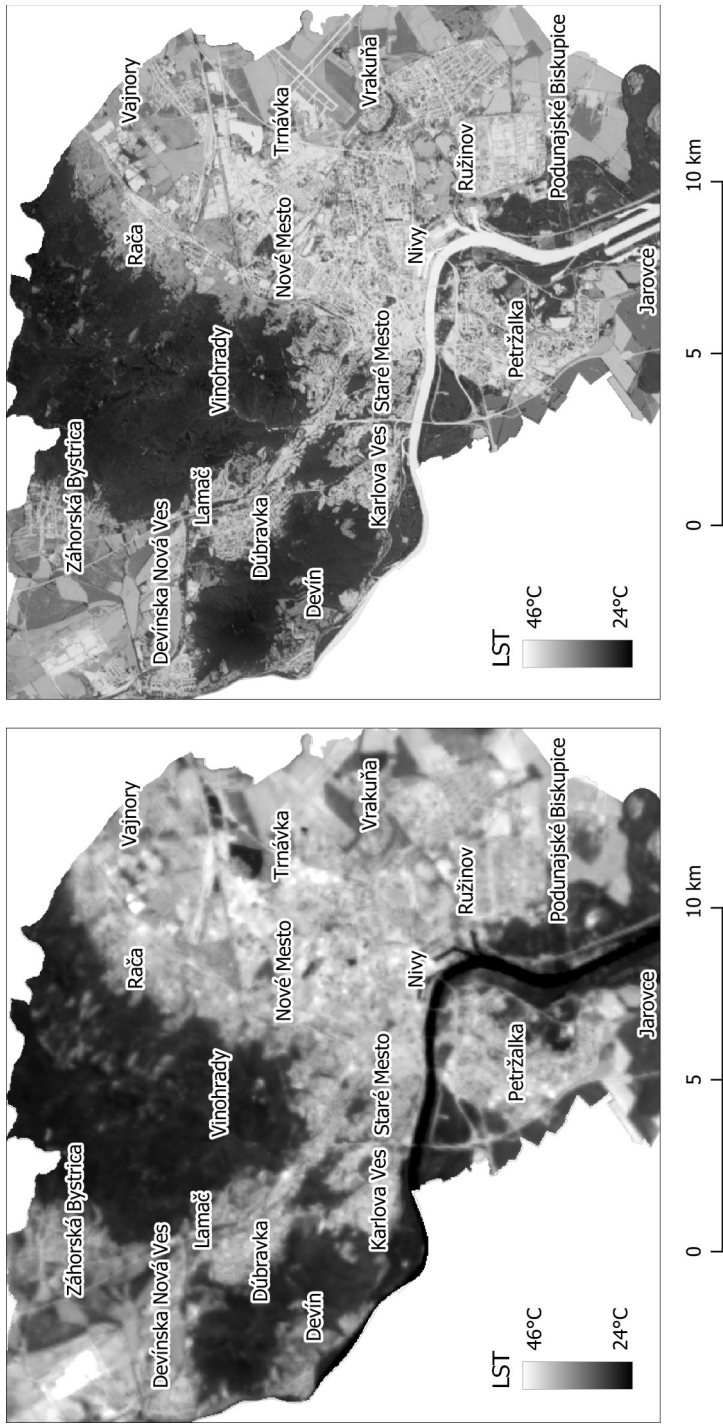
Ďalším zdrojom skreslenia modelov môže byť nelineárna povaha vzájomnej závislosti LST a vysvetľujúcich premenných. Jednoduchá lineárna regresia odhalila, že napr. NDVI a BUI majú takmer lineárny vzťah s LST iba v letných mesiacoch. Vzťah ostatných premenných k LST je zase výrazne ovplyvnený veľkým množstvom bodov s krajnými hodnotami premenných ako je nízka nadmorská výška, plne priepustné povrchy, povrchy úplne bez vegetácie alebo naopak plne pokryté vegetáciou, ktorých teplotný rozptyl je veľmi široký.

Pri hodnotení výsledkov regresných modelov sa tiež odporúča testovať priestorovú autokoreláciu hodnôt rezíduí. Ak sa vo výsledkoch vyskytujú štatisticky významné priestorové zhluky vysokých (HH) alebo naopak nízkych (LL) hodnôt, znamená to, že v regresnom modeli chýba niektorá kľúčová premenná. Tento predpoklad sa potvrdil vo všetkých testovaných modeloch, pričom v jarných a letných modeloch bola väčšina zhlukov vysokých aj nízkych hodnôt lokalizovaná na podobných miestach (obr. 8). Zhluky nízkych hodnôt rezíduí sa kumulovali v južnej časti Malých Karpát a v lužných lesoch okolo Dunaja, kde model predpovedal príliš vysoké hodnoty LST. Naopak zhluky vysokých hodnôt boli lokalizované na východnom podhorí Karpát v oblasti viníc, ako aj vo východnej časti intravilánu mesta v častiach Ružinov, Trnávka, Nové Mesto a Rača.

Ako ukážku predikcie uvádzame LST vypočítanú na základe OLS modelu z 29.7.2013 (obr. 9). Keďže boli z modelovania vylúčené body na vodných plochách, model na týchto miestach na základe neprítomnosti vegetácie predikoval nerealisticky vysoké teploty. Na druhej strane, rozloženie teplôt v zastavaných oblastiach je zmapované s oveľa väčšou detailnosťou.



Obrázok 8 Priestorová lokalizácia štatisticky významných zhlukov vysokých hodnôt (HH) a zhlukov nízkych hodnôt (LL) štandardizovaných rezidui regresných modelov zo 16.4.2016 a 29.7.2013. Zdroj: spracované autormi



Obrázok 9 Povrchová teplota (LST) dňa 29.7.2013 nameraná (vľavo – zdroj Landsat 8) a vypočítaná pomocou regresného modelu (vpravo – spracované autormi)

4 DISKUSIA

Výsledky analýzy jednotlivých geografických faktorov potvrdili kľúčový vplyv vegetácie na LST v letných mesiacoch. Ako najvýznamnejší sa ukázal vegetačný index NDVI, nasledovaný podielom drevinovej vegetácie WVF. Časový vývoj vzťahov medzi NDVI a LST je v súlade so zisteniami iných štúdií (Yuan a Bauer, 2007; Wicky a Parlow, 2017). Lineárny vzťah sa prejavuje predovšetkým v letných mesiacoch, a platí len pre pozitívne hodnoty NDVI.

Podiel zelene býva často vyjadrený ako frakcia vegetácie F_v (Weng et al., 2004; Li et al., 2011), prípadne ako frakcia vegetačnej pokrývky FVC (Zhao et al., 2018). Kým F_v sa podobne ako podiel nepriepustných povrchov určuje metódami lineárneho spektrálneho miešania, FVC sa odvodzuje z hodnôt NDVI. Obidva tieto ukazovatele sú s NDVI silne zviazané, a preto sú rovnako ako NDVI limitované variabilitou a nelineárnosťou vo vzťahu k LST (Li et al., 2011).

V prezentovaných modeloch bola na určenie podielu zelenej vegetácie VF a WVF použitá vrstva krajinnej pokrývky, získaná klasifikáciou snímky Sentinel-2 vo vyššom rozlíšení. Hoci sa VF a WVF dynamicky nemenia počas roka, vo väčšine modelov predstavujú reprezentatívnejšiu charakteristiku zastúpenia zelene s vplyvom na mikroklimu ako NDVI. WVF vykazuje stredne silný až silný vzťah k LST počas celého roka (R^2 0,56 – 0,75), zahrnutie trávnych porastov tento vzťah oslabuje.

Analýzy zastúpenia trávo-bylinnej, krovinnej a stromovej vegetácie a urbanizovaných a technizovaných areálov z vrstiev krajinnej pokrývky vytvorených interpretáciou snímok družíc Sentinel-2 potvrdzujú veľkú praktickú aplikovateľnosť týchto dát pre potreby hodnotenia vplyvu jednotlivých typov povrchov v súlade s review Feranec et al. (2019). Podľa FAO (2012) sa za les považuje areál porastený lesnými drevinami s potenciálnou výškou viac ako 5 m, s minimálnou výmerou 0,5 ha a minimálnou šírkou 20 m. Mestské lesy Bratislavy predstavujú významný prvok v ochrane pred následkami klimatickej zmeny. Pre potreby zachytenia rozdielov v mikroklimé vegetácie urbanizovaného priestoru je efektívne rozdeliť triedy krajinnej pokrývky, reprezentujúce vegetáciu, podľa zastúpenia drevinnej vegetácie, resp. zápoja korún stromov.

K lokalitám mestského priestoru s najväčšími prejavmi klimatických zmien patria centrá miest s množstvom umelých povrchov, tvoriace mestské ostrovy tepla (Manley, 1958). V súlade so Stewart and Oke (2012), udávajúcimi ako hlavné príčiny ich vzniku väčšiu absorpciu slnečného žiarenia múrmi budov, pomalšie uvoľňovanie tepla z pevných umelých povrchov a spaľovanie fosílnych palív, a našimi zisteniami ohľadne menšieho zastúpenia zelených plôch, potvrdzujeme ich vplyv na mikroklimu a mezoklimu centra Bratislavy.

Z hľadiska ročného chodu teploty povrchov najväčší vplyv vegetácie preukázali modely v letných mesiacoch, čo je v súlade so zisteniami Wicki a Parlow (2017) a Zeng et al. (2021). Hodnoty R^2_{adj} letných modelov (0,86 – 0,87) sú porovnateľné s inými štúdiami, v ktorých bol použitých vyšší počet nezávislých premenných, vrátane údajov o krajinnej pokrývke (napr. Bechtel et al., 2012; Wicky a Parlow, 2017). Publikované štúdie však podrobnejšie neuvádzajú iné charakteristiky

modelov, ako napr. rozdelenie rezíduí. Analýza modelov z Bratislavy preukázala, že napriek vysokým hodnotám R^2 môžu byť hodnoty rezíduí zhlukované, čo svedčí o nestabilite a nestacionarite modelov.

Na riešenie problému odlišného správania sa modelov v geografickom priestore môžeme aplikovať metódu GWR. Táto metóda je však výpočtovo náročná, preto je nutné zmenšiť počet vstupných bodov (v našom prípade na 500). Aby bola zaručená lokálna povaha regresného modelovania, počet susedov, resp. šírka pásma b , by mali byť čo najmenšie. Kým pri jarých modeloch boli najlepšie výsledky dosiahnuté s použitím premenných NDVI a BUI, pri letných modeloch sa najviac osvedčili premenné NDVI, IMD a WVF (tab. 4). Hoci GWR modely v jarých dátumoch nadobudli o niečo nižšie hodnoty R^2_{adj} ako OLS modely, hodnoty $AICc$ kritéria sa použitím GWR metódy výrazne znížili, čo svedčí o lepšom prispôbení modelu pozorovaným dátam. Rovnaké zlepšenie bolo dosiahnuté aj pri letných dátumoch, pričom hodnoty R^2_{adj} boli ešte o niečo vyššie ako pri OLS modeloch. Pri mapovom zobrazení lokálnych hodnôt R^2 sa ukázalo, že najvyššiu presnosť GWR modely vykazujú v západnej časti územia a vo východnej polovici Malých Karpát, naopak vo východnej časti územia je presnosť o niečo nižšia. Analýza zvyškových chýb modelov ukázala, že majú náhodný charakter a nevytvárajú takmer žiadne štatisticky významné zhluky.

Tabuľka 4 Výsledky GWR regresie

Ročné obdobie	Dátum	R^2_{adj}	$AICc$	Počet susedov	Nezávislé premenné
JAR	24.04.2013	0,77	2203,44	53	NDVI, BUI
	16.04.2016	0,81	2014,53	69	NDVI, BUI
	03.04.2017	0,80	1931,42	33	NDVI, BUI
LETO	29.07.2013	0,88	2099,54	107	NDVI, IMD, WVF
	03.07.2015	0,89	2065,17	134	NDVI, IMD, WVF
	19.07.2015	0,89	1922,68	128	NDVI, IMD, WVF

Zdroj: spracované autormi

Aplikácia štatistických modelov GWR podobne ako v štúdiách Kalota (2016) alebo Zhao et al. (2018) priniesla presnejšie zachytenie vzájomných vzťahov závislej a nezávislých premenných ako len použitie jednoduchej lineárnej regresie. Nevýhodou GWR metód však je, že neposkytujú všeobecne platnú regresnú rovnicu na predikciu hodnôt závislej premennej.

Výsledky porovnania LST predikovanou OLS modelom s LST odvodenou z teplotného pásma Landsat ukázali, že model bude potrebné spresniť pridaním faktora reprezentujúceho vodné plochy (napr. vodný spektrálny index NDWI). Po takomto spresnení by mohol slúžiť ako detailná ukážka distribúcie teplôt v meste počas vln horúčav. Nízke priestorové rozlíšenie teplotných dát je pritom spolu s heterogenitou

priestorovej štruktúry jednou z hlavných limitácií lokálnych štúdií teploty v mestskom prostredí (Mushore et al., 2017; Hofierka et al., 2020). Ďalšie spresnenie by mohlo priniesť zahrnutie faktorov tieňovaného reliéfu (Peng et al., 2020) a lesného spektrálneho indexu Forest Index (Ye et al., 2014).

5 ZÁVER

Mestská zeleň plní v období klimatickej zmeny významné funkcie pri ochrane pred jej následkami. Na základe štúdia dát z rôznych zdrojov (družicové snímky Landsat, digitálny výškový model SRTM, vrstva krajinej pokrývky a nepriepustnosti povrchu) sme skúmali vplyv rôznych faktorov reprezentujúcich charakteristiky vegetácie, zastavaných povrchov a nadmorskej výšky na teplotu povrchu v katastrálnych územiach Bratislavy. Vzájomné vzťahy medzi teplotou a jednotlivými faktormi sme analyzovali metódou jednoduchkej lineárnej regresie, pričom sa ukázalo, že vplyv jednotlivých geografických faktorov na povrchovú teplotu sa počas roka mení. Najvyššia korelácia bola dosiahnutá pri hodnotách vegetačného indexu NDVI v letných mesiacoch (R^2 0,77 – 0,79), kým v ostatných obdobiach mal na teplotu najvýznamnejší vplyv podiel drevinovej vegetácie (R^2 0,33 – 0,53). Najvyrovnanejšie vzťahy medzi premennými preukázala jednoduchá lineárna regresia vo vzťahu k nadmorskej výške. Spektrálne indexy v jesenných a zimných mesiacoch nevykazovali žiadne relevantné závislosti.

Spoločný vplyv uvedených faktorov na povrchovú teplotu sme modelovali pomocou viacnásobnej lineárnej regresie (OLS). Vysvetľujúca lineárna regresia vo väčšine prípadov ako kľúčový faktor ovplyvňujúci povrchovú teplotu vyhodnotila zastúpenie drevinovej vegetácie v konkrétnej časti mesta, čo je v súlade s výsledkami jednoduchkej regresie. Najvyššie hodnoty korigovaného R^2 dosiahli letné modely a jarný model zo 16.4.2016 (0,86 – 0,88), čím sa potvrdil predpoklad, že spoločné pôsobenie faktorov dokáže vysvetliť väčšiu časť variability povrchovej teploty ako jednotlivé faktory zvlášť.

V príspevku sme riešili aj aplikáciu štatistických metód hodnotenia výkonnosti, významnosti, stacionarity a skreslenia lineárnych regresných modelov, ktorá nebýva súčasťou publikácií venovaných modelovaniu povrchovej teploty, hoci môže odhaliť závažné problémy. Aj keď v každom modeli sa na území Bratislavy dosiahli pomerne vysoké hodnoty koeficientu determinácie, presné zhodnotenie vzťahov by vyžadovalo ďalší podrobnejší výskum. Štatisticky významné hodnoty Koenkerovej (BP) štatistiky vo všetkých modeloch poukazujú na nekonzistentný vzťah skúmaných faktorov k povrchovej teplote v dátovom a/alebo geografickom priestore. Príčinou môže byť náročnejšie modelovanie vyšších teplôt v heterogénnom zastavanom území, ako aj nelineárnosť modelovaných vzťahov. Na nekonzistentnosť v geografickom priestore poukazujú aj štatisticky významné zhľuky vysokých a nízkych hodnôt rezíduí modelov, ktoré sa pri jarných aj letných modeloch koncentrovali na rovnakých miestach.

Problém konzistentnosti dát pomohla vyriešiť metóda lokálnej geograficky váženej regresie (GWR), pri ktorej boli vypočítané nižšie hodnoty parametra *AICc* a vzťahy boli modelované presnejšie. Ako reprezentatívne vegetačné faktory boli potvrdené podiel drevinovej vegetácie a vegetačný index NDVI. Nevýhodou tejto metódy je, že neposkytuje všeobecne platnú regresnú rovnicu na predikciu hodnôt povrchovej teploty. Napriek nedostatkom OLS metódy, predikcia povrchovej teploty touto metódou umožňuje detailnejšiu charakteristiku priestorového rozloženia teplôt v heterogénnom zastavanom území, než štandardne používaná vrstva povrchovej teploty odvodená z družicových snímok Landsat.

Pod'akovanie

Práca vznikla vďaka podpore OP Integrovaná infraštruktúra (OPII) v rámci projektu FOMON - ITMS kód 313011V465, spolufinancovaného zo zdrojov Európskeho fondu regionálneho rozvoja a Vedeckej grantovej agentúry Ministerstva školstva, vedy, výskumu a športu a Slovenskej akadémie vied v rámci projektu VEGA 1/0217/23.

Literatúra

- BARSI, J. A., BARKER, J. L., SCHOTT, J. R. 2003. An Atmospheric Correction Parameter Calculator for a Single Thermal Band Earth-Sensing Instrument. *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, 5, 3014-3016.
- BECKER, F., LI, Z. 1990. Towards a local split window method over land surfaces. *International Journal of Remote Sensing*, 11, 3, 369-393.
- BECHTEL, B., ZAKŠEK, K., HOSHYARIPOUR, G. 2012. Downscaling Land Surface Temperature in an Urban Area: A Case Study for Hamburg, Germany. *Remote Sensing*, 4, 10, 3184-3200.
- BOBÁĽOVÁ, H., BENOVÁ, A., KOŽUCH, M. 2021. Hierarchical Object-Based Mapping of Urban Land Cover Using Sentinel-2 Data: A Case Study of Six Cities in Central Europe. *PFJ-Journal of Photogrammetry Remote Sensing and Geoinformation Science*, 89, 1, 15-31.
- BRUŠKA, A. 2018. *Analýza vplyvu vybraných geografických charakteristík na teplotu povrchu v Bratislave*. Diplomová práca. Bratislava, Univerzita Komenského.
- BUČEK, J., KOREC, P. 2013. *Moderná humánna geografia mesta Bratislava: priestorové štruktúry, siete a procesy*. Bratislava, Univerzita Komenského.
- COPERNICUS, 2023. *Imperviousness*. [online] [cit. 2023-02-02]. Dostupné na: <<https://land.copernicus.eu/pan-european/high-resolution-layers/imperviousness>>
- DASH, P., GÖTTSCHE, F. M., OLESEN, F. S., FISCHER, H. 2001. Retrieval of land surface temperature and emissivity from satellite data: Physics, theoretical limitations and current methods. *Journal of the Indian Society of Remote Sensing*, 29, 23-30.
- DENG, Y., WANG, S., BAI, X., TIAN, Y., WU, L., XIAO, J., CHEN, F., QIAN, Q. 2018. Relationship among land surface temperature and LUCC, NDVI in typical karst area. *Scientific Reports*, 8, 641.
- DOBROVOLNÝ, P., KRAHULA, L. 2015. The spatial variability of air temperature and nocturnal urban heat island intensity in the city of Brno, Czech Republic. *Moravian Geographical Reports*, 23, 3, 8-16.
- ESMAILNEJAD, M. 2022. Evaluation and forecasting of hot days in the Zahedan city. *Acta Geographica Universitatis Comenianae*, 66, 1, 47-62.

- ESRI, 2023. *How OLS regression works (ArcGIS Pro Help)*. [online] [cit. 2023-02-02]. Dostupné na: <<https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-statistics/how-ols-regression-works.htm>>
- FAO, 2020. *Terms and definitions. Forest resources assessment working paper 180*. Rome. [online] [cit. 2023-05-14]. Dostupné na: <<https://www.fao.org/3/I8661EN/i8661en.pdf>>
- FERANEC, J., OŤAHEL, J. 1999. Mapovanie krajinskej pokrývky metódou CORINE v mierke 1: 50 000: návrh legendy pre krajiny programu Phare. *Geografický časopis*, 51, 1, 19-44.
- FERANEC, J., KOPECKÁ, M., SZATMÁRI, D., HOLEC, J., ŠTASTNÝ, P., PAZÚR, R., BOBÁLOVÁ, H. 2019. A review of studies involving the effect of land cover and land use on the urban heat island phenomenon, assessed by means of the MUKLIMO model. *Geografie*, 124, 1, 83-101.
- GOGA, T., BOBÁLOVÁ, H. 2017. Matematické princípy regresnej analýzy v geografickej perspektíve. *Acta Geographica Universitatis Comenianae*, 61, 2, 241-256.
- GREGOROVÁ, G., FILLOVÁ. 2004. *Štatistické metódy v geografii*. Bratislava, Geografika.
- HOFIERKA, J., GALLAY, M., ONAČILLOVÁ, K., HOFIERKA, J. Jr. 2020. Physically-based land surface temperature modeling in urban areas using a 3-D city model and multispectral satellite data. *Urban Climate*, 31, 100566.
- JIA, H., YANG, D., DENG, W., WEI, Q., JIANG, W. 2021. Predicting land surface temperature with geographically weighed regression and deep learning. *WIREs Data Mining and Knowledge Discovery*, 11, (1), e1396. <https://doi.org/10.1002/widm.1396>
- KAIMARIS, D., PATIAS, P. 2016. Identification and Area Measurement of the Built-up Area with the Built-up Index (BUI). *International Journal of Advanced Remote Sensing and GIS*, 5, 6, 1844-1858.
- KALOTA, D. 2017. Exploring relation of land surface temperature with selected variables using geographically weighted regression and ordinary least square methods in Manipur State, India. *Geocarto International*, 32, 10, 1105-1119.
- KERAMITSOGLU, I., DAGLIS, I. A., AMIRIDIS, V., CHRYSOULAKIS, N., CERIOLA, G., MANUNTA, P., MAIHEU, B., DE RIDDER, K., LAUWAET, D., PAGANINI, M. 2012. Evaluation of satellite-derived products for the characterization of the urban thermal environment. *Journal of Applied Remote Sensing*, 6, 1, 061704.
- LI, H., LIU, Q. 2008. Comparison of NDBI and NDVI as indicators of surface urban heat island effect in MODIS imagery. In Li, D., Gong, J., Wu, H. (eds.). *Proceedings of SPIE 7285, International Conference on Earth Observation Data Processing and Analysis (ICE-ODPA)*, 728503.
- LI, J., SONG, C., CAO, L., ZHU, F., MENG, X., WU, J. 2011. Impacts of landscape structure on surface urban heat islands: A case study of Shanghai, China. *Remote Sensing of Environment*, 115, 12, 3249-3263.
- LI, Z. L., TANG, B. H., WU, H., REN, H., YAN, G., WAN, Z., TRIGO, I. F., SOBRINO, J. A. 2013. Satellite-derived land surface temperature: current status and perspectives. *Remote Sensing of Environment*, 131, 14-37.
- LIJIELIN, E., XIAOPINGLIU, X., WEILINIAO, M. 2018. Urbanization effects on heat waves in Fujian Province, Southeast China. *Atmospheric Research*, 210, 15, 123-132.
- MALLICK, J., KANT, Y., BHARATH, B. D. 2008. Estimation of land surface temperature over Delhi using Landsat-7 ETM+. *Journal of Indian Geophysical Union*, 12, 3, 131-140.
- MANLEY, G. 1958. On the frequency of snowfall in metropolitan England. *Quarterly Journal of the Royal Meteorological Society*, 84, 70-72.
- MUSHORE, T. D., ODINDI, J., DUBE, T., MATONGERA, T. N., MUTANGA, O. 2017. Remote sensing applications in monitoring urban growth impacts on in-and-out door thermal conditions: a review. *Remote Sensing Applications: Society and Environment*, 8, 83-93.
- PENG, X., WU, W., ZHENG, Y., SUN, J., HU, T., WANG, P. 2020. Correlation analysis of land surface temperature and topographic elements in Hangzhou, China. *Scientific Reports*, 10, 10451.

- RIMARČÍK, M. 2007. *Štatistika pre prax*. Vlastné nakladateľstvo.
- ROUSE, J. W., HAAS, R. H., SCHEEL, J. A., DEERING, D. W. 1974. Monitoring Vegetation Systems in the Great Plains with ERTS. In Freden, S. C., Mercanti, E. P., Becker, M. A. (eds.). *Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium*, 1, 48-62.
- SEIDL, R., SCHELHAAS, M. J. J., RAMMER, W., VERKERK, P. J. 2014. Increasing forest disturbances in Europe and their impact on carbon storage. *Nature Climate Change*, 4, 806-810.
- SHMÚ, 2022. *Operatívne údaje z vybraných staníc*. [online] [cit. 2023-02-02]. Dostupné na: <https://www.shmu.sk/sk/?page=1&id=klimat_operativneudaje1>
- SNYDER, W. C., WAN, Z., ZHANG, Y., FENG, Y. Z. 1998. Classification-based emissivity for land surface temperature measurement from space. *International Journal of Remote Sensing*, 19, 14, 2753-2774.
- SPURNÁ, P. 2008. Geograficky vážená regrese: metóda analýzy priestorové nestacionarity geografických javů. *Geografie - sborník české geografické společnosti*, 113, 2, 21-35.
- STEWART, D. I., OKE, T. R. 2012. Local climate zones for urban temperature studies. *Bulletin of the American Meteorological Society*, 93, 1879-1900.
- SU, Y., FOODY, G., CHENG, K. 2012. Spatial non-stationary in the relationships between land cover and surface temperature in an urban heat island and its impacts on thermally sensitive populations. *Landscape and Urban Planning*, 107, 2, 172-180.
- ŠŮ SR, 2022. *Sčítanie obyvateľov, domov a bytov 2021*. Bratislava, Štatistický úrad Slovenskej republiky.
- URBAN ATLAS, 2018. *SK001L1 – Bratislava*. European Environmental Agency. Dostupné na: <<https://land.copernicus.eu/local/urban-atlas/urban-atlas-2018>>
- USGS 2018. *USGS EROS Archive – Digital Elevation – Shuttle Radar Topography Mission (SRTM)*. [online] [cit. 2023-02-02]. Dostupné na: <<https://www.usgs.gov/centers/eros/science/usgs-eros-archive-digital-elevation-shuttle-radar-topography-mission-srtm-1>>
- USGS 2019. *Landsat 8 (L8) Data Users Handbook. Version 5.0, EROS, Sioux Falls, South Dakota, USA*. [online] [cit. 2023-05-14]. Dostupné na: <<https://www.usgs.gov/landsat-missions/landsat-8-data-users-handbook>>
- WENG, Q., LU, D., SCHUBRING, J. 2004. Estimation of land surface temperature–vegetation abundance relationship for urban heat island studies. *Remote Sensing of Environment*, 89, 4, 467-483.
- WENG, Q. 2009. Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64, 4, 335-344.
- WICKI, A., PARLOW, E. 2017. Multiple regression analysis for unmixing of surface temperature data in an urban environment. *Remote Sensing*, 9, 684.
- YE, W., LI, X., CHEN, X., ZHANG, G. 2014. A spectral index for highlighting forest cover from remotely sensed imagery. In Jackson, T. J., Chen, J. M., Gong, P., Liang, S. (eds.). *Land Surface Remote Sensing II. Proceedings of SPIE - The International Society for Optical Engineering*, 9260.
- YU, X., GUO, X., WU, Z. 2014. Land surface temperature retrieval from Landsat 8 TIRS - Comparison between radiative transfer equation-based method, split window algorithm and single channel method. *Remote Sensing*, 6, 9829-9852.
- YUAN, F., BAUER, M. E. 2007. Comparison of impervious surface area and normalized difference vegetation index as indicators of surface urban heat island effects in Landsat imagery. *Remote Sensing of Environment*, 106, 3, 375-386.
- 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.

- YUVARAJ, R. M. 2020. Extents of Predictors for Land Surface Temperature Using Multiple Regression Model. *The Scientific World Journal*, 3958589.
- ZENG, F. F., FENG, J., ZHANG, Y., TSOU, J. Y., XUE, T., LI, Y., LI, R. Y. M. 2021. Comparative Study of Factors Contributing to Land Surface Temperature in High-Density Built Environments in Megacities Using Satellite Imagery. *Sustainability*, 13, 13706.
- ZHAO, H., REN, Z., TAN, J. 2018. The Spatial Patterns of Land Surface Temperature and Its Impact Factors: Spatial Non-Stationarity and Scale Effects Based on a Geographically-Weighted Regression Model. *Sustainability*, 10, 7, 2242.

Modeling the influence of selected physical-geographical characteristics on the land surface temperature in Bratislava

Summary

Manifestations of climate change are also increasing in Central Europe and affect all regions. The number of extreme meteorological events, windstorms, flood situations, causing soil erosion and also heat waves is increasing. These events have an impact not only on the human population, but also on fauna and flora. Vegetation, on the other hand, can effectively counteract their manifestations. Forest communities represent areas of land cover with a significant ecostabilization function. Within an urbanized environment, parks, gardens and other urban greenery are of similar importance, which can mitigate the extreme warming of the land surface temperature (LST).

Bratislava as the capital of the Slovak Republic due to its geographical conditions, such as the relatively considerable range of altitudes, the lowland and highland relief, the occurrence of urbanized surfaces, waters, non-forest vegetation and protected forests areas, represents a suitable model area for monitoring the influence of geographical factors on the surface temperature. In the article, based on regression models, we analyze the relationship between the LST and the altitude, the amount of green vegetation and built-up surfaces in the cadastral territories of the city of Bratislava. The interpretation of the LST was carried out using the thermal band of Landsat 8 satellite images. We used the free available digital elevation model SRTM to derive the altitude. The amount of green vegetation was represented by the vegetation index NDVI and the land cover layer with the proportion of green vegetation VF and woody vegetation WVF from 2016. Built-up surfaces were represented by the Built-Up Index (BUI) and the imperviousness density layer (IMD). The analysis of the relationship between surface temperature and selected geographic parameters was investigated using statistical indicators of simple linear regression, multiple linear regression, and geographically weighted regression. ArcGIS tools from the Spatial Statistics toolbox were used to calculate regression models of multiple and geographically weighted regression analysis.

The influence of individual geographical factors on the surface temperature varies. The results of a simple linear regression showed that the amount of vegetation, especially trees, has the greatest influence on the LST as a dependent variable in the summer months, while the altitude has the most stable influence on the LST throughout the year. Altitude as an independent variable explains on average about 47% of the LST variability. The vegetation index NDVI proved to be the most significant, followed by the proportion of woody vegetation WVF. Conversely, the NDVI shows the strongest relationship with the LST in summer months when it can explain almost 80% of the LST variability. On the contrary, there is practically no dependence between the LST and NDVI in the autumn and winter months. The

land cover layer, obtained by the classification of the Sentinel-2 image in a higher resolution, was used to determine the proportions of green vegetation VF and WVF. Although VF and WVF do not change dynamically during the year, in most models they express a more representative characteristic of vegetation with an impact on the microclimate than NDVI. WVF shows a moderate to strong relationship with LST throughout the year (R^2 0.56-0.75), the inclusion of grassland in VF weakens this relationship. Multiple regression analysis confirmed the previously mentioned dependencies. In most cases, regression models evaluated the representation of vegetation in a specific part of the city as a key factor affecting the surface temperature. Although relatively large values of the coefficient of determination were achieved in each model, an accurate assessment of the relationships would require further, more detailed research.

Analyzes of the representation of grass-herb, shrub and tree vegetation and urbanized and technical areas from the land cover layers created by the interpretation of Sentinel-2 satellite images confirm the great practical applicability of these data for the needs of assessing the impact of individual types of surfaces.