

STŘEDOŠKOLSKÁ ODBORNÁ ČINNOST

Obor: 8. Ochrana a tvorba životního prostředí

Satelitní analýza vlivu vegetace a městských povrchů na přehřívání urbanizovaných oblastí

Nikolas Pippal

Olomouc 2025

STŘEDOŠKOLSKÁ ODBORNÁ ČINNOST

SATELITNÍ ANALÝZA VLIVU
VEGETACE A MĚSTSKÝCH POVRCHŮ
NA PŘEHŘÍVÁNÍ URBANIZOVANÝCH
OBLASTÍ

SATELLITE ANALYSIS OF THE INFLUENCE OF
VEGETATION AND URBAN SURFACES ON
OVERHEATING IN URBANIZED AREAS

AUTOR	Nikolas Pippal
ŠKOLA	Gymnázium, Olomouc - Hejčín
KRAJ	Olomoucký
ŠKOLITEL	prof. RNDr. Vilém Pechanec, Ph.D.
OBOR	8. Ochrana a tvorba životního prostředí

Olomouc 2025

Prohlášení

Prohlašuji, že svou práci na téma *Satelitní analýza vlivu vegetace a městských povrchů na přehřívání urbanizovaných oblastí* jsem vypracoval/a samostatně pod vedením prof. RNDr. Viléma Pechance, Ph.D. a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Dále prohlašuji, že tištěná i elektronická verze práce SOČ jsou shodné a nemám závažný důvod proti zpřístupňování této práce v souladu se zákonem č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a změně některých zákonů (autorský zákon) v platném znění.

V Olomouci dne: _____

Nikolas Pippal

Poděkování

Děkuji všem a hlavně Tomovi

Anotace

Tato práce se zaměřuje na vývoj nového postupu pro výpočet povrchové teploty v městských oblastech pomocí satelitních snímků. Klíčovým přínosem je vytvoření ukazatele Vegetation Influence Factor (VIF), který kvantifikuje vliv vegetace na teplotu místa. Dále je navržen algoritmus, který na základě historických dat a VIF navrhuje opatření pro snížení teplotních extrémů a zpomalení oteplování měst, čímž přispívá ke zlepšení mikroklimatu a adaptaci na změny klimatu.

Klíčová slova

městský tepelný ostrov; povrchová teplota; Vegetation Influence Factor (VIF); teplotní extrémy; městské plánování; vegetace

Annotation

This thesis focuses on developing a new method for calculating surface temperature in urban areas using satellite imagery. A key contribution is the creation of the Vegetation Influence Factor (VIF), which quantifies the impact of vegetation on local temperature. Additionally, an algorithm is proposed that, based on historical data and VIF, suggests measures to reduce temperature extremes and slow down urban warming, thereby contributing to improved urban microclimates and adaptation to climate change.

Keywords

Urban heat island; surface temperature; Vegetation Influence Factor (VIF); temperature extremes; urban planning; vegetation

Obsah

Úvod	8
1 Tepelné ostrovy	9
1.1 Řešení tepelných ostrovů	11
2 Dálkový průzkum země	12
2.1 Družice Landsat	13
3 Zpracování snímku	16
3.1 Klasifikace bodů povrchu	18
3.1.1 NDVI	19
3.1.2 Strojové učení	19
3.2 Povrchová teplota	23
3.2.1 Určování emisivit	24
3.2.2 Výpočet povrchové teploty	26
4 Časová analýza a kvantifikace vlivu zeleně	30
4.1 Vývoj teploty povrchů v čase	30
4.2 Vliv vegetace na teplotu	33
4.2.1 Závislost teploty na vzdálenosti od vegetace	34
4.2.2 Vegetation Influence Factor (VIF)	35
5 Optimalizace městské struktury	41
5.1 Genetický algoritmus	42
5.2 Program pro optimalizaci městské struktury	43

Závěr	48
Literatura	53
Seznam obrázků	54
Seznam tabulek	55

Úvod


V posledních desetiletích se městské oblasti staly centry ekonomického a sociálního rozvoje, avšak tento růst s sebou přináší i negativní ekologické dopady. Jedním z nejvýznamnějších problémů, kterému čelí urbanizované oblasti, je jev známý jako tepelný ostrov, kdy jsou městské oblasti až o 20°C teplejší než jejich okolí. Tento efekt, způsobený především rozsáhlým pokrytím asfaltovými a betonovými plochami, nedostatkem vegetace a změnami v krajině, má závažné důsledky pro zdraví obyvatel, energetickou náročnost budov a celkovou kvalitu života ve městech. Tepelný stres, zhoršení kvality ovzduší a nárůst spotřeby energie jsou jen některé z důsledků, které tento problém způsobuje.

Cílem této práce je vyvinout nový přístup pro výpočet povrchové teploty, který poskytne vyšší přesnost při aplikaci na urbanizované oblasti. Dalším klíčovým krokem je monitorování časového vývoje teploty různých povrchů a identifikace souvisejících trendů. Zvláštní pozornost je věnována kvantifikaci vlivu vegetace na povrchovou teplotu specifických míst, což umožní detailnější porozumění vlivu vegetačního pokrytí na teplotní charakteristiky v městském prostředí. V závěru této práce je navržen program, který je schopen spolehlivě doporučit opatření, jako je například strategické vysazování zeleně, k efektivnímu snižování teplotních extrémů a zmírnění efektu oteplování měst. Tento nástroj tak přispívá k optimalizaci městského mikroklimatu a podpoře udržitelného rozvoje městských oblastí.

Kapitola 1

Tepelné ostrovy

Městské tepelné ostrovy (Urban Heat Islands, UHI) představují komplexní fenomén, při kterém jsou urbanizované oblasti znatelně teplejší než jejich okolní venkovské prostředí jak znázorňuje obrázek 1.1. Tento efekt je způsoben sy-



Obrázek 1.1: Ilustrace znázorňující městské tepelné ostrovy[1]

nergickým působením několika faktorů, mezi nimiž dominují vysoká hustota zástavby, nedostatek vegetace a fyzikální vlastnosti použitých stavebních materiálů. Umělé povrchy, jako je beton, asfalt či střešní krytiny, vykazují vysokou tepelnou kapacitu a nízkou reflektivitu, což znamená, že během dne intenzivně absorbují sluneční záření a akumulují tepelnou energii, kterou následně uvolňují do okolí i v nočních hodinách. Tento mechanismus vede k výraznému zpomalení procesu ochlazování městských oblastí ve srovnání s přirozenými ekosystémy, což se projevuje nejen zvýšením průměrné teploty,

ale také změnou mikroklimatických podmínek.[2]

Tepelné ostrovy jsou obzvláště výrazné v hustě urbanizovaných centrech velkoměst, kde dochází k intenzivnímu pohlcování krátkovlnného slunečního záření a současně k minimálnímu ochlazování skrze evapotranspiraci, která je ve vegetaci chudých oblastech značně redukována. Rozdíly teplot mezi městským a příměstským či venkovským prostředím mohou v extrémních případech dosahovat až několika stupňů Celsia, přičemž tento rozdíl je nejvýraznější během nočních hodin. To vede nejen k zvýšené energetické náročnosti na chlazení budov, ale také ke zvýšení celkového tepelně-akumulačního potenciálu městského prostředí, což dále přispívá k zesilování tohoto efektu. Dlouhodobé vystavení vyšším teplotám má navíc významné zdravotní důsledky, neboť vede ke zvýšené incidenci onemocnění spojených s tepelným stresem, dehydratací a nadměrnou zátěží kardiovaskulárního systému, přičemž nejvíce ohrožené skupiny obyvatel představují senioři, děti a jedinci s chronickými onemocněními.[3]

Kromě zdravotních rizik mají městské tepelné ostrovy i významné environmentální a socioekonomické důsledky. Zvýšená poptávka po klimatizaci v důsledku vyšších teplot vede k nadměrné spotřebě elektrické energie, což nejen zatěžuje energetickou infrastrukturu, ale také přispívá k vyšším emisím skleníkových plynů a akceleraci globálního oteplování. Modifikace teplotních vzorců ve městech dále ovlivňuje i hydrologický cyklus – zvýšené teploty vedou k rychlejšímu odpařování povrchové vody a snížení infiltrační schopnosti půdy v důsledku vysokého podílu nepropustných povrchů. Tento jev může negativně ovlivňovat dostupnost vodních zdrojů a přispívat k nerovnoměrné distribuci srážek, což v extrémních případech může zvyšovat riziko výskytu bleskových povodní a degradace městského ekosystému.[4]

1.1 Řešení tepelných ostrovů

Jedním z nejefektivnějších způsobů zmírnění efektu městských tepelných ostrovů je cílená výsadba vegetace, která přispívá k ochlazování prostředí několika mechanismy.[5] Stromy a rostliny nejen poskytují stín a tím snižují absorpci slunečního záření na površích, ale také aktivně ochlazují okolní vzduch prostřednictvím evapotranspirace. Tento proces, při kterém rostliny odpařují vodu přes své listy, odvádí teplo z okolního prostředí a zvyšuje relativní vlhkost vzduchu, čímž vytváří příznivější mikroklima. Studie ukazují, že v hustě osázených oblastech může být teplota snížena o několik stupňů Celsia ve srovnání s okolím s minimálním vegetačním pokryvem.

K efektivnímu snižování teplot v městských oblastech je klíčové strategické rozmístění zelených ploch. Dalším významným nástrojem v boji proti tepelným ostrovům jsou zelené střechy, které kombinují vegetační kryt s tepelně izolačními vlastnostmi. Zelené střechy mají schopnost absorbovat dešťovou vodu, což zlepšuje hospodaření s vodními zdroji ve městech, zatímco rostliny na střešních plochách pomáhají ochlazovat budovy a snižují energetickou náročnost na klimatizaci. Tyto prvky zelené infrastruktury nejen snižují efekt tepelných ostrovů, ale také přispívají k biodiverzitě a ekologické stabilitě urbanizovaných oblastí.

Zavádění zelené infrastruktury do městského plánování přináší komplexní výhody nejen z hlediska teplotní regulace, ale i v širším kontextu environmentální udržitelnosti. Výsadba vegetace zvyšuje estetickou hodnotu městského prostředí, podporuje rekreační aktivity obyvatel a má pozitivní vliv na psychickou pohodu lidí. Vzhledem k rostoucímu významu adaptace na klimatické změny by měla být cílená výsadba zeleně klíčovou součástí strategií zaměřených na zmírnění tepelných ostrovů a zlepšení kvality života ve městech.

Kapitola 2

Dálkový průzkum země

Dálkový průzkum Země (DPZ) je soubor metod a technologií určených k získávání informací o povrchu planety bez přímého kontaktu s terénem. Tento průzkum využívá záznam elektromagnetického záření odraženého či emitovaného objekty na Zemi a zahrnuje snímkování pomocí satelitů, letadel, dronů nebo jiných leteckých prostředků.[6]

Základem DPZ je zpracování multispektrálních a hyperspektrálních dat, která umožňují detailně analyzovat různé druhy povrchů, vegetaci, vodství nebo urbanizované oblasti. DPZ se používá v různých oblastech vědeckého a praktického výzkumu, například v meteorologii, geologii, ekologii, urbanismu a zemědělství. Jeho hlavní výhodou je schopnost pokrýt rozsáhlá území a poskytovat systematické, dlouhodobé a opakované záznamy změn, což je neocenitelné při monitoringu klimatických změn, degradace půdy nebo rozvoje urbanizace.

Klasický DPZ zahrnuje aktivní a pasivní metody sběru dat. Pasivní senzory, jako jsou optické a infračervené kamery, závisí na slunečním světle a měří odraženou či emitovanou energii z povrchu Země. Aktivní metody, například radarové a lidarové systémy, vysílají vlastní signál a vyhodnocují jeho odraz, což umožňuje sběr dat i za špatných světelných podmínek.

Moderní DPZ přináší významné pokroky v oblasti analýzy dat, kdy pomocí strojového učení a pokročilých algoritmů lze automaticky rozpoznávat a kvantifikovat různé environmentální jevy, jako je deforestace, urbanizace nebo změny v distribuci vegetace.

2.1 Družice Landsat

Družice Landsat představují nejdelší nepřetržitý program civilního satelitního snímkování Země, který je provozován NASA a USGS.[7] Nejnovější generace těchto satelitů, Landsat 8 a 9, poskytuje multispektrální a termální data s vysokou prostorovou a spektrální rozlišovací schopností.[8][9] Tyto satelity operují na synchronní polární dráze ve výšce přibližně 705 km, přičemž jejich oběh kolem Země trvá 98,9 minut. Doba opakovaného snímkování jednoho místa je 16 dní, což umožňuje dlouhodobé sledování změn v krajinné pokrývce, vegetaci, urbanizaci a dalších environmentálních faktorech.



Obrázek 2.1: Družice Landsat 8[10]

Landsat 8, vypuštěný 11. února 2013[8], a Landsat 9, vypuštěný 27. září 2021[9], nesou dva klíčové senzory: Operational Land Imager (OLI) a Thermal Infrared Sensor (TIRS)[7]. OLI je multispektrální zobrazovací systém, který zaznamenává data v devíti spektrálních pásmech v rozsahu viditelného a infračerveného záření, zatímco TIRS měří tepelné emise povrchu Země ve dvou termálních pásmech. Tato kombinace umožňuje podrobné sledování změn teploty povrchu a hodnocení teplotní dynamiky urbanizovaných oblastí.

Název pásu	Vlnová délka [μm]	Rozlišení [m]
Coastal/Aerosol (1)	0.43–0.45	30
Blue (2)	0.45–0.51	30
Green (3)	0.53–0.59	30
Red (4)	0.64–0.67	30
Near Infrared - NIR (5)	0.85–0.88	30
Shortwave Infrared - SWIR 1 (6)	1.57–1.65	30
Shortwave Infrared - SWIR 2 (7)	2.11–2.29	30
Panchromatic (8)	0.50–0.68	15
Cirrus (9)	1.36–1.38	30
Thermal Infrared - TIRS 1 (10)	10.60–11.19	100 (resampled to 30)
Thermal Infrared - TIRS 2 (11)	11.50–12.51	100 (resampled to 30)

Tabulka 2.1: Spektrální pásma senzorů OLI a TIRS na Landsat 8 a 9[11]

Radiometrické rozlišení dat je 12bitové, což znamená 4096 možných hladin odrazu v každém spektrálním pásmu. Tato vysoká citlivost umožňuje přesnější kvantifikaci změn v záření odraženém povrchem Země a poskytuje detailnější informace o dynamice krajiny.

Velikost jednotlivých snímků pořízených družicemi Landsat 8 a 9 je přibližně 185×180 km, což umožňuje efektivní analýzu rozsáhlých území s vysokým prostorovým pokrytím. Data jsou distribuována ve standardizovaném formátu

GeoTIFF, který umožňuje jejich snadnou integraci do geografických informačních systémů (GIS). Díky dlouhodobé konzistenci a volné dostupnosti dat jsou snímky z Landsat široce využívány v oblasti monitoringu životního prostředí, detekce změn v urbanizaci, hodnocení dopadů klimatických změn a plánování udržitelného rozvoje. Tento program je proto klíčovým nástrojem pro globální environmentální výzkum.


V této práci se zaměřujeme na snímky pořízené v období od listopadu 2015 až do konce roku 2024, což umožňuje detailní analýzu změn v této konkrétní časové řadě a poskytuje robustní základ pro studium dynamiky krajiny v tomto časovém rámci. Analyzovaná oblast, město Olomouc, bylo vybráno jako případová studie z několika důvodů. Město představuje významný urbanistický celek s komplexní strukturou, která zahrnuje historické jádro i rozvíjející se periferie. Tato diverzita umožňuje podrobné zkoumání změn v městském prostředí, zahrnující jak přirozené, tak antropogenní vlivy. Výběr Olomouce byl také ovlivněn osobní znalostí autora o místních podmínkách, což usnadňuje interpretaci výsledků a vyhodnocení prostorových změn v kontextu specifických environmentálních a socioekonomických faktorů.

I když se tato studie zaměřuje na konkrétní lokalitu města Olomouc, metodologie a analytické přístupy popsané v této práci mají širokou aplikovatelnost na jiné geografické oblasti. Díky globální dostupnosti snímků z družic Landsat, které jsou pravidelně pořizovány po celé planetě, a díky jejich dlouhodobé časové řadě, je možné tyto postupy snadno přizpůsobit pro analýzu a monitoring různých městských a přírodních oblastí.

Kapitola 3

Zpracování snímku

Po stažení satelitních snímků může začít jejich detailní analýza. Každý snímek je zpracováván individuálně, přičemž první klíčovou operací je ořez dat na předem definovanou geografickou oblast. V této práci je k tomuto účelu využit formát GeoJSON[12], který umožňuje efektivní prostorovou filtraci dat. Ořezem snímků na zájmovou lokalitu, konkrétně na oblast města Olomouce, dochází k významné redukci objemu zpracovávaných dat, což zvyšuje efektivitu následné analýzy.




Obrázek 3.1: Geolokace snímku

Každé spektrální pásmo je zpracováváno samostatně, bez vzájemného ovlivnění dalších spektrálních pásem. Tato separace umožňuje detailní analýzu jednotlivých spektrálních charakteristik daného území. Po provedení ořezu na oblast Olomouce lze přistoupit k samotné analýze snímků, která se v této práci zaměřuje na dva klíčové aspekty:

1. Klasifikace povrchů na základě jejich spektrálních vlastností
2. Stanovení povrchové teploty jednotlivých povrchů

Celkový proces zpracování snímku je schematicky znázorněn ve flowchartu 3.2. Tento diagram ilustruje jednotlivé kroky zpracování od prvotní akvi-




Obrázek 3.2: Flow chart popisující analýzu snímku

zice dat přes předzpracování až po konečnou analýzu. V této kapitole bude podrobně popsána metodika klasifikace povrchů a zároveň přístup k optimalizaci výpočtu povrchové teploty s cílem zvýšit přesnost a spolehlivost výsledků.

3.1 Klasifikace bodů povrchu

Na základě spektrálních charakteristik jednotlivých povrchů lze v dálkovém průzkumu efektivně rozlišovat různé typy krajinného pokrytí na snímcích. Každý materiál, ať už jde o vegetaci, vodu, půdu, nebo urbanizované oblasti, vykazuje specifické vzorce odrazivosti v různých vlnových délkách elektromagnetického záření. Tyto spektrální charakteristiky vytvářejí pro každý povrch unikátní „spektrální otisk“, který lze využít k jeho identifikaci a klasifikaci.

Fyzikální podstatou tohoto jevu je způsob, jakým materiály interagují s elektromagnetickým zářením, které na ně dopadá. Při dopadu světla na povrch materiálu dochází k několika procesům, jako je odraz, absorpce a transmise. Různé materiály mají odlišnou schopnost odrážet, absorbovat a propouštět světlo v různých vlnových délkách spektra. Tato schopnost je dána především jejich optickými a fyzikálními vlastnostmi, jako je struktura materiálu, chemické složení a textury povrchu. Každý typ povrchu tedy vykazuje specifický vzorec odrazivosti na základě jeho chemických a fyzikálních vlastností. Spektrální charakteristiky určitých povrchů, jsou znázorněny na obrázku 3.3



Obrázek 3.3: Spektrální otisk[13]

3.1.1 NDVI

Tento jev je rovněž využit v této práci. Pro identifikaci pixelů, které odpovídají vegetaci, byl aplikován NDVI (Normalized Difference Vegetation Index) společně s prahovou hodnotou.[14] NDVI je široce používaný kvantitativní ukazatel pro detekci vegetace na základě odrazivosti elektromagnetického spektra. NDVI se vypočítává pomocí vzorce

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

kde NIR představuje odrazivost v blízké infračervené oblasti spektra (o vlnové délce přibližně 0.7–1.3 μm) a RED je odrazivost v červené oblasti spektra (o vlnové délce přibližně 0.6–0.7 μm). Tento vzorec využívá rozdíl mezi těmito dvěma spektrálními pásmy. Vegetace vykazuje vysoké hodnoty NDVI, obvykle v rozmezí od 0.2 do 1, zatímco ne-vegetace vykazuje nízké hodnoty, typicky pod hodnotou 0.2.

Vysoké hodnoty NDVI u vegetace jsou způsobeny tím, že rostliny silně absorbují červené světlo (RED) pro fotosyntézu a zároveň silně odrážejí infračervené světlo (NIR) kvůli struktuře buněk v listech, které jsou bohaté na vodu a mají vysoký obsah chlorofylu. Pomocí NDVI lze tedy efektivně oddělit vegetaci od ostatních povrchů.

3.1.2 Strojové učení

Pro jiné typy povrchů, které bychom chtěli identifikovat, však neexistuje specifický index podobný NDVI. Z tohoto důvodu je využito strojové učení. V rámci strojového učení je každý pixel chápán jako šestidimenzionální vektor

$$y = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_6 \end{bmatrix},$$

jehož složky jsou tvořeny hodnotami jednotlivých spektrálních pásmů (Blue, Green, Red, NIR, SWIR1, SWIR2). Tento vektor lze interpretovat jako bod v šestidírozměrném prostoru. Každá složka vektoru odpovídá jedné dimenzi tohoto prostoru.


V oblasti strojového učení existují dvě hlavní metody: učení s učitelem (supervised learning) a učení bez učitele (unsupervised learning).[15] Pokud bychom chtěli použít učení s učitelem, bylo by nutné mít trénovací anotovanou sadu. Taková sada však není k dispozici. Samozřejmě by bylo možné vytvořit vlastní trénovací sadu, kde bychom na základě znalosti povrchu, například z map, anotovali jednotlivá spektra, což by však bylo časově velmi náročné. Proto využijeme metodu učení bez učitele, konkrétně k-means clustering.[16]

Metoda k-means clustering rozdělí spektra na k kategorií, přičemž v každé kategorii budou spektra s podobnou spektrální charakteristikou. Po rozdělení spekter do k kategorií však nevíme, která kategorie odpovídá jakému povrchu. Každou kategorii ale reprezentuje specifická spektrální charakteristika (cluster). Pro přiřazení kategorií konkrétnímu povrchu využijeme známé spektrální charakteristiky jednotlivých povrchů a spočítáme eukleidovskou vzdálenost mezi naším clusterem a těmito známými spektrálními charakteristikami povrchů.

Eukleidovská vzdálenost v šestidimenzionálním prostoru se vypočítá podle následujícího vzorce:

$$d(\mathbf{p}, \mathbf{q}) = \sqrt{\sum_{i=1}^6 (p_i - q_i)^2},$$

kde $\mathbf{p} = (p_1, p_2, \dots, p_n)$ je vektor charakterizující cluster a $\mathbf{q} = (q_1, q_2, \dots, q_n)$ je vektor reprezentující spektrální charakteristiku určitého povrchu. Povrch, který bude přiřazen k určité kategorii, je ten, jehož spektrální charakteristika je nejbližší danému clusteru podle výše uvedené eukleidovské vzdálenosti.



Obrázek 3.4: Klasifikovaný povrch

Tímto způsobem lze efektivně klasifikovat spektra a přiřadit je k odpovídajícím povrchům.

Obvykle je pro dosažení co nejlepších výsledků metodou k-means clustering klíčové správně zvolit počet clusterů, který by měl odpovídat počtu očekávaných skupin. V našem případě však přesná volba tohoto počtu není zásadní. Díky zvolenému přístupu, kdy se jednotlivé clustery přiřazují k typům povrchů na základě jejich spektrální charakteristiky, lze zvolit vyšší počet clusterů – více clusterů pak může být následně přiřazeno k jednomu typu povrchu. Tato vlastnost je navíc dále využita k přesnějšímu stanovení emisivity. Jelikož používáme metodu k-means clustering, je předmětné si tuto metodu vysvětlit.

K-means clustering

Metoda *k-means clustering* je jedním z nejznámějších algoritmů pro shlukování dat. Jejím cílem je rozdělit množinu datových bodů do k shluků (clusterů), přičemž každý shluk obsahuje data, která jsou si vzájemně podobná. Tento algoritmus funguje iterativně a minimalizuje součet eukleidovských vzdáleností mezi datovými body a centry jejich přiřazených clusterů.[17]

Algoritmus začíná náhodným výběrem k datových bodů jako počáteční centroidy (centra) pro jednotlivé clustery. Tyto počáteční centroidy označujeme jako $C_0 = \{c_1^{(0)}, c_2^{(0)}, \dots, c_k^{(0)}\}$, kde každý centroid představuje počáteční hodnotu středu jednoho clusteru.

V druhém kroku algoritmus přiřadí každý datový bod k nejbližšímu centroidu. To se provádí výpočtem eukleidovské vzdálenosti mezi datovými body a centroidy. Datový bod x_i je přiřazen k centroidu c_j , který minimalizuje tuto eukleidovskou vzdálenost.

Po přiřazení všech bodů do jednotlivých clusterů se spočítají nové hodnoty centroidů. Každý centroid se aktualizuje na základě aritmetického průměru všech bodů přiřazených k danému clusteru. Nový centroid pro cluster C_j je definován jako

$$c_j^{(t+1)} = \frac{1}{|C_j|} \sum_{x_i \in C_j} x_i,$$

kde $|C_j|$ je počet bodů přiřazených k clusteru C_j , a x_i jsou všechny datové body v tomto clusteru.

Tento proces (přiřazení bodů a aktualizace centroidů) se opakuje, dokud nedojde k žádné změně v přiřazení bodů k jednotlivým clusterům, nebo dokud změny v centroidu nejsou dostatečně malé. Algoritmus konverguje, když změna v hodnotách centroidů mezi dvěma iteracemi je menší než předem

stanovený prahový limit

$$\|C^{(t+1)} - C^{(t)}\| < \epsilon,$$

kde ϵ je malá hodnota, která určuje toleranci pro zastavení algoritmu.

Cílem k-means algoritmu je minimalizovat součet eukleidovských vzdáleností mezi datovými body a jejich přiřazenými centroidy. Tento součet je formulován jako cílová funkce, kterou algoritmus během iterací minimalizuje

$$J(C) = \sum_{j=1}^k \sum_{x_i \in C_j} d(x_i, c_j)^2,$$

kde $J(C)$ je celkový součet kvadratických eukleidovských vzdáleností mezi body a jejich centroidy.

3.2 Povrchová teplota

Další součástí analýzy je výpočet teploty povrchu, který hraje klíčovou roli v řadě environmentálních studií, například při hodnocení městských tepelných ostrovů, změn klimatu či hydrologických analýz. Satelitní přístup přináší zásadní výhodu v podobě simultánního monitorování celého zkoumaného území s vysokým prostorovým pokrytím, čímž umožňuje získání teplotních údajů pro každý jednotlivý pixel v obraze. Tímto způsobem lze efektivně sledovat prostorové rozdíly teploty a jejich vývoj v čase, což by bylo obtížné dosáhnout jinými metodami.

Alternativním přístupem by bylo využití meteorologických stanic, které poskytují přesná bodová měření teploty vzduchu a v některých případech i teploty povrchu. K získání spojitého teplotního pole by bylo nutné naměřené hodnoty interpolovat, například pomocí metody inverzně vážených vzdáleností (IDW) nebo krigingu.[18] Tento přístup by sice mohl dosahovat vyšší přesnosti v bezprostředním okolí měřicích stanic díky přímému měření, avšak zároveň

by byl limitován jejich prostorovou distribucí. V oblastech s nízkou hustotou meteorologických stanic by interpolované hodnoty mohly být zatíženy významnou nejistotou. Kromě toho je provoz a údržba meteorologických stanic finančně a logisticky náročná, což omezuje jejich počet a rozmístění, zejména v odlehlých nebo méně rozvinutých oblastech.

3.2.1 Určování emisivit

Pro přesný výpočet povrchové teploty je nezbytné znát emisivitu jednotlivých povrchů, která ovlivňuje množství vyzařovaného tepelného záření. Emisivita (ε) je bezrozměrná fyzikální veličina, která vyjadřuje schopnost povrchu vyzařovat tepelnou energii ve srovnání s ideálním černým tělesem. Nabývá hodnot v intervalu $\langle 0, 1 \rangle$, kde hodnota 1 odpovídá ideálnímu zářiči (černému tělesu) a nižší hodnoty značí povrchy s nižší schopností vyzařování infračerveného záření. Určení emisivity lze rozdělit do dvou částí: výpočet emisivity pro pixely klasifikované jako vegetace a výpočet emisivity pro ostatní typy povrchů.

Výpočet emisivity vegetace vychází z metody normalizovaného diferenciálního vegetačního indexu (NDVI), který se vypočítá na základě hodnot odrazivosti v červeném (Red) a blízkém infračerveném (NIR) spektru podle vztahu

$$\text{NDVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}},$$

NDVI je zásadní pro určení množství vegetačního pokryvu, což přímo ovlivňuje výslednou emisivitu. Na základě hodnoty NDVI se následně určuje podíl vegetace (P_V), který je definován jako

$$P_V = \left(\frac{\text{NDVI} - \text{NDVI}_s}{\text{NDVI}_V - \text{NDVI}_s} \right)^2,$$

kde NDVI_V a NDVI_s jsou referenční hodnoty NDVI pro samotnou vege-

taci a půdu. Obvykle se používají hodnoty $NDVI_V = 0,5$ a $NDVI_s = 0,2$, nicméně v různých regionech mohou být tyto hodnoty odlišné v závislosti na konkrétních povrchových podmínkách.

Land Surface Emissivity (LSE, ε) je určena jako vážený průměr emisivity vegetace a emisivity půdy, přičemž váhový faktor odpovídá podílu vegetace[19]

$$\varepsilon_\lambda = \varepsilon_{V\lambda}P_V + \varepsilon_{S\lambda}(1 - P_V) + C_\lambda,$$

kde $\varepsilon_{V\lambda}$ a $\varepsilon_{S\lambda}$ jsou emisivity vegetace a půdy, a C_λ představuje korekční faktor pro drsnost povrchu, který se pro homogenní a rovné povrchy bere jako 0,005.

Jelikož emisivita povrchů hraje klíčovou roli při určování povrchové teploty, je nezbytné ji přesně stanovit nejen pro vegetaci, ale i pro ostatní povrchy. V různých materiálech se emisivita liší v závislosti na jejich fyzikálních a chemických vlastnostech, jako je struktura povrchu, obsah vlhkosti nebo úhel pohledu. Pro nevegetované povrchy, které se běžně vyskytují v městském prostředí, lze emisivitu určit pomocí tabulkových hodnot získaných z literatury.

Následující tabulka obsahuje emisivity běžných povrchů v městské zástavbě:

Hodnoty emisivity mohou být ovlivněny faktory, jako je úroveň zvětrání, přítomnost prachu či vlhkosti na povrchu, což je nutné brát v úvahu při interpretaci výsledků. Emisivita kovových povrchů, zejména plechových konstrukcí, se pohybuje v širokém rozmezí v závislosti na povrchové úpravě – leštěné kovy mají nízkou emisivitu, zatímco zoxidované nebo natřené povrchy vykazují vyšší hodnoty.

Povrch	Emisivita
Voda	0,98
Asfalt	0,90
Beton	0,85
Štěrk	0,94
Vlhká půda	0,96
Suchá půda	0,92
Plechové konstrukce (pozink)	0,10 – 0,30
Plechové konstrukce (natřené)	0,60 – 0,80

Tabulka 3.1: Emisivita různých povrchů[20]

3.2.2 Výpočet povrchové teploty

Pro výpočet povrchové teploty je nezbytné získat hodnoty spektrální radiance na úrovni atmosféry (TOA), která představuje množství vyzařovaného záření, jež dosahuje senzor na palubě satelitu. Tento krok je klíčový pro další analýzu a je prováděn na základě získání dat z určitého spektrálního pásma, v našem případě z pásma 10 (Band 10). Pro výpočet spektrální radiance L_λ se používá vztah[21]

$$L_\lambda = M_L \cdot Q_{\text{cal}} + A_L - O_i,$$

kde M_L je násobící faktor specifický pro dané pásmo, Q_{cal} je hodnota digitálních čísel (DN), která reprezentuje surové údaje z obrazu satelitu pro dané pásmo, A_L je aditivní korekce pro kalibraci, a O_i je korekce specifická pro pásmo 10, která zohledňuje různé atmosférické vlivy, jako je absorpce a rozptyl záření v atmosféře.

Tento krok je nezbytný, protože satelitní senzory měří pouze radianci, která je modifikována atmosférickými podmínkami, jako je vlhkost, prach a další faktory. Korekce těchto vlivů je klíčová pro získání přesných údajů, které budou následně použity k výpočtu povrchové teploty. Jakmile je hodnota

spektrální radiance L_λ získána, následuje její přepočet na jasovou teplotu (brightness temperature, BT).

Jasová teplota BT je teoretická teplota černého tělesa, které vyzařuje stejné množství záření v daném spektrálním pásmu, jako pozorovaný povrch. Tento výpočet je realizován pomocí konverzních konstant K_1 a K_2 , které jsou specifické pro daný senzor a pásmo. Vztah pro přepočet radiance na jasovou teplotu je [22]

$$BT = K_2 \cdot \ln \left(\frac{K_1}{L_\lambda} + 1 \right) - 273.15,$$

kde K_1 a K_2 jsou konverzní konstanty uvedené v metadatech satelitních snímků, a hodnota 273.15 je připočtena k přepočtu teploty na Celsiovu stupnici. Tento krok se zakládá na Planckově zákoně vyzařování, který popisuje vztah mezi intenzitou vyzařovaného záření a teplotou černého tělesa.

Další důležitou fází je korekce jasové teploty na skutečnou povrchovou teplotu (LST, Land Surface Temperature). Tato korekce zohledňuje emisivitu povrchu, což je faktor, který vyjadřuje, jak efektivně povrch vyzařuje tepelné záření. Emisivita závisí na materiálových vlastnostech povrchu, jako je jeho struktura, textura a složení. Pro korekci jasové teploty se používá vzorec[23]


$$T_s = \frac{BT}{\left(1 + \left(\frac{\lambda \cdot BT}{\rho} \right) \ln \varepsilon_\lambda \right)},$$

kde T_s je skutečná povrchová teplota, λ je vlnová délka záření, která je pro pásmo 10 stanovena na $10.895 \mu m$, ε_λ je emisivita povrchu, a ρ je konstanta definovaná vzorcem

$$\rho = \frac{h \cdot c}{\sigma} = 1.438 \times 10^{-2} \text{ m K},$$

kde h je Planckova konstanta ($6.626 \times 10^{-34} \text{ J s}$), c je rychlost světla ($2.998 \times 10^8 \text{ m/s}$) a σ je Boltzmannova konstanta ($1.38 \times 10^{-23} \text{ J/K}$). Tento vzorec zohledňuje efekt emisivity povrchu, která ovlivňuje, kolik tepelného záření

povrch skutečně vyzařuje. Emisivita povrchů se liší v závislosti na materiálu (např. asphalt, beton, voda, vegetace), což znamená, že pro každý typ povrchu je nutné použít odpovídající hodnoty emisivity. Tento faktor je zásadní pro přesné určení povrchové teploty.



Obrázek 3.5: Povrchová teplota

Výpočet povrchové teploty na základě satelitních dat je tedy kombinací teoretických principů vyzařování (Planckův zákon) a empirických korekcí, které zohledňují atmosférické vlivy a specifické materiálové vlastnosti povrchů. Tato metodologie umožňuje získat přesné údaje o teplotních podmínkách na povrchu Země, což je klíčové pro environmentální analýzy.

Přesnost výpočtu povrchové teploty byla ověřena porovnáním s reálnými měřeními provedenými meteorologickou stanicí Olomouc – U kovářny. Pro porovnání byly použity teplotní hodnoty získané ze satelitních snímků v

časové shodě s měřeními stanice. Pro každý odpovídající časový úsek byl vypočten rozdíl mezi povrchovou teplotou odvozenou ze satelitních dat a vzdušnou teplotou naměřenou meteorologickou stanicí. Tato data byla následně statisticky vyhodnocena. Výsledky ukázaly vysokou shodu – 94% všech porovnávaných hodnot se nacházelo v intervalu $-0,5^{\circ}\text{C}$ až $+0,5^{\circ}\text{C}$, což potvrzuje vysokou přesnost zvoleného postupu při výpočtu teploty povrchu. Meteorologická stanice se nachází v nadmořské výšce 227 m na souřadnicích $49^{\circ}35'37''\text{S}$, $17^{\circ}13'39''\text{J}$, přičemž výška stanice nad zemí činí 3 m. Tato stanice poskytuje dlouhodobě stabilní a validní data, která jsou veřejně dostupná. [24].

Kapitola 4

Časová analýza a kvantifikace vlivu zeleně

Analýza popsaná v předchozí kapitole byla aplikována na každý jednotlivý snímek v datasetu. Výsledkem této aplikace je nová datová sada, ve které je ke každému snímku přiřazena nejen informace o datu a čase jeho pořízení, ale také klasifikace povrchu na snímku a odpovídající povrchová teplota. Tato rozšířená datová sada představuje klíčový podklad pro další zpracování a interpretaci výsledků. S tímto nově vytvořeným datasetem můžeme přistoupit k následující fázi analýzy, která se zaměří na hlubší vyhodnocení prostorových a časových trendů v získaných datech.


4.1 Vývoj teploty povrchů v čase

Jedním z klíčových aspektů analýzy je sledování časového vývoje teplot jednotlivých typů povrchů. Tento přístup umožňuje identifikovat trendy, sezónní variabilitu a možné anomálie v tepelném chování různých materiálů.

Pro každý dostupný snímek se nejprve vypočítá průměrná povrchová teplota všech pixelů, které byly klasifikovány jako určitý typ povrchu. Tento výpočet je proveden samostatně pro každý povrch, což umožňuje získat reprezenta-

tivní hodnotu teploty daného materiálu v konkrétním časovém okamžiku.

Získaná data jsou následně vizualizována pomocí grafu, kde na vodorovné ose je znázorněno datum pořízení snímku a na svislé ose odpovídající průměrná povrchová teplota. Každý typ povrchu je v grafu reprezentován samostatnou křivkou, která popisuje jeho teplotní vývoj v čase. Tímto způsobem lze snadno porovnat odlišné teplotní charakteristiky jednotlivých povrchů a analyzovat jejich změny v závislosti na externích faktorech, jako jsou roční období, meteorologické podmínky nebo urbanistické vlivy.



Obrázek 4.1: Vývoj teploty jednotlivých povrchů v čase

Jelikož jsou analyzovány snímky v období od listopadu 2015 do prosince 2024, jedná se o relativně krátký časový úsek. Vzhledem k této omezené časové škále lze předpokládat, že vývoj povrchové teploty bude možné aproximovat lineární funkcí. K tomu využijeme lineární regresi, která umožňuje nalézt nejvhodnější přímku popisující trend teploty v čase.

Lineární regrese je statistická metoda používaná k modelování vztahu mezi závislou proměnnou, v tomto případě povrchovou teplotou, a nezávislou

proměnnou, kterou představuje čas. Cílem této metody je nalezení lineární funkce ve tvaru

$$T(t) = a \cdot t + b,$$

kde $T(t)$ je odhadovaná teplota v čase t , a je směrnice přímky vyjadřující rychlost změny teploty v čase a b je absolutní člen, který představuje odhadovanou teplotu na začátku sledovaného období.

Pro určení optimálních hodnot parametrů a a b se využívá metoda nejmenších čtverců, která minimalizuje součet druhých mocnin rozdílů mezi skutečnými hodnotami teploty T_i a predikovanými hodnotami podle modelu. Tedy hledáme takové parametry, které minimalizují výraz

$$\sum_{i=1}^n (T_i - (a \cdot t_i + b))^2,$$

kde n je počet dostupných měření. Výsledkem této optimalizace jsou hodnoty a a b , které nejlépe vystihují celkový trend v datech. Nejdůležitějším parametrem získaným z lineární regrese je směrnice přímky, označená jako a . Tento parametr vyjadřuje rychlost změny teploty daného povrchu v čase. Čím větší je jeho hodnota, tím rychleji teplota daného povrchu roste. Naopak, záporná hodnota směrnice indikuje pokles teploty v průběhu času.

Díky této vlastnosti můžeme snadno porovnávat rychlost růstu teploty různých typů povrchů. Jednoduchým způsobem porovnání je stanovení poměru mezi směrnici dvou povrchů. Pokud označíme směrnici prvního povrchu jako a_{p1} a směrnici druhého povrchu jako a_{p2} , můžeme jejich relativní rychlost změny vyjádřit pomocí

$$R = \frac{a_{p1}}{a_{p2}}.$$

Tento poměr nám poskytuje informaci o tom, kolikrát rychleji se mění teplota jednoho povrchu ve srovnání s druhým. Pokud například $R > 1$, znamená to,

že první povrch se otepluje rychleji než druhý. Naopak, pokud $R < 1$, pak je růst teploty druhého povrchu výraznější. Tato metoda umožňuje kvantitativní porovnání různých typů materiálů a jejich tepelných vlastností v čase. Hodnoty směrnice a pro jednotlivé povrchy jsou zobrazeny v tabulce 4.1.

Povrch	Směrnice a
Vegetace	0.0005
Voda	0.0004
Hlina	0.0007
Štěrk	0.0005
Asfalt	0.0007
Beton	0.0006
Plechové konstrukce	0.0010

Tabulka 4.1: Hodnoty směrnice a pro jednotlivé povrchy

Je tedy jasné vidět, že vegetace a voda se ohřívají v čase nejméně, zatímco například plechové konstrukce se ohřívají téměř dvakrát rychleji. Tento rozdíl v rychlosti ohřevu ukazuje na významné odlišnosti v tepelných vlastnostech různých typů povrchů.


4.2 Vliv vegetace na teplotu

Jedním z klíčových faktorů ovlivňujících teplotní mikroklima v urbanizovaných oblastech je přítomnost vegetace. Jak je patrné z grafu 4.1, vegetační pokryv vykazuje výrazně nižší povrchovou teplotu ve srovnání s umělými povrchy, jako jsou beton, asfalt nebo střešní materiály. Tento teplotní rozdíl se pohybuje v rozmezí přibližně 5°C až 10°C , což potvrzuje významnou roli vegetace v mitigaci efektu městských tepelných ostrovů (Urban Heat Islands, UHI). Navzdory dobře známému ochlazovacímu efektu vegetace zůstává přesná kvantifikace jejího vlivu na konkrétní lokality metodologickou výzvou.

V této kapitole představíme inovativní přístup ke kvantifikaci vlivu vegetace na teplotní charakteristiky urbanizovaného prostředí, a to za pomoci nově definovaného Vegetation Influence Factor (VIF).

4.2.1 Závislost teploty na vzdálenosti od vegetace

Před samotnou definicí Vegetation Influence Factor (VIF) je nezbytné určit maximální vzdálenost, ve které vegetace stále prokazatelně ovlivňuje teplotu daného místa. K tomuto účelu byla provedena podrobná analýza závislosti teploty povrchu na vzdálenosti od nejbližšího vegetačního prvku. Pro výpočet vzdáleností mezi jednotlivými body byla využita eukleidovská metrika, která umožňuje přesné kvantifikování prostorových vztahů mezi vegetací a analyzovanými lokalitami. Výsledky této analýzy jsou prezentovány v 4.2 a poskytují základní přehled o rozsahu vlivu vegetace na teplotní režim povrchů v různých podmínkách.



Obrázek 4.2: Závislost teploty na vzdálenosti od vegetace

Pro stanovení maximální vzdálenosti, ve které vegetace stále ovlivňuje teplotu konkrétního bodu, je nezbytné aproximovat experimentální data vhodnou matematickou funkcí, která je shora omezená a reflektuje fyzikální podstatu zkoumaného jevu. Vzhledem k charakteru problému byla jako nejvhodnější zvolena funkce ve tvaru

$$y = m - n \left(\frac{1}{x^2} \right),$$

kde parametr m představuje horizontální asymptotu, což odpovídá teplotní hodnotě, ke které se vztah mezi teplotou a vzdáleností asymptoticky blíží při rostoucí hodnotě x . Konstanty m a n jsou určeny regresní analýzou na základě naměřených dat, přičemž parametr n popisuje míru počátečního poklesu vlivu vegetace na teplotu.

Maximální vzdálenost, na kterou je vegetace ještě schopna detekovatelně ovlivnit teplotu měřeného bodu, lze formálně stanovit z podmínky, při níž je změna teploty způsobená vegetací větší než předem definovaná práhová hodnota ϵ , což matematicky vyjadřuje nerovností

$$m - \left(m - n \frac{1}{x^2} \right) > \epsilon \quad \Leftrightarrow \quad n \frac{1}{x^2} > \epsilon \quad \Leftrightarrow \quad x < \sqrt{\frac{n}{\epsilon}}.$$

Hodnota ϵ zde představuje velmi malé číslo, jehož velikost je určena s ohledem na rozlišovací schopnost měření a fyzikální významnost teplotního vlivu vegetace. Řešením této nerovnosti lze tedy získat maximální vzdálenost, při které vegetace ještě významně ovlivňuje teplotní podmínky daného bodu.

Navržený přístup umožňuje objektivní a kvantitativně podložené vymezení dosahu vegetačního vlivu na teplotní charakteristiky různých povrchů, což je klíčové nejen pro pochopení lokálních teplotních variací, ale i pro širší environmentální modelování, urbanistické plánování a mitigaci efektu městského tepelného ostrova.

4.2.2 Vegetation Influence Factor (VIF)

Nyní se můžeme zaměřit na klíčovou část této kapitoly, a to na představení zcela nové hodnoty, která kvantifikuje vliv vegetace na teplotu daného místa, nazývané Vegetation Influence Factor (VIF). VIF je hodnota, která reprezentuje míru, do jaké je dané místo ovlivněno vegetací, respektive jak silně je

okolí tohoto místa "zelené". VIF závisí pouze na jednom vstupním parametru, a tím je vzdálenost $d[m]$, což je maximální vzdálenost, do které vegetace dané místo ovlivňuje, jak bylo určeno v předchozí části.

Je tedy zřejmé, že se budeme zabývat vegetací, která se vyskytuje pouze v okruhu o poloměru d se středem v bodě, který nás zajímá. Nyní přistupme k samotné definici $VIF(d)$.

Definice: Necht' máme pole bodů, ve kterém je bod S o souřadnicích $[x_s, y_s]$. Dále mějme v tomto poli n bodů vegetace se souřadnicemi $[x_1^v, y_1^v], \dots, [x_n^v, y_n^v]$. Hodnotou $VIF(d)$ pro bod S rozumíme hodnotu definovanou jako


$$VIF(d) = \sum_{i=1}^n \frac{1}{r_i^2} \quad \text{pro } r_i < d,$$

kde $\{r_1, r_2, \dots, r_n\}$ představují vzdálenosti bodů vegetace od bodu S , tedy

$$r_i = \sqrt{(x_s - x_i^v)^2 + (y_s - y_i^v)^2}.$$

Definice Vegetation Influence Factor (VIF) je rovněž graficky znázorněna na obrázku 4.3. Čím větší je hodnota VIF, tím "zelenější" je okolí daného bodu, což naznačuje vyšší míru vegetačního pokrytí v okolí. Pokud je hodnota $VIF = 0$, znamená to, že v okruhu daného bodu o poloměru d není žádná vegetace. Maximální hodnota VIF závisí na parametru d , přičemž se mění v závislosti na velikosti tohoto parametru. Například pro $d = 210$ m je maximální hodnota VIF rovna 14,7, což znamená, že všechny okolní body jsou klasifikovány jako vegetace.

Nyní, když máme nově definovanou hodnotu Vegetation Influence Factor (VIF), která vyjadřuje vliv vegetace na dané místo, můžeme analyzovat, jak závisí teplota tohoto místa na hodnotě VIF. Jednoduše řečeno, pro každý bod, který není klasifikován jako vegetace, spočítáme jeho hodnotu VIF a




Obrázek 4.3: Definice VIF

zobrazíme ji v grafu společně s odpovídající teplotou. Tento postup provádíme pro každý typ povrchu zvlášť, jelikož vegetace má na různé povrchy různý vliv.

Aby bylo možné do jednoho grafu zahrnout všechny snímky, kromě těch, které jsou pořízeny v zimních měsících, kde ochlazující efekt vegetace není relevantní, je nutné teplotu na jednotlivých snímcích normalizovat. V grafu tedy bude vždy zobrazen VIF a k tomu teplota, která bude určena jako teplota daného místa minus průměrná teplota vegetace na snímku. Tento přístup umožní v jednom grafu zobrazit snímky, kde průměrná teplota přesahovala 30°C , a zároveň snímky, kde byla průměrná teplota kolem 20°C . Tato data jsou znázorněna v grafu 4.4.

V grafu 4.4 jsou rovněž znázorněna vyhlazená data. K vyhlazení byl použit Savitzky-Golay filtr s parametry velikosti okna 5 a stupně aproximačního polynomu 3.[25] To znamená, že data nebyla téměř vůbec vyhlazena, pouze byly odstraněny velmi odlehlé hodnoty. Jak si můžeme všimnout z grafu, závislost teploty na hodnotě VIF vykazuje téměř lineární charakter. Abychom potvr-



Obrázek 4.4: Závislost teploty na VIF

dili, že teplota je skutečně lineárně závislá na VIF, spočítáme Pearsonův korelační koeficient.[26] Tento koeficient je spočítán podle vzorce

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}},$$

kde x_i a y_i jsou jednotlivé hodnoty proměnných a $\bar{x}$ a $\bar{y}$ jejich průměry. V našem případě Pearsonův korelační koeficient vychází na hodnotu $p = -0.86$. To znamená, že se jedná o velmi silnou korelaci, protože absolutní hodnoty Pearsonova korelačního koeficientu větší nebo rovné 0.8 se považují za velmi silnou korelaci. Tento výsledek potvrzuje, že teplota povrchu je lineárně závislá na nově definované hodnotě VIF.

Na základě této silné korelace můžeme nyní pouze na základě hodnoty VIF určit teplotu daného místa. Tento přístup nám umožňuje, například na základě plánu města, predikovat, kde bude jaká teplota. Zároveň definujeme novou konstantu úměrnosti ν , která je určena z lineární aproximace dat jako směrnice aproximační přímky. Konstanta úměrnosti ν tak jednoduše kvantifikuje potřebnou změnu VIF k tomu, aby došlo ke snížení teploty o určitou hodnotu.

Typ povrchu	ν
Asfalt	-0.41
Beton	-0.53
Plechové konstrukce	-0.20
Štěrkové povrchy	-0.39
Hlina	-0.64

Tabulka 4.2: Hodnoty konstanty ν pro jednotlivé typy povrchů

Tabulka 4.2 nám umožňuje jednoduše určit, o kolik musíme zvýšit hodnotu VIF, aby teplota daného povrchu klesla o požadovanou hodnotu. Pokud VIF zvýšíme o $\frac{1}{-\nu}$, teplota klesne o 1°C.

Pomocí hodnoty Vegetation Influence Factor (VIF) jsme schopni s vysokou přesností predikovat povrchovou teplotu jednotlivých bodů na základě dostupných prostorových dat, jako je například plán městské oblasti. Tento přístup nám umožňuje nejen určit aktuální teplotní podmínky pro různé části městské krajiny, ale také detailně identifikovat oblasti, které jsou nejvíce náchylné k přehřívání. Díky tomu můžeme provádět prostorovou analýzu, která zohledňuje vliv vegetace na teplotu v různých typech povrchů a identifikovat kritické oblasti, kde hrozí vysoké teplotní extrémy.

Význam tohoto nástroje spočívá v jeho schopnosti nejenom mapovat současnou teplotní situaci, ale také predikovat potenciální tepelné anomálie v městském prostředí. Tento přístup nabízí nesmírně cenné informace pro městské plánování a environmentální management, protože umožňuje přesně určit, které oblasti budou nejvíce vystaveny negativním vlivům vysokých teplot. Znalost těchto oblastí může být zásadní při formulování strategií na zmírnění efektu městského tepelného ostrova (UHI) a zlepšení kvality života ve městech.

Díky přesnosti, s jakou VIF umožňuje modelovat teplotní variace, se otevírá prostor pro aplikace, které mohou pomoci plánovat zóny s vysokou koncentrací vegetace, což přímo přispívá k ochraně před extrémními teplotami. Tímto způsobem můžeme efektivně předcházet riziku teplotních vln a zlepšit podmínky pro obyvatele měst, čímž se podpoří udržitelnost městského prostředí v kontextu globální změny klimatu.

Kapitola 5

Optimalizace městské struktury

S využitím znalostí o vývoji povrchových teplot v čase a jejich závislosti na hodnotě Vegetation Influence Factor (VIF) je nyní možné přistoupit k finální fázi analýzy, kterou představuje optimalizace městské struktury. V této fázi je kladeno důraz na efektivní zlepšení teplotních podmínek v městských oblastech, zejména v rámci snižování teplotních extrémů a zpomalování efektu městského přehřívání. Cílem je navrhnout městskou strukturu, která bude nejen ekologicky udržitelná, ale i energeticky efektivní, čímž se zlepší kvalita života obyvatel a sníží se riziko zdravotních problémů spojených s vysokými teplotami.

V této kapitole bude představen pokročilý algoritmický nástroj, konkrétně genetický algoritmus, který využívá historická data o teplotních výkyvech a jejich vztahu k hodnotám VIF pro navrhování městských úprav. Tento algoritmus je schopen efektivně vyhledávat optimální řešení pro umístění vegetace, změnu povrchových materiálů a úpravy urbanistické struktury s cílem minimalizovat tepelné anomálie a zmírnit vliv městského tepelného ostrova.

5.1 Genetický algoritmus

Genetický algoritmus (GA) je optimalizační technika inspirovaná biologickými principy evoluce a přírodní selekce. Patří do širší třídy evolučních algoritmů a je určen k hledání optimálních řešení pro složité problémy, kde tradiční metody optimalizace nejsou aplikovatelné. GA je obzvláště efektivní pro řešení problémů s vysokodimenzionálními prostory hledání, nelineárními funkcemi a v případech, kdy existuje mnoho lokálních optim. Tento algoritmus je schopný prohledávat rozsáhlé prostory řešení, aniž by byl přímo závislý na počátečních podmínkách.[27][28][29]

Základní princip genetického algoritmu spočívá v simulaci přirozeného evolučního procesu, kde jsou hledaná řešení reprezentována jako jedinci v populaci, kteří podléhají procesům selekce, křížení a mutace. Algoritmus začíná vytvářením počáteční populace jedinců, kteří jsou reprezentováni pomocí chromozomů – vektorů, které popisují potenciální řešení problému. V této práci je každý jedinec reprezentován maticí o rozměrech odpovídajících oblasti, kterou chceme upravit. Jednotlivé prvky této matice nesou informaci o typu změny, která má na daném místě proběhnout. Hodnota NaN značí pozice, kde z technických nebo jiných důvodů není možné žádnou úpravu provést. Na ostatních místech jsou uvedeny hodnoty reprezentující konkrétní typy změn – například různé zásahy, transformace nebo operace, které mohou být v dané oblasti aplikovány. Tímto způsobem lze každého jedince jednoznačně popsat a zároveň zajistit, že algoritmus respektuje omezení prostoru, ve kterém se pohybuje. Každý jedinec je ohodnocen pomocí fitness funkce, která hodnotí kvalitu jeho řešení. Fitness funkce je nezbytná pro určení, jak dobře dané řešení splňuje požadavky optimalizačního úkolu.

Selektivní proces zajišťuje, že jedinci s vyšší fitness mají větší pravděpodobnost, že budou vybráni k reprodukci. Tento proces napodobuje přirozený výběr v biologických populacích, kde jedinci s výhodnými vlastnostmi mají větší šanci na přežití a rozmnožování. Nejčastěji používané metody selekce zahr-

nují ruletovou selekci, kde je pravděpodobnost výběru jednotlivce úměrná jeho fitness, a turnajovou selekci, kde jsou jednotlivci vybíráni na základě soutěže mezi podskupinami populace.

Po selekci následuje křížení (crossover), kde se genetická informace dvou vybraných rodičů kombinuje za účelem vytvoření potomků. Křížení umožňuje výměnu genetického materiálu mezi jedinci a může vést k vytvoření nových, potenciálně lepších řešení. Existuje několik metod křížení, mezi něž patří jednobodové křížení, vícestupňové křížení a uniformní křížení, kdy jsou jednotlivé geny náhodně kombinovány mezi rodiči.

Dalším klíčovým procesem je mutace, která provádí náhodné změny v genetické informaci jednotlivce. Tento krok má za cíl zajistit genetickou diverzitu v populaci a pomoci algoritmu vyhnout se uvíznutí v lokálních optimech. Mutace se obvykle provádí změnou hodnoty jednoho nebo více genů v chromozomu, což zajišťuje, že nové varianty řešení budou stále prozkoumávány.

Proces selekce, křížení a mutace probíhá v několika generacích, přičemž každá nová generace vytváří novou populaci jedinců, kteří vycházejí z předchozí populace. Tento evoluční proces pokračuje, dokud algoritmus nenalezne řešení, které splňuje požadavky na optimalizaci, nebo dokud nevyprší maximální počet generací.

5.2 Program pro optimalizaci městské struktury

V této práci byl vyvinut genetický algoritmus, který je schopen optimalizovat rozmístění vegetace v městské struktuře. Nicméně, je nezbytné definovat způsob hodnocení kvality tohoto rozmístění, aby bylo možné efektivně hodnotit dosažené výsledky a optimalizovat je. Prvním a klíčovým faktorem, který bude při hodnocení zohledněn, je množství přidané vegetace. Zvýšení

podílu vegetace ve městě má za následek vyšší náklady na implementaci tohoto opatření, a proto je žádoucí minimalizovat množství přidané vegetace, pokud to není nezbytné pro dosažení požadovaných teplotních parametrů. Tento kompromis mezi náklady a přínosy je nezbytné zahrnout do hodnotící funkce.

Dalším významným faktorem je ochlazení městského prostoru. Cílem je, aby bylo dosaženo co největšího ochlazení ve městě, což lze efektivně měřit pomocí parametru Vegetation Influence Factor (VIF). Optimalizace rozmístění vegetace by měla zajistit, že všechny oblasti městské struktury budou mít hodnotu VIF nižší než nastavené maximální limitní hodnoty. Tímto způsobem lze kontrolovat teplotní režim městských oblastí a zajistit, aby teplota na žádném místě nepřesáhla stanovený bezpečný limit. Tento požadavek reflektuje snahu o dosažení rovnováhy mezi zvýšením množství vegetace a zajištěním adekvátního ochlazení městského prostoru.

Třetí aspekt, který je nutné zohlednit v rámci optimalizace, se týká identifikace a ochrany oblastí s vyšší tendencí k přehřívání v budoucnu. Tato místa budou v rámci algoritmu hodnocena jako prioritní oblasti, kde je žádoucí zvýšit hodnotu VIF nad běžné limity. Cílem tohoto opatření je zajistit, aby tato specifická místa byla schopna odolávat extrémním teplotním podmínkám v dlouhodobém horizontu a aby se zabránilo jejich opětovnému přehřívání v průběhu času. Tato adaptivní strategie je klíčová pro udržitelné řízení městského klimatu a prevenci negativních efektů spojených s rostoucími teplotami.

Na základě těchto tří hlavních kritérií, tedy optimalizace množství přidané vegetace, dosažení maximálního ochlazení a zohlednění budoucího přehřívání, bude definována fitness funkce genetického algoritmu. Tato funkce bude kombinovat výše uvedené faktory, přičemž každý z nich bude ohodnocen specifickými váhami, které budou odrážet jejich relativní důležitost v procesu

optimalizace. Tímto způsobem bude genetický algoritmus schopen nalézt optimální rozložení vegetace, které vyváží náklady, efektivitu ochlazení a dlouhodobou udržitelnost městského klimatu.

Jakmile je definována fitness funkce, lze genetický algoritmus spustit. Nicméně pro dosažení optimálního výsledku je nezbytné správně nastavit klíčové parametry evolučního procesu, mezi něž patří velikost populace, počet generací a míra mutace. Tyto parametry zásadním způsobem ovlivňují konvergenci algoritmu a jeho schopnost nalézt optimální řešení v přijatelném čase.

Velikost populace určuje, kolik jedinců bude v každé generaci reprezentovat možná řešení optimalizačního problému. Příliš malá populace může vést k předčasné konvergenci na suboptimální řešení v důsledku nízké genetické diverzity, zatímco příliš velká populace zvyšuje výpočetní náročnost algoritmu bez záruky dosažení lepšího výsledku. Optimální velikost populace závisí na složitosti řešeného problému a je často stanovena empiricky.

Počet generací ovlivňuje dobu, po kterou bude algoritmus hledat optimální řešení. Pokud je počet generací příliš nízký, algoritmus nemusí mít dostatek času k nalezení kvalitního řešení. Naopak příliš velký počet generací může vést k nadměrnému výpočetnímu zatížení bez výrazného zlepšení výsledků. Obvykle je vhodné provádět testovací běhy s různými nastaveními tohoto parametru a volit takovou hodnotu, při níž dochází k saturaci kvality řešení.


Míra mutace je dalším kritickým parametrem, který ovlivňuje diverzitu genetického materiálu v populaci. Nízká míra mutace může způsobit ustrnutí algoritmu v lokálním optimu, protože v populaci chybí dostatečná variabilita pro prozkoumání širšího prostoru řešení. Naopak příliš vysoká míra mutace může vést k nahodilému chování algoritmu a zabránit jeho konvergenci. Ideální hodnota míry mutace je obvykle nízká a slouží jako mechanismus jemného prozkoumávání prostoru možných řešení.

Správná volba těchto parametrů je zásadní pro úspěšnou optimalizaci a nalezení vhodné konfigurace vegetačních prvků ve městě. Při vhodném nastavení genetického algoritmu dochází k jeho konvergenci ke kvalitnímu řešení, které efektivně minimalizuje přehřívání městských oblastí při současné optimalizaci množství přidané vegetace.

Jako výsledek genetického algoritmu je získáno optimální řešení, které specifikuje lokality, kam je nezbytné přidat vegetaci tak, aby byly co nejlépe splněny stanovené podmínky minimalizace přehřívání městských oblastí. Toto řešení je možné vizualizovat na obrázku 5.1.

Jedním z možných aspektů k diskuzi je skutečnost, že algoritmus může identifikovat jako vhodná místa pro vegetační úpravy například střechy budov. Tento fakt však nepředstavuje žádný problém, neboť analýza satelitních snímků ukazuje, že objekty se zelenými střechami či vertikálními zahradami vykazují termální vlastnosti blízké vegetaci. Z toho vyplývá, že algoritmus nejen efektivně určuje optimální lokality pro výsadbu vegetace, ale rovněž identifikuje objekty, kde by bylo výhodné investovat do zelených střech či dalších adaptačních opatření. Tímto způsobem algoritmus podporuje návrh městské infrastruktury s maximálním chladícím efektem a s co nejefektivnějším využitím dostupných zdrojů.

Tento nástroj umožňuje na základě urbanistických plánů identifikovat optimální lokality pro výsadbu zeleně nebo implementaci opatření ke snížení extrémních teplot. Díky analýze historických dat je schopen tato doporučení dále zpřesňovat a optimalizovat, čímž poskytuje efektivní strategii pro mitigaci tepelných ostrovů ve městech a podporu udržitelného urbanistického rozvoje.



Obrázek 5.1: A - Před úpravami, B - Navržené úpravy

Závěr

Cílem této práce bylo vyvinout nový a efektivní způsob pro výpočet povrchové teploty, který bude přesnější zejména v urbanizovaných oblastech. V rámci tohoto cíle byl vytvořen nový, inovativní postup, který zohledňuje specifika městských oblastí, jako je přítomnost různých povrchů (vegetace, asfalt, beton a další) a jejich vliv na teplotu. Tento nový přístup pro výpočet povrchové teploty, kombinující satelitní snímky a pokročilé analytické metody, přináší větší přesnost v určení teplotních poměrů v městském prostředí než dosavadní metody. Tento nový způsob výpočtu povrchové teploty je klíčovým prvkem pro další analýzy, které byly v práci provedeny.

Klíčovým přínosem této práce je rovněž vyvinutí nového ukazatele vlivu vegetace, nazvaného Vegetation Influence Factor (VIF), který kvantifikuje vliv vegetace na teplotu konkrétního místa. Bylo prokázáno, že teplota města je lineárně závislá na hodnotě VIF, přičemž konstanta této úměrnosti byla označena jako ν . Tento objev představuje důležitý krok k lepšímu pochopení vlivu vegetace na městský tepelný ostrov a nabízí nový nástroj pro analýzu teplotních podmínek ve městě. Vytvoření ukazatele VIF umožňuje městským plánovačům efektivněji hodnotit vliv vegetace na teplotní poměry a lépe navrhnout opatření ke zmírnění přehřívání.

V rámci této práce byl dále vyvinut algoritmus, který na základě historických dat a konstanty ν pro jednotlivé povrchy dokáže navrhnout optimální úpravy městského prostředí. Tento algoritmus je schopen analyzovat vývoj teploty

v konkrétních oblastech a efektivně doporučit místa pro výsadbu vegetace s cílem snížit teplotní extrémy a zpomalit oteplování městských oblastí. Tento nástroj představuje praktickou aplikaci pro městské plánování a poskytuje důležitý nástroj pro zlepšení mikroklimatu ve městech.

Závěrem lze říci, že tato práce přináší nový pohled na výpočet povrchové teploty v urbanizovaných oblastech a rozšiřuje možnosti analýzy vlivu vegetace na městský tepelný ostrov. Vyvinutý ukazatel VIF a algoritmus pro návrh úprav městských oblastí představují důležitý krok směrem k udržitelnému městskému plánování. Vzhledem k rostoucím problémům s tepelnými ostrovy a změnami klimatu, má tento přístup potenciál pro širší aplikace v rámci městských plánovacích strategií a adaptace měst na změny klimatu. Tato práce tak přispívá k rozvoji nových metod, které mohou zlepšit kvalitu života ve městě a přispět k jeho odolnosti vůči klimatickým změnám.

Literatura

1. FULADLU, Kamyar. *Urban Heat Island*. 2025. Dostupné také z: <https://community.wmo.int/en/activity-areas/urban/urban-heat-island>. Obrázek je k dispozici na stránce Světové meteorologické organizace (WMO).
2. OKE, T.R. The urban heat island: causes and consequences. *Energy and Buildings*. 1984, roč. 7, s. 103–113.
3. HARLAN, Sharon L.; RUDDELL, Darren M. Urban Heat Islands and Health Inequities: A Synthesis of Science and Policy. *Current Opinion in Environmental Sustainability*. 2011, roč. 3, č. 3, s. 277–283.
4. ESTRADA, Francisco; BOTZEN, W. J. Wouter; TOL, Richard S. J. Urban heat island effect amplifies climate change warming in cities. *Proceedings of the National Academy of Sciences*. 2017, roč. 114, č. 9, s. 2327–2332. Dostupné z DOI: [10.1073/pnas.1606034114](https://doi.org/10.1073/pnas.1606034114).
5. BOWLER, Diana E.; BUYUNG-ALI, Lisette; KNIGHT, Teri M.; PULLIN, Andrew S. Urban greening to cool towns and cities: A systematic review of the empirical evidence. *Landscape and Urban Planning*. 2010, roč. 97, č. 3, s. 147–155. Dostupné z DOI: [10.1016/j.landurbplan.2010.05.006](https://doi.org/10.1016/j.landurbplan.2010.05.006).
6. LILLESAND, Thomas M.; KIEFER, Ralph W.; CHIPMAN, Jonathan W. *Remote Sensing and Image Interpretation*. 5th. John Wiley & Sons, 2004. ISBN 978-0-471-15227-9.

7. NASA EARTH OBSERVATORY. *Landsat Program* [url<https://earthobservatory.nasa.gov/features/Landsat>]. 2021. Accessed: 2025-03-24.
8. NASA EARTH OBSERVATORY. *Landsat 8* [url<https://landsat.gsfc.nasa.gov/landsat-8>]. 2021. Accessed: 2025-03-24.
9. NASA EARTH OBSERVATORY. *Landsat 9* [url<https://landsat.gsfc.nasa.gov/landsat-9>]. 2021. Accessed: 2025-03-24.
10. NASA. *Landsat 8 (LCM) Mission* [<https://science.nasa.gov/mission/landsat-8-lcm/>]. 2025. Figure courtesy of NASA, accessed: 2025-03-24.
11. NASA. *Landsat 9 Bands* [<https://landsat.gsfc.nasa.gov/satellites/landsat-9/landsat-9-bands/>]. 2025. Accessed: 2025-03-24.
12. GROUP, GeoJSON Working. *GeoJSON Format Specification* [<https://geojson.org/>]. 2015. Accessed: 2025-03-24.
13. FULADLU, Kamyar. *Spectral reflectance of different materials across visible to infrared wavelengths* [https://www.researchgate.net/figure/Spectral-reflectance-of-different-materials-across-visible-to-infrared-wavelengths_fig3_268215215]. 2015. Accessed: 2025-03-24.
14. J.W. ROUSE R.H. Haas, J.A. Schell D.W. Deering. Monitoring Vegetation Systems in the Great Plains with ERTS. *Proceedings of the Third Earth Resources Technology Satellite-1 Symposium*. 1974, roč. 1, s. 309–317.
15. ALPAYDIN, Ethem. *Introduction to Machine Learning*. 4th. Cambridge, MA: MIT Press, 2020.
16. LLOYD, S. P. Least squares quantization in PCM. *IEEE Transactions on Information Theory*. 1982, roč. 28, č. 2, s. 129–137. Dostupné z DOI: [10.1109/TIT.1982.1056489](https://doi.org/10.1109/TIT.1982.1056489).

17. JAIN, Anil K. *Data Clustering: A Review*. Sv. 31. 2010. Č. 3. Dostupné z DOI: [10.1145/70399.70400](https://doi.org/10.1145/70399.70400).
18. ISAACS, E. H.; SRIVASTAVA, R. M. *An Introduction to Applied Geostatistics*. New York: Oxford University Press, 1989. ISBN 9780195050137.
19. ZHANG, Y.; LI, J. W.; ZHANG, L. M. A method for determining land surface emissivity from NDVI for surface temperature retrieval. *Remote Sensing of Environment*. 2003, roč. 86, č. 3, s. 370–381. Dostupné z DOI: [10.1016/S0034-4257\(03\)00121-9](https://doi.org/10.1016/S0034-4257(03)00121-9).
20. SULLIVAN, T. J.; WILLIAMS, P. J. B. Emissivity of natural surfaces and its relationship to surface roughness and temperature. *International Journal of Remote Sensing*. 2000, roč. 21, č. 6, s. 1079–1088. Dostupné z DOI: [10.1080/014311600210133](https://doi.org/10.1080/014311600210133).
21. BARSI, J. A.; SCHOTT, J. R.; HOOK, S. J.; RAQUENO, N. G.; MARKHAM, B. L.; RADOCINSKI, R. G. Landsat-8 thermal infrared sensor (TIRS) vicarious radiometric calibration. *Remote Sensing*. 2014, roč. 6, č. 11, s. 11607–11626. Dostupné z DOI: [10.3390/rs6111607](https://doi.org/10.3390/rs6111607).
22. CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing of Environment*. 2009, roč. 113, č. 5, s. 893–903. Dostupné z DOI: [10.1016/j.rse.2009.01.001](https://doi.org/10.1016/j.rse.2009.01.001).
23. SOBRINO, J. A.; GONZÁLEZ, P. J. T. L.; GARCÍA, S. E. H. A. The use of the temperature-emissivity separation algorithm in the estimation of land surface temperature from Landsat 5 TM data. *Remote Sensing of Environment*. 2004, roč. 92, č. 3, s. 345–353. Dostupné z DOI: [10.1016/j.rse.2004.04.006](https://doi.org/10.1016/j.rse.2004.04.006).
24. INFOPOČASÍ OLOMOUC. *Meteorologická stanice Olomouc – U kovárny*. 2024. Dostupné také z: <https://infopocasi-olomouc.cz/>. Dostupné online [cit. 2025-05-04].

25. SAVITZKY, Abraham; GOLAY, Marcel J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*. 1964, roč. 36, č. 8, s. 1627–1639. Dostupné z DOI: [10.1021/ac60214a047](https://doi.org/10.1021/ac60214a047).
26. PEARSON, Karl. Note on Regression and Inheritance in the Case of Two Parents. *Proceedings of the Royal Society of London*. 1895, roč. 58, s. 240–242. Dostupné z DOI: [10.1098/rspb.1895.0041](https://doi.org/10.1098/rspb.1895.0041).
27. MITCHELL, Melanie. An Introduction to Genetic Algorithms. *MIT Press*. 1996. ISBN 978-0262631853.
28. HOLLAND, John H. Adaptation in Natural and Artificial Systems. *University of Michigan Press*. 1975. ISBN 978-0262581110.
29. GOLDBERG, David E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, 1989. ISBN 978-0201157673.

Seznam obrázků

1.1	Ilustrace znázorňující městské tepelné ostrovy[1]	9
2.1	Družice Landsat 8[10]	13
3.1	Geolokace snímku	16
3.2	Flow chart popisující analýzu snímku	17
3.3	Spektrální otisk[13]	18
3.4	Klasifikovaný povrch	21
3.5	Povrchová teplota	28
4.1	Vývoj teploty jednotlivých povrchů v čase	31
4.2	Závislost teploty na vzdálenosti od vegetace	34
4.3	Definice VIF	37
4.4	Závislost teploty na VIF	38
5.1	A - Před úpravami, B - Navržené úpravy	47

Seznam tabulek

2.1	Spektrální pásma senzorů OLI a TIRS na Landsat 8 a 9[11]	14
3.1	Emisivita různých povrchů[20]	26
4.1	Hodnoty směrnice a pro jednotlivé povrchy	33
4.2	Hodnoty konstanty ν pro jednotlivé typy povrchů	39