

Univerzita Palackého v Olomouci

Přírodovědecká fakulta

Katedra geoinformatiky

**STANOVENÍ PROSTOROVÉ DIFERENCIACE
OBYVATEL OBCE NA ZÁKLADĚ DAT DPZ**

Bakalářská práce

Petra ĎURIANČÍKOVÁ

Vedoucí práce RNDr. Jakub MIŘIJOVSKÝ, Ph.D.

Olomouc 2020

Geoinformatika a geografie

ANOTACE

Bakalářská práce se zabývá sestavením optimálních postupů pro stanovení počtu obyvatel a jejich prostorové diferenciaci v rámci obce či jejích částí na základě dat dálkového průzkumu Země (DPZ). V práci jsou testovány metody DPZ a GIS (geografických informačních systémů), které zahrnují především obrazovou analýzu, analýzu digitálních výškových modelů, spektrální indexy a variace metody Housing Unit.

Postupy jsou sestaveny pro dva hlavní typy dat DPZ: komerční satelitní snímky o velmi vysokém rozlišení v kombinaci s výškovými daty a volně dostupné satelitní snímky. Jako pomocná data jsou využita volně dostupná data z OpenStreetMap (OSM). Dílčím cílem každého postupu je extrakce zástavby. Postupy stanovené jako optimální jsou aplikovány na dvou případových studiích pro města Olomouc a Piešťany, z nichž u první jsou k dispozici komerční data.

Výsledkem práce jsou doporučené postupy pro odhad počtu obyvatel v rámci obce, jejích částí či specifického typu zástavby a samotné odhady počtu obyvatel v rámci případových studií obcí Olomouc a Piešťany. Výsledky práce poslouží pro další experimentální testování dat DPZ pro účely odhadu počtu obyvatel. Doporučí, která data a metody by bylo vhodné dále zkoumat, a které naopak nepřinášejí optimální výsledky.

KLÍČOVÁ SLOVA

DPZ; nDMP; extrakce zástavby, odhad počtu obyvatel

Počet stran práce: 59

Počet příloh: 15 (z toho 2 volné a 13 vázaných)

ANNOTATION

The bachelor thesis deals with the compilation of optimal approaches for determining the number of inhabitants and their spatial differentiation within a municipality or its parts based on remote sensing data. The thesis is testing methods of remote sensing and GIS, that mainly include image analysis, analysis of digital elevation models, spectral indices and variations of the Housing Unit method.

The approaches are compiled for two main types of remote sensing data: very high-resolution commercial satellite images in combination with elevation data and publicly available satellite images. The open OpenStreetMap dataset is used as auxiliary data. A partial goal of each approach is an extraction of buildings. The optimal approaches are applied on two case studies for cities Olomouc and Piešťany, the first of which has commercial data available.

The results of this theses are recommended approaches for population estimation within the municipality, its parts or specific type of housing development and population estimates themselves for the case studies of the municipalities of Olomouc and Piešťany. The results of the thesis will be used for further experimental testing of remote sensing data for the purposes of population estimation. The thesis will recommend which data and methods should be further investigated and which, on the contrary, do not yield optimal results.

KEYWORDS

Remote sensing, nDSM, building extraction, population estimation

Number of pages: 59

Number of appendixes: 15

Prohlašuji, že

- bakalářskou práci včetně příloh, jsem vypracovala samostatně a uvedla jsem všechny použité podklady a literaturu.

- jsem si vědoma, že na moji bakalářskou práci se plně vztahuje zákon č.121/2000 Sb. - autorský zákon, zejména § 35 – využití díla v rámci občanských a náboženských obřadů, v rámci školních představení a využití díla školního a § 60 – školní dílo,

- beru na vědomí, že Univerzita Palackého v Olomouci (dále UP Olomouc) má právo nevýdělečně, ke své vnitřní potřebě, bakalářskou práci užívat (§ 35 odst. 3),

- souhlasím, aby jeden výtisk bakalářské práce byl uložen v Knihovně UP k prezenčnímu nahlédnutí,

- souhlasím, že údaje o mé bakalářské práci budou zveřejněny ve Studijním informačním systému UP,

- v případě zájmu UP Olomouc uzavřu licenční smlouvu s oprávněním užít výsledky a výstupy mé bakalářské práce v rozsahu § 12 odst. 4 autorského zákona,

- použít výsledky a výstupy mé bakalářské práce nebo poskytnout licenci k jejímu využití mohu jen se souhlasem UP Olomouc, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly UP Olomouc na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Olomouci dne

Petra Ďuriančíková

Děkuji vedoucímu práce RNDr. Jakubovi Miřijovskému, Ph.D. za cenné rady, připomínky a čas, který mi během řešení práce věnoval. Dále děkuji doc. RNDr. Jaroslavu Burianovi, Ph.D. a Mgr. Vítu Páztovi, Ph.D. za rady k problematice odhadu počtu obyvatel.

Za poskytnutá data děkuji vedoucímu práce a Katedře geoinformatiky Univerzity Palackého.

Na závěr bych chtěla poděkovat své rodině a přátelům za neustálou podporu.

UNIVERZITA PALACKÉHO V OLOMOUCI

Přírodovědecká fakulta

Akademický rok: 2018/2019

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Petra ĎURIANČÍKOVÁ**
Osobní číslo: **R17443**
Studijní program: **B1301 Geografie**
Studijní obor: **Geoinformatika a geografie**
Téma práce: **Stanovení prostorové diferenciace obyvatel obce na základě dat DPZ**
Zadávající katedra: **Katedra geoinformatiky**

Zásady pro vypracování

Cílem práce je stanovit optimální postupy pro zjištění diferenciace počtu obyvatel v rámci města na základě dat DPZ. Studentka se pokusí stanovit vlastní postupy pro výpočet rozložení obyvatel při využití družicových a leteckých snímků a digitálních modelů povrchu. Studentka využije obrazové analýzy za účelem stanovení typu objektu, digitálních modelů povrchu pro stanovení výšky objektu. Na základě těchto dat přiřadí k nově vzniklým kategoriím počet obyvatel. Výsledky porovná s počty obyvatel na základě adresních bodů. Studentka zpracuje dvě případové studie. První bude lokalizována na město Olomouc, druhá na vybrané zahraniční město, kde použije dostupná data z družicového systému. Výsledkem práce bude zejména doporučený postup pro stanovení počtu obyvatel v jednotlivých částech obce.

Celá práce, tj. text včetně všech příloh, posteru, výstupů, zdrojových i vytvořených dat, map, programových kódů a databází, student odevzdá v digitální podobě na paměťovém nosiči (CD, DVD, SD karta, flash disk) s popisem (jméno, název, KGI, rok). Text práce s přílohami odevzdá ve dvou svázaných výtiscích na sekretariát katedry ve stanoveném termínu. O práci student vytvoří webovou stránku v souladu s pravidly dostupnými na stránkách katedry. Práce bude zpracována podle obecných zásad (Voženílek, 2002) a závazné šablony pro kvalifikační práce na KGI. Povinnou přílohou práce bude poster formátu A2.

Rozsah pracovní zprávy: **max. 50 stran**
Rozsah grafických prací: **dle potřeby**
Forma zpracování bakalářské práce: **tištěná**

Seznam doporučené literatury:

RAPANT, P.: Družicové polohové systémy. VŠB-TU Ostrava, 2002. 200 str.
LILLESAND, T., KIEFER, R., CHIPMAN, J. Remote Sensing and Image Interpretation. John Wiley & Sons, Inc., New York, 756 s., 2008.
CAMPBELL, J., B., WYNNE, R. H. Introduction to Remote Sensing. 5th ed. Guilford Press, New York, 667 s., 2011.
Pavelka, K. (2002). Fotogrammetrie 10, 2.přepřac. vyd. Praha: FSv ČVUT, 198 s.
VOŽENÍLEK, V.: Diplomové práce z geoinformatiky. Olomouc, Univerzita Palackého v Olomouci, 2002. 31 s.

Vedoucí bakalářské práce: **RNDr. Jakub Miřjovský, Ph.D.**
Katedra geoinformatiky

Datum zadání bakalářské práce: 6. května 2019
Termín odevzdání bakalářské práce: 6. května 2020

L.S.

doc. RNDr. Martin Kubala, Ph.D.
děkan



prof. RNDr. Vít Voženílek, CSc.
vedoucí katedry

V Olomouci dne 2. září 2019

OBSAH

SEZNAM POUŽITÝCH ZKRATEK	10
ÚVOD	11
1 CÍLE PRÁCE.....	12
2 METODY A POSTUPY ZPRACOVÁNÍ.....	13
2.1 Použité metody	13
2.1.1 Metody DPZ	13
2.1.2 Metody GIS	13
2.1.3 Metoda Housing Unit	13
2.1.4 Agregace	14
2.2 Zájmové území.....	14
2.3 Použitá data	14
2.3.1 Satelitní snímky	14
2.3.2 Digitální modely	15
2.3.3 Adresní body.....	15
2.3.4 Volně dostupná data	15
2.4 Použité programy	15
2.5 Postup zpracování.....	16
3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY	17
3.1 Údaje o počtu obyvatel	17
3.1.1 Údaje o počtu obyvatel v Česku	17
3.1.2 Údaje o počtu obyvatel ve světě.....	17
3.2 Metody pro odhad počtu obyvatel	18
3.2.1 Dasymetrická metoda.....	18
3.2.2 Statistické modelování	19
3.2.3 Metoda Housing unit.....	19
3.3 Práce zabývající se řešenou problematikou	19
3.3.1 Historie.....	19
3.3.2 Současnost	20
4 PŘEDZPRACOVÁNÍ DAT	25
4.1 Pan-sharpening	25
4.2 Převzorkování	27
4.3 Digitální modely.....	27
4.3.1 Normalizace	27
4.3.2 Generování DMP a DMR z bodového mračna.....	27
5 EXTRAKCE ZÁSTAVBY.....	29
5.1 Postup I: Obrazová klasifikace.....	29
5.1.1 Neřízená klasifikace	29
5.1.2 Řízená klasifikace.....	29
5.2 Postup II: Analýzy nDMP.....	34
5.2.1 Odstranění vysoké vegetace	34
5.2.2 Detekce zástavby.....	36

5.2.3	Postprocessing	37
5.2.4	Stanovení obytných budov dle OSM	42
5.3	Postup III: Spektrální indexy	42
5.3.1	Stanovení obytných budov dle OSM	46
6	ODHAD POČTU OBYVATEL.....	48
6.1	Část obce	49
6.2	Obec.....	50
6.2.1	Agregace dat	51
6.3	Korelační analýza.....	52
7	VÝSLEDKY	54
7.1	Případová studie I: Olomouc	54
7.1.1	Postup I: Obrazová klasifikace	54
7.1.2	Postup II: Analýzy nDMP	54
7.1.3	Postup III: Spektrální indexy	55
7.2	Případová studie II: Piešťany	56
8	DISKUZE	57
9	ZÁVĚR	59
	POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE	
	PŘÍLOHY	

SEZNAM POUŽITÝCH ZKRATEK

Zkratka	Význam
BSI	Bare Soil Index
ČSÚ	Český statistický úřad
ČÚZK	Český úřad zeměměřický a katastrální
ESA	European Space Agency
DMP	digitální model povrchu
DMP 1G	digitální model povrchu 1. generace
DMR	digitální model reliéfu
DMR 5G	digitální model reliéfu 5. generace
DPZ	dálkový průzkum Země
ESRI	Environmental System Research Institute
GHS	Global Human Settlement
GIS	geografický informační systém
LiDAR	Light Detection And Ranging
ML	Maximum Likelihood
MNDWI	Modified Normalized Difference Water Index
nDMP	normalizovaný digitální model povrchu
NDBI	Normalized Difference Built-up Index
NDI	Normalized Difference Index
NDVI	Normalized Difference Vegetation Index
NIR	Near Infra Red
OBIA	Object-oriented Image Analysis
OSM	OpenStreetMap
PU	přesnost z hlediska uživatele
PZ	přesnost z hlediska zpracovatele
RGB	Red Green Blue
RMSE	Root Mean Square Error
RT	Random Trees
SLDB	Sčítání lidu, domů a bytů
SVM	Support Vector Machine
SWIR	Short Wave Infra Red
VHR	Very High Resolution

ÚVOD

Je pohodlné zaměřit se pouze na sebe a na to, co je před námi. Je ale třeba si uvědomit, že kolem nás je celý svět plný dalších lidí. Lidé jsou svět, společnost, město, domov. Lidé tvoří svět lepším místem a zároveň jsou silou, která ho nejvíce ničí.

Data o lidech se stávají jedněmi z těch nejdůležitějších. Informace o počtu obyvatel a jejich rozmístění jsou nezbytné pro veškeré rozhodovací procesy v rámci státní a městské správy, i pro svět jako takový. I přes to jsou ale sčítání lidu prováděna v mnoha zemích standardně pouze každých 10 let. Tato data je ale nutné aktualizovat pravidelně v kratších intervalech, jelikož se jedná o stěžejní faktory pro krizový management i územní plánování.

DPZ nabízí obrovský potenciál pro zjišťování počtu obyvatel a jejich prostorového rozmístění. Metody DPZ jsou řádově mnohem rychlejší a méně náročné na prostředky než standardní sčítání lidu. DPZ je v současné době jedním z nejrychleji se rozvíjejících odvětví, jehož data se stále zlepšují jak z pohledu kvality, tak pokrytí. Se zlepšujícími se softwary a daty je nutné stále testovat možné využití dat DPZ pro odhady počtu obyvatel. Dosud nebylo možné sčítáním lidu konkurovat. Data DPZ ale tento potenciál jistě mají. Přesnost metod a dat DPZ pro odhady počtu obyvatel je nutné zkoumat a dále vylepšovat, aby bylo v budoucnu možné tyto metody reálně používat v praxi pro získávání dat o počtu obyvatel, která budou aktuálnější a rychleji dostupná.

Bakalářská práce byla vypracována v rámci projektu VaV MK ČR DG16P02B014 Kulturní dědictví krajiny Arcidiecéze olomoucké – výzkum, prezentace a management.

1 CÍLE PRÁCE

Cílem práce je stanovit optimální postupy pro zjištění diferenciaci počtu obyvatel v rámci města na základě dat DPZ. Při využití družicových a leteckých snímků a digitálních modelů povrchu je záměrem vytvořit vhodné postupy pro výpočet rozložení obyvatel. Počty obyvatel budou přiřazovány na základě typu a výšky objektu. Výsledky budou statisticky zhodnoceny vzhledem k referenčním datům. Budou zpracovány dvě případové studie, z nichž první bude lokalizována na město Olomouc, druhá na město Piešťany. V případě druhé případové studie budou využity volně dostupné satelitní snímky.

Hlavní cíl práce je řešen v posloupnosti několika dílčích cílů:

- předzpracování dat,
- stanovení postupů pro extrakci zástavby,
- stanovení postupů pro výpočet obyvatel,
- aplikace na případových studiích,
- statistické zhodnocení.

Optimálním postupem je ten, který kombinuje nízké náklady a vysokou automatizaci při získání co nejpřesnějšího počtu obyvatel. Řešení vychází především z obrazových analýz, analýz normalizovaného digitálního modelu povrchu (nDMP) a variací metody Housing Unit.

Pro případovou studii Olomouce jsou využity následující kombinace dat:

- satelitní snímek QuickBird, nDMP o rozlišení 0,6 m/px, OSM,
- satelitní snímek QuickBird, nDMP o rozlišení 2 m/px, OSM,
- volně dostupný satelitní snímek Sentinel-2A, OSM.

Pro statistické zhodnocení přesnosti stanovení počtu obyvatel jsou využity adresní body s přiřazenými počty obyvatel dle sčítání lidu, domů a bytů (SLDB) 2011.

Pro případovou studii Piešťan je využit volně dostupný družicový snímek Sentinel-2A a pomocná data OSM. Pro statistické zhodnocení přesnosti stanovení počtu obyvatel je využit volně dostupný dataset Evropské komise Global Human Settlement (GHS) Population grid za rok 2015.

Výsledkem práce jsou nejvhodnější postupy pro stanovení počtu obyvatel obce či jejich částí na základě dat DPZ či kombinací dat DPZ s volně dostupnými daty z OSM. Výsledné optimální postupy určí, do jaké míry jsou metody stanovení počtu obyvatel na základě dat DPZ přesné a vypovídající, a jak je lze k odhadu počtu obyvatel využívat. Práce poslouží pro další experimentální testování dat DPZ pro účely stanovení počtu obyvatel. Doporučí, která data a metody by bylo vhodné dále zkoumat, a které naopak nepřinášejí optimální výsledky.

2 METODY A POSTUPY ZPRACOVÁNÍ

2.1 Použité metody

2.1.1 Metody DPZ

Pan-sharpening je nahrazení jasové složky multispektrálního snímku daty z pan-chromatického snímku, který má vyšší rozlišení, přičemž vzniká multispektrální snímek s rozlišením panchromatického (Dobrovolný, 1998).

Cloth Simulation Filter (CSF) je plugin v softwaru CloudCompare. Jedná se o nástroj pro automatickou klasifikaci bodového mračka na body, které se nacházejí na reliéfu (ground) a ostatní body (non-ground) (Zhang a kol., 2016). Z bodů „ground“ lze vytvořit DMR.

Obrazová klasifikace je proces třídění obrazových bodů do konečného počtu tříd na základě rozhodovacích pravidel – klasifikátorů. Základem **řízené klasifikace** jsou trénovací data – výběr reprezentativních pixelů pro každou informační třídu, která byla definována klasifikačním schématem (Dobrovolný, 1998). Při **neřízené klasifikaci** jsou pixely zařazeny do tříd na základě shlukové analýzy – není třeba vytvářet trénovací data. **Per-pixel klasifikace** je metoda přiřazování informací jednotlivým pixelům v obraze, kdy se klasifikátory zaměřují především na porovnávání spektrálních hodnot pixelů s trénovacími daty (Dobrovolný, 1998). **Objektově orientovaná klasifikace** se snaží o napodobení vizuální interpretace obrazu člověkem (Blaschke a kol., 2014). Klasifikátory zohledňují nejen spektrální hodnoty segmentů, ale také např. jejich tvar či velikost. Prvním krokem objektově orientované klasifikace je **segmentace** – automatický proces rozdělení obrazu na prostorově souvislé objekty podobné realitě (stromy, budovy) (Blaschke a kol., 2014).

Spektrální indexy jsou kombinace hodnot spektrální odrazivosti snímku ze dvou nebo více spektrálních pásem, které lze vyjádřit jako matematické rovnice (Lillesand a kol., 2008). Používají se pro zvýraznění určitých prvků na snímku, jako je např. vegetace, voda nebo zástavba.

2.1.2 Metody GIS

Použité metody GIS se týkají především analytických, numerických a konverzních operací s daty v softwaru ArcGIS Pro. Byly využívány především nástroje rasterizace a vektorizace, reklasifikace, *Raster Calculator*, *Regularize Building Footprint* či *Summarize Within* a numerické operace.

2.1.3 Metoda Housing Unit


Metoda pro odhad počtu obyvatel pro malá území, která předpokládá, že každý člověk žije v určitém typu obytné zástavby (Wu a Murray, 2007). Počet obyvatel území je definován jako počet obydlených bytových jednotek nebo domácností vynásobených průměrným počtem osob na domácnost s přičtením počtu osob žijících v hromadných ubytovacích zařízeních (Rayer, 2015). V práci byla využita variace této metody, kdy bylo pracováno s průměrnou plochou jednoho bytu daného typu zástavby a průměrným počtem osob na tento byt.

2.1.4 Agregace

Metoda byla využita pro vizualizaci prostorové diferenciace obyvatel obce. Agregace je nejjednodušší metoda pro přiřazování statistických informací buňkám pravidelné polygonové sítě. Je založena na přesně adresně lokalizovaných datech (např. na základě údajů ze sčítání lidu) (Klauda, 2016).

2.2 Zájmové území

První případová studie je zaměřena na území Olomouce a blízkého okolí, které odpovídá pokrytí poskytnutého snímku QuickBird. Území zaujímá přibližně 70,4 km². Druhá případová studie je zaměřena na území slovenského města Piešťany. Zájmové území odpovídá hranicím obce a zaujímá přibližně 44,2 km². Vymezení zájmových území lze sledovat na obrázku 1.



Obr. 1 Vymezení zájmových území.

2.3 Použitá data

2.3.1 Satelitní snímky

Pro případovou studii města Olomouce byl Katedrou geoinformatiky UP zapůjčen satelitní snímek **QuickBird** z roku 2012 zobrazující město Olomouc. Jedná se o komerční produkt firmy Digital Globe. QuickBird se řadí mezi družice s velmi vysokým rozlišením (VHR). Prostorové rozlišení v panchromatickém pásmu je 0,6 m/px, v multispektrálním 2,4 m/px. Snímá v pásmech viditelného spektra (RGB) a blízkém infračerveném (NIR).

Dále byly využity volně dostupné snímky družice **Sentinel-2A**. Sentinel 2 je mise evropského programu Copernicus, která volně poskytuje snímky s vysokým rozlišením.

Sentinel-2A snímá celkem ve 13 spektrálních pásmech. Prostorové rozlišení se liší v závislosti na pásmu. RGB a NIR pásma mají rozlišení 10 m/px, zatímco dalších šest pásem pouze 20 m/px. Tři pásma (B1, B9 a B10) jsou v rozlišení 60 m/px. Snímky level-2A pro území Olomouce a Piešťan byly získány z oficiálního portálu Copernicus Open Acces Hub. Level-2A produkty již obsahují atmosférické korekce, které proběhly pomocí procesoru Sen2Cor (ESA, 2020). Snímek pro území Olomouce pochází z 30. 6. 2019, snímek pro území Piešťan z 25. 10. 2019.

2.3.2 Digitální modely

Pro případovou studii města Olomouce byly využity **digitální model povrchu 1. generace (DMP 1G)** a **digitální model reliéfu 5. generace (DMR 5G)**. Oba produkty nabízejí rozlišení 2 m/px a vznikly z dat pořízených metodou leteckého laserového skenování výškopisu ČR v letech 2009 až 2013. Digitální modely pro území Olomouce vznikly v roce 2013 při skenování pásma Východ (Dušánek, 2014).

Vedoucím práce bylo poskytnuto **bodové mračno** ve formátu LAS vygenerované na základě leteckých snímků Olomouce z roku 2016, ze kterého byly vytvořeny DMP a DMR. Pokryté území je o něco menší než v případě snímku QuickBird. Z tohoto důvodu se skutečný počet obyvatel v Příloze 6 mezi výstupními vrstvami liší o 164 obyvatel. Bodové mračno bylo vedoucím práce vygenerováno v softwaru Agisoft Metashape při hustotě bodů stanovené na *Medium*.

2.3.3 Adresní body

Vrstva adresních bodů s přiřazenými počty obyvatel dle SLDB 2011 byla poskytnuta katedrou geoinformatiky UP, která data zakoupila od Českého statistického úřadu (ČSÚ). Vrstva je platná k 1. 7. 2016 a je označována jako „Statistické budovy (vchody k bytům)“. Relevantními atributy pro bakalářskou práci byly především prostorová lokalizace budov a počet obvykle bydlících obyvatel na adresní bod (BUDOBYSL).

2.3.4 Volně dostupná data

Pro statistické zhodnocení přesnosti postupů v případě práce se snímky Sentinel-2A byl použit **GHS Population Grid** za rok 2015, který volně poskytuje Evropská komise. Jedná se o rastrovou vrstvu o straně buňky 250 m. Každá buňka obsahuje počet obyvatel, který byl do gridové sítě agregován na základě údajů ze sčítání lidu a hustoty zástavby (Florczyk a kol., 2019). Jako pomocná data byly využity vrstvy získané z **OSM**: budovy, silnice, železnice, řeky a využití území.

2.4 Použité programy

ArcGIS Pro

Verze 2.5 byla využita pro obrazovou klasifikaci, extrakci budov, analýzy nad nDMP, výpočet obyvatel i statistické vyhodnocení. Pokud není v textu uvedeno jinak, byl vždy využit tento software.

QGIS

Verze 3.10.2 byla využita pro import dat z OSM pomocí pluginu QuickOSM.

Envi

Zkušební 30denní verze 5.5.3 byla testována pro řízenou klasifikaci snímku QuickBird.

CloudCompare

Verze 2.10.2 byla využita pro klasifikaci bodového mračna na body „ground“ a „non-ground“ pomocí pluginu CSF.

RStudio

Verze 1.3.959 byla využita pro výpočet korelace mezi charakteristikami rezidenčních budov a skutečným počtem obyvatel dle SLDB 2011.

SNAP


Verze 7.0.0 byla využita pro předzpracování snímků družice Sentinel-2A.

Adobe Illustrator

Týdenní zkušební verze CC 2020 byla využita za účelem tvorby grafických výstupů.

2.5 Postup zpracování

Postup zpracování bakalářské práce odpovídá vytýčeným dílčím cílům. Nejprve byla provedena rešerše současného stavu řešené problematiky, poté předzpracování dat, testování postupů pro extrakci zástavby a odhad počtu obyvatel, aplikace na případových studiích a statistické zhodnocení vzhledem k referenčním datům. Jednotlivé kroky zpracování znázorněné na obrázku 2 jsou popsány dále v kapitolách 4, 5 a 6.



Obr. 2 Vývojový diagram postupu zpracování.

3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

Metody DPZ poskytují alternativu k metodám sčítání lidu, které jsou náročné jak z hlediska časového, tak z hlediska prostředků potřebných pro jejich vykonávání. DPZ je v současné době rychle se rozvíjejícím odvětvím, které se dostává do povědomí stále širšího okruhu odborné i laické veřejnosti. Družicové snímky nacházejí stále větší uplatnění v nejrůznějších aplikacích a jejich uživatelská základna roste. Příčinou tohoto rychlého rozvoje jsou především výhody, které DPZ má oproti klasickému mapování a stále se zlepšující prostorové rozlišení družicových snímků. Mezi výhody DPZ můžeme zařadit zejména nižší finanční náklady, rychlost či operativnost (Dobrovolný, 1998).

3.1 Údaje o počtu obyvatel

Ačkoliv jsou údaje o počtu obyvatel nezbytné pro celou řadu rozhodovacích procesů, sčítání lidu jsou standardně prováděna jen každých pět či deset let (Rao, 2003). Data o počtu obyvatel ale musí být pravidelně aktualizována v kratších intervalech, aby vyhovovala požadavkům územního plánování či krizového managementu. Proto jsou nutné odhady počtu obyvatel.

Demografové považují informace o počtu obyvatel, které nejsou založeny na sčítání lidu či registru obyvatel, za odhady. Populační odhady hrají klíčovou roli v mnoha odvětvích jako je analýza trhu, územní plánování či alokace zdrojů a poptávka po nich v současné době roste (Rayer, 2015).

Pro odhady počtu obyvatel rozlohou velkých území jsou typické demografické a ekonomické přístupy, které tento počet zjišťují pomocí nejaktuálnějších dat ze sčítání lidu, k nim přidají počty narozených, data o migraci a odečtou počty zemřelých a data o emigraci (Wu a Murray, 2007). Tato práce je ale zaměřena na odhady v malém měřítku. Malá území pro odhad počtu obyvatel lze definovat jako správní jednotky pod státní úrovní. Příkladem mohou být okresy, města, obce či sčítací obvody. Tato území se mohou výrazně lišit jak velikostí, tak počtem obyvatel (Rao, 2003).

3.1.1 Údaje o počtu obyvatel v Česku

Sčítání lidu a registr obyvatel jsou základními zdroji dat o počtu obyvatel Česka. Sčítání lidu je zde spojeno se zjišťováním údajů o domech a bytech, proto se používá termín sčítání lidu, domů a bytů. SLDB je vždy prováděno na základě příslušného zákona. Hlavním odpovědným orgánem je ČSÚ. Data jsou kombinací dvou primárních zdrojů: údajů z administrativních registrů a ze sčítacích formulářů (ČSÚ, 2015).

V práci byly údaje ze SLDB 2011 v rámci adresních bodů využity jak pro validaci výsledků, tak pro stanovení postupů pro odhad počtu obyvatel. Bylo vycházeno z počtu obvykle bydlícího obyvatelstva, nikoliv z trvale bydlícího. Místo obvyklého pobytu osoby je definováno jako místo, kde osoba obvykle tráví období svého každodenního odpočinku a kde je členem konkrétní domácnosti (ČSÚ, 2015). Pro odvození místa je určující faktické bydliště osoby v rozhodný okamžik sčítání (ČSÚ, 2015). Tento ukazatel byl vybrán z důvodu jeho promítnutí do všech okruhů zpracovaných dat v rámci SLDB, jako je např. určení obydlenosti bytu a také vzhledem k jeho vyšší vypovídající hodnotě v porovnání s trvalým pobytem, kdy může člověk ve skutečnosti bydlet na jiném místě.

3.1.2 Údaje o počtu obyvatel ve světě

Pro další země a světovou populaci existuje více volně dostupných zdrojů dat, které lze využít pro odhady počtu obyvatel a jejich validaci. Mezi nejvýznamnější poskytovatele

patří Evropská komise, Statistická divize Organizace spojených národů (OSN) a Americký úřad pro sčítání lidu.

Evropská komise poskytuje GHS Population grid. Jedná se o rastrovou vrstvu zobrazující prostorovou distribuci světové populace jako počet obyvatel na jednu buňku o straně 250 m nebo 1 km. GHS Population grid je dostupný pro roky 1975, 1990, 2000 a 2015. Počty obyvatel z dat CIESIN Gridded Population of the World verze 4.10 byly disagregovány z administrativních jednotek do buňek gridu za pomoci dat o distribuci zástavby z GHS Layer (Florczyk a kol., 2019). V práci byl využit tento zdroj dat, jelikož poskytuje nejpodrobnější informace o počtu obyvatel.

V rámci Eurostatu poskytuje Evropská komise data o počtu obyvatel přepočtená na grid o velikosti buňky 1 km². Toto měřítko je ovšem nevhodné pro odhady počtu obyvatel v rámci obcí, a to především těch, které svou velikostí odpovídají českým obcím. Dále poskytuje údaje získané ze sčítání lidu za jednotlivé země Evropské unie, v některých případech až do úrovně NUTS 2. V těchto datech se nevyskytují údaje o průměrné obydlivosti či velikosti bytů, ani údaje, dle kterých by tyto faktory bylo možné spočítat. Dále mají nedostatečnou podrobnost pro aplikaci na konkrétní obce.

Statistická divize OSN poskytuje data získaná z národních statistických úřadů všech zemí světa od roku 1995 do současnosti v rámci demografických ročenek. K dispozici jsou ekonomické a etnické charakteristiky obyvatelstva, dále informace o vzdělání, domácnostech a migraci (United Nations, 2020). V rámci charakteristik domácností jsou k dispozici i počty domácností dle jejich velikosti. Data jsou poskytována v rámci jednotlivých zemí. Statistická divize OSN vytváří také odhady a projekce počtu obyvatel, které každoročně zveřejňuje v tzv. perspektivách světové populace (United Nations, 2020).

Americký úřad pro sčítání lidu poskytuje v rámci mezinárodní databáze údaje o počtech obyvatel zemí světa, včetně projekcí, údajů o narozených a zemřelých a hustoty obyvatel. Tyto údaje jsou k dispozici pouze pro celé země.

3.2 Metody pro odhad počtu obyvatel

V práci Wu a kol. (2005) jsou shrnuty zásadní metody pro odhad počtu obyvatel na základě dat DPZ či GIS, které jsou rozděleny do dvou kategorií – na plošnou interpolaci a statistické modelování.

Metody plošné interpolace jsou užívány především v případě, kdy jsou k dispozici data o počtu obyvatel pro jinou plošnou jednotku, než je požadováno. Z tohoto důvodu nebylo těchto metod v práci využito pro odhad počtu obyvatel, pouze pro jeho vizualizaci nad gridovou sítí. Pro přepočet obyvatel se využívá především metod agregace, disagregace či interpolace. Dle Wu a kol. (2005) je nejvíce používaným, nejjednodušším a také nejstabilnějším přístupem dasymetrická metoda.

3.2.1 Dasymetrická metoda

Dasymetrická metoda se řadí mezi kartografické metody plošných znaků pro znázornění relativních hodnot. Na rozdíl od metody kartogramu vznikají plochy až na základě vyhodnocení prostorového rozložení jevu, nikoliv předem (Voženílek a Kaňok, 2011). Dle práce Fishera a Langforda (1996) také metoda není náchylná k chybám vzniklým při klasifikaci satelitních snímků. Dasymetrickým mapováním obyvatelstva se zabýval ve své práci Kolařík (2012), který rozdělil zkoumané území na pět kategorií, kdy každé byla následně přiřazena váha na základě průměrné hustoty zalidnění. Testováním disagregačních metod pro přepočet hustoty zalidnění a počtu obyvatel se zabýval také Zapletal (2019), dle kterého je pro přepočet obyvatel nejvhodnější

disagregace s využitím pomocných dat – konkrétně využití kombinace obytných adresních bodů a počtu podlaží obytných budov vážených způsobem využití budovy.

V rámci dasymetrické metody je nejčastěji využíván binární přístup pro svou jednoduchost. Nevýhodou jsou ale problémy při rozpoznávání rozdílů v distribuci obyvatel v jednotlivých rezidenčních zónách. Při identifikaci rozdílů mezi těmito zónami naopak k problémům nedochází (Wu a kol., 2005). Zájmové území je v případě binárního přístupu klasifikováno na plochy obydlené a neobydlené. Počty obyvatel dle sčítání lidu jsou poté rozděleny do obydlených ploch. Studii využívající tuto metodu zpracovali také Holt a kol. (2004).

3.2.2 Statistické modelování

Metody statistického modelování lze rozdělit na pět kategorií, které jsou založeny na vztazích mezi populací a: (1) městskými oblastmi, (2) využitím půdy, (3) rezidenčními budovami, (4) charakteristikami obrazových pixelů a (5) dalšími fyzickými nebo socioekonomickými ukazateli (Wu a kol., 2005). Vztahy jsou modelovány především pomocí regresní či korelační analýzy. V práci byla testována korelace mezi počtem obyvatel dle referenčních dat a charakteristikami rezidenčních budov, které byly získány na základě dat DPZ.

3.2.3 Metoda Housing unit

Pro odhad počtu obyvatel pro malá území se běžně používá metoda *Housing unit* či její variace (Wu a Murray, 2007). Tato metoda předpokládá, že každý člověk žije v určitém typu obytné zástavby. Počet obyvatel území je definován jako počet obydlených bytových jednotek nebo domácností vynásobených průměrným počtem osob na domácnost s přičtením počtu osob žijících v hromadných ubytovacích zařízeních (např. koleje, pečovatelské domy) (Rayer, 2015).

Z variace této metody bylo vycházeno také v této práci, jelikož je vhodná pro malá zájmová území a bylo předpokládáno, že pomocí ní lze dosáhnout nejpresnějších výsledků. Počet obyvatel byl odhadován na základě typu obytné zástavby. Průměrná plocha jednoho bytu pro daný typ zástavby byla násobena průměrným počtem osob na jeden byt.

3.3 Práce zabývající se řešenou problematikou

3.3.1 Historie

Odhady počtu obyvatel na základě metod a dat DPZ se rozvíjely od 50. let 20. století, kdy byly jednotlivé domy či bytové jednotky manuálně počítány z leteckých fotografií. Přestože byly takto odhadované počty obyvatel relativně přesné, manuální přístup je časově náročný, a to značně komplikuje jeho aplikace na větší městské oblasti (Wu a Murray, 2007). Pro studium městského obyvatelstva různých zemí byla družicová data poprvé využita Toblerem (1969), který uvažoval, že město má kruhový tvar. Pomocí satelitních snímků družice Gemini byly změřeny poloměry daných měst a zjištěna silná statistická korelace mezi těmito poloměry a počtem obyvatel. Korelační koeficienty v rámci relevantních pozorování se pohybovaly mezi hodnotami 0,87 pro anglická města až po 0,987 pro města provincie Ontario v USA. Pro egyptská města ale metoda vykazovala vysoké nepřesnosti a do práce nebyla zahrnuta. V práci Isaky a Hegeduse (1982) byly využity přímo hodnoty pixelů pro stanovení hustoty zalidnění. Průměrné

spektrální hodnoty pásem 4, 6 a 7 snímků družice Landsat MSS vykazovaly korelaci s hustotou zalidnění Tokya.

Dle práce Lo (1986) byly rozlišovány čtyři hlavní přístupy pro odhad počtu obyvatel dle snímků DPZ na základě:

1. počtu obydlených jednotek,
2. měření velikosti urbanizovaných oblastí,
3. měření obydlených ploch stanovených na základě využití území,
4. automatizované analýzy digitálního obrazu.

První tři přístupy byly v minulosti dlouho využívány pro vizuální interpretaci analogových leteckých snímků v různých měřítcích. Automatizované postupy pro odhady počtu obyvatel z dat DPZ se začaly rozvíjet na konci 90. let. Tyto přístupy extrahují z dat DPZ dva hlavní typy ukazatelů, a to spektrální odrazivost a klasifikaci využití území.


3.3.2 Současnost

S vypuštěním komerčních družic o velmi vysokém rozlišení, jako jsou IKONOS nebo QuickBird (obr. 3), které tuto etapu odstartovaly, dochází ke zpřesňování populačních odhadů. Prostorové rozlišení udává nejmenší objekt, který lze na snímku rozpoznat. Je dáno velikostí pixelu, která je základní jednotkou digitálního obrazu (Dobrovolný, 1998). Jako družice s velmi vysokým rozlišením se označují ty, které snímají s prostorovým rozlišením menším než jeden metr. V současné době se jedná mimo zmíněných také o World-View 1 a 2, GeoEye-1, Pléiades a další. Spektrální rozlišení udává šířku intervalu vlnových délek (pásma), ve kterých senzor snímá (Dobrovolný, 1998). Spektrální rozlišení je neméně důležité, jelikož umožňuje využití spektrálních indexů či vhodných pásem pro automatickou klasifikaci zástavby. Díky velmi vysokému rozlišení lze snímky využívat pro extrakci zastavěného území či přímo pro detekci jednotlivých budov. Všechny tyto družice jsou ale komerční, což umožňuje využití jejich snímků pro odhady obyvatel pouze omezenému počtu uživatelů.



Obr. 3 Detail snímku družice QuickBird na centrum města Olomouc (zdroj: KGI UP, Digital Globe).

Mezi volně dostupná data s vysokým rozlišením patří snímky družic Sentinel-2A a Landsat 7 či 8. Sentinel-2A snímá v pásmech RGB a NIR v prostorovém rozlišení 10 m. Nabízí 13 spektrálních pásem. Landsat 7 snímá v panchromatickém pásmu v rozlišení 15 m a nabízí pouze 8 spektrálních pásem. Vzhledem k vyššímu prostorovému i spektrálnímu rozlišení byly v práci využity snímky družice Sentinel-2A (obr. 4).



Obr. 4 Detail snímku družice Sentinel-2A na centrum města Olomouc (zdroj: ESA).

Proces automatické detekce budov ze satelitních snímků je umožněn také pokrokem v technikách zpracování obrazu, především v automatické detekci a extrakci prvků. Široce využívanou technologií je také LiDAR (Light Detection and Ranging). Data takto získaná slouží primárně pro odvozování výšky budov (Wu a kol., 2005).

LiDAR je technologie využívající laserového záření pro měření výšky terénu. K tomuto používá čas, za který se puls laserového záření vrátí od povrchu zpět do senzoru (Lillesand a kol., 2008). Získání dat z LiDAR je však spojeno s vysokými náklady. Alternativou jsou DMP, veřejně dostupné nebo vygenerované na základě satelitních či leteckých snímků. DMP představuje digitální reprezentaci krajiny včetně veškerých umělých a přírodních objektů, jako je krajinný pokryv a stavby (VÚGTK, 2020). V aplikacích pro odhad počtu obyvatel jsou nejvíce využívány normalizované DMP (nDMP), vzniklé odečtením DMR od DMP. Takto vygenerovaný digitální model reprezentuje skutečné výšky budov a ostatních prvků od zemského povrchu (Steinnocher a kol., 2019).

Byla publikována řada výzkumů na téma odhadu počtu obyvatel na základě výškových dat, přístupů statistického modelování, dasymetrického mapování, či agregace a disagregace dostupných dat.

Práce Lu a kol. (2010) byla založena na snímku QuickBird a výškových datech LiDAR. Odhad počtu obyvatel na základě plochy a objemu budov byl realizován na úrovni sčítacích obvodů města Denver. Obrysy obytné zástavby byly extrahovány pomocí objektově orientované klasifikace rozhodovacích stromů třemi způsoby: pouze ze satelitních snímků, pouze z dat LiDAR a z kombinace obou zdrojů. Zatímco extrakce

budov na základě satelitního snímku vykazovala Kappa koeficient 0,709, LiDAR a kombinace obou zdrojů dat vedla ke zpřesnění Kappa koeficientu na 0,88. K modelaci vztahu mezi obyvatelstvem a rozlohou či objemem vymezených budov byla použita regresní analýza. Pro odhad počtu obyvatel zde byl přesnější přístup, který počítal pouze s rozlohou, jelikož se v zájmovém území nacházely především samostatné rodinné domy o jednom podlaží. RMSE (Root Mean Square Error) počtu obyvatel se pohybovalo mezi 10 a 30, což lze považovat za přesný výsledek. Je ovšem nutné zmínit, že zájmové území bylo, co se týče typu zástavby, značně homogenní a klasifikační schéma objektově orientované klasifikace mohlo sestávat pouze ze dvou tříd – rezidenční budovy a ostatní.

Práce Alahmadiho a kol. (2013) je zaměřena na odhad počtu obyvatel pro Um Alhamam, část Rijádu. Toto zájmové území již není homogenní, jelikož obsahuje různé typy zástavby od vil až po paláce. K dispozici byla data ze sčítání lidu za jednotlivé wardy (územní jednotky). Cílem této práce bylo tyto počty obyvatel disagregovat na jednotlivé parcely. Pro extrakci budov ze snímku Landsat ETM+ byly využity klasifikační algoritmy ISODATA a Support Vector Machine (SVM). Byly definovány čtyři klasifikační třídy: zástavba, asfalt, vegetace a holá půda. Kappa koeficient neřízené klasifikace ISODATA dosahoval 0,66, zatímco v případě řízené klasifikace SVM se zvýšil na 0,75. Dále byly využity údaje o výšce získané z nDMP. Autoři určili, že rezidenční budova musí mít minimálně 4,8 m. Pro modelaci vztahu mezi zástavbou a počtem obyvatel byla využita regresní analýza, ze které vzniklo sedm modelů. V případě, kdy byly ze zástavby vyloučeny budovy menší než 4,8 m se RMSE počtu obyvatel snížila z 16,2 na 4,9. V novější studii Alahmadiho a kol. (2016) pro stejné zájmové území byla výšková data využita nejen za účelem stanovení počtu podlaží, ale také pro klasifikaci zástavby na různé typy.

V bakalářské práci bylo vycházeno z podobného principu, kdy byla zástavba do stanovené výšky vyloučena z dalších operací. Dále byl také testován způsob, kdy byly budovy na základě výšky rozděleny na různé typy. Na rozdíl od předchozích studií ale nebyla k odhadu počtu obyvatel použita regresní analýza. Proto je těžké srovnávat přesnost odhadů, jelikož v bakalářské práci je počítáno s procentními odchylkami od skutečného počtu obyvatel, zatímco ve zmíněných studiích byla pro stanovení přesnosti použita RMSE.

Ve studii Gua a kol. (2017) byla použita pouze volně dostupná satelitní data Google Earth a doplňující data o budovách z OSM. Zájmovým územím byla malá část West Coast v Singapuru. Budovy byly extrahovány s celkovou přesností 95 %. Pro stanovení výšky budov byla použita délka stínů, které budovy vrhají. V práci ovšem není zmíněno, zda a do jaké míry je takto získaná výška přesná. Pro odhad počtu obyvatel byla použita metoda Housing Unit pro dva typy obytné zástavby pomocí vynásobení počtu bytů v budově, hustoty obyvatel a obydlenosti. Z popisu autorů avšak není jasný zdroj informací o hustotě obyvatel či obydlenosti ani přesná čísla. Odhad počtu obyvatel pro celé zájmové území dosahuje přesnosti 92,5 %. Jedná se o velmi malé území a s ohledem na nahrazení většiny budov daty z OSM se dá takto vysoká přesnost očekávat.

Pomocná data z OSM byla využita také v bakalářské práci pro odlišení rezidenčních budov od zbytku zástavby, či pro odstranění ostatních staveb v případě použití snímku Sentinel-2A. V případě, kdy nebyla k dispozici výšková data, nebylo přistoupeno k odvození výšky na základě délky stínů. Vzhledem k prostorovému rozlišení snímku Sentinel-2A a spektrálnímu chování stínů by bylo značně komplikované je klasifikovat.

Práce Vigneshwarana a Vasanthy (2018) je zaměřena na extrakci zastavěného území ze snímků Sentinel-2A. Byl stanoven normalizovaný diferenční index NDI, který je založen

na pásmech 2 (Blue) a 8 (NIR), jejichž prostorové rozlišení je 10 m. Dle autorů je zástavba nejlépe odlišitelná, pokud se hodnoty indexu pohybují mezi -0,29 a 0,09. Hodnota Kappa koeficientu bez jakýchkoli úprav byla 0,54. Pokud by byla předem ze snímku extrahována např. vegetace či voda, lze předpokládat, že by se přesnost indexu zvýšila. Pokud byla do procesu zakomponována také manuální editace dle snímku Google Earth, hodnota Kappa koeficientu se zvýšila na 0,785. V bakalářské práci byl tento index testován na snímku Sentinel-2A spolu s několika dalšími, které jsou ovšem obecně známy a široce používány.

Steinnocher a kol. (2019) se zaměřují na dvě případové studie rozdílných měst na základě snímků družice Pléiades, LiDAR a nDMP. Prvním je Salzburg s řadou dostupných kvalitních referenčních i primárních dat o počtu obyvatel. Druhým městem je Port-Au-Prince na Haiti. V tomto případě nejsou k dispozici relevantní referenční ani primární data. Autoři vychází pouze z literatury a z údajů sčítání lidu za rok 2015. Tyto údaje jsou ale k dispozici pouze pro velká administrativní území, nikoliv pro konkrétní sčítací obvody či budovy. Autoři používají k odhadu počtu obyvatel přístupy disagregace a agregace. V prvním případě rozdělují počet obyvatel dostupný za větší územní celky do menších při využití dat DPZ jako pomocných dat pro stanovení hustoty obyvatelstva. Druhým přístupem je výpočet hustoty obyvatel pro pravidelný grid či jednotlivé budovy na základě údajů o průměrném počtu obyvatel na buňku, budovu či domácnost. Následně je možné určit celkový počet obyvatel zájmového území. V práci bylo zjištěno, že nDMP vygenerované na základě satelitních snímků vykazují dostatečnou přesnost pro odhad rozložení obyvatel, pokud jsou k dispozici spolehlivá data pro rozdělení zástavby na obytnou a neobytnou. Přesnost v případě Salzburgu je počítána na základě celkové relativní chyby na buňku gridu o straně 100 a 500 m. Nejlepší výsledky dosahují chyby 9,5 % v případě přístupu využívající LiDAR a všechna dostupná doplňující data. Nejhorším výsledkem je chyba 23,2 % při použití nDMP a průměrných hustot obyvatel na určitý typ zástavby. V případě Port-Au-Prince nelze přesnost odhadu obyvatel brát jako relevantní, jelikož bylo vycházeno pouze z neúplného pokrytí zájmového území budovami z OSM.

Současným trendem metod DPZ je objektově orientovaná klasifikace (OBIA). Počet publikací, výzkumů a softwarů zabývajících se touto klasifikační metodou stále roste. Vývojem, aplikacemi a výhodami OBIA oproti per-pixel klasifikátorům se zabývají Blaschke a Strobl (2001) a Blaschke a kol. (2014). OBIA se začala rozvíjet okolo roku 2000. Obrazové objekty představují smysluplné entity (např. strom, dům nebo vozidlo), které lze ze snímku rozlišit. Proto jsou výrazně závislé na měřítku. Důležitou součástí OBIA je segmentace (obr. 5) – rozdělení zájmového území na základě homogenity na prostorově souvislé, nesouvislé a homogenní objekty, označované jako segmenty (Blaschke a kol., 2014). Segmentace otevírá možnost aplikovat různé geografické koncepty na zpracování snímků. Již v roce 2001 byla dle autorů OBIA v mnoha případech vhodnější než tradiční metody per-pixel klasifikace. Byly to nejen aplikace na snímky s velmi vysokým prostorovým rozlišením, ale také např. komplexní situace jako je zastavěné území. (Blaschke a Strobl, 2001). Proces segmentace ovšem závisí na zkušenostech uživatele, jelikož je nutné stanovit parametry, na základě kterých budou segmenty vytvářeny.



Obr. 5 Náhled segmentace snímku QuickBird na centrum města Olomouc (zdroj: KGI UP, Digital Globe).

Všechny zmíněné výzkumy, práce či články s výjimkou bakalářských prací Kolaříka (2012) a Zapletala (2019), jsou zahraniční. V Česku se touto tematikou dosud nikdo jiný nezabýval, pravděpodobně z důvodu, že jsou zde údaje o počtu obyvatel kvalitní a snadno dostupné. Postupy stanovené v rámci zmíněných výzkumů se týkají zahraničních zájmových území, která se značně liší od českého prostředí. Lze očekávat, že aplikace na rozmanitou zástavbu v Česku bude komplikovanější. Dalším faktorem je také velikost zájmového území, kdy s výjimkou prací Lu a kol. (2010) a Steinnochera a kol. (2019) byl počet obyvatel odhadován na malých částech měst, což lze označit za jednodušší aplikaci. V neposlední řadě je důležité zmínit také mnohdy nedostatečný popis či naopak složitost postupů. Zmíněné výzkumy byly zaměřeny především na finální přesnost odhadu počtu obyvatel bez ohledu na složitost a opakovatelnou proveditelnost metod či náročnost zpracování. V bakalářské práci je kladen důraz i na tyto aspekty.

Na Katedře geoinformatiky UP byly zpracovány dvě práce, které se se dotýkají problematiky extrakce zástavby z dat DPZ: bakalářská práce Tögelové (2011) a diplomová práce Poura (2015). Již zmíněné práce Kolaříka (2012) a Zapletala (2019) se zabývají disagregací dat o počtu obyvatel.

Přestože mají metody odhadu počtu obyvatel na základě dat DPZ velký potenciál, v současné době existuje rozpor mezi akademickým výzkumem a skutečnou praxí. Ta se setkává s nedostatkem zkušeností pracovníků, technickými a aplikačními problémy, které brání širšímu využití metod DPZ pro tento účel (Rayer, 2015).

4 PŘEDZPRACOVÁNÍ DAT

Před samotným testováním a stanovením optimálních postupů proběhlo předzpracování vstupních dat. Konkrétně se jedná o předzpracování satelitních snímků a digitálních modelů, z bodového mračna poskytnutého vedoucím práce bylo nutné vygenerovat DMP a DMR. Veškeré zpracování dat včetně následujících kapitol 5 a 6, s výjimkou předzpracování bodového mračna v softwaru Agisoft Metashape, bylo testováno na notebooku HP Pavillion s procesorem Intel Core i5-7300HQ, CPU 2,50GHz a pamětí RAM 8 GB.

4.1 Pan-sharpening


Pro snímek QuickBird bylo nutné provést pan-sharpening – integraci panchromatického pásma o prostorovém rozlišení 0,6 m/px s multispektrálním, jehož prostorové rozlišení je 2,4 m/px. Bylo vyzkoušeno pět metod, které jsou v softwaru ArcGIS Pro dostupné: Brovey, Esri, Gram-Schmidt, IHS a Simple Mean. Metody byly použity v jejich výchozím nastavení, pouze v případě metody Gram-Schmidt byl specifikován typ senzoru.

Metoda Brovey vykazuje výborné výsledky, co se týče integrace prostorového rozlišení snímku, avšak znatelně mění hodnoty pixelů, a to především u vegetace (obr. 6A). Téměř identický výsledek měla také metoda IHS (obr. 6B).

Metoda Esri vykazovala nejhorší výsledky u integrace prostorového rozlišení snímku. Tento nedostatek se projevil především u vegetace a stínů, kdy lze na snímku rozpoznat jednotlivé pixely (obr. 6C).


Metoda Simple Mean je nejjednodušší z vyzkoušených, jelikož zde není možné specifikovat váhu pro jednotlivá spektrální pásma. Integrace prostorového rozlišení nebyla optimální. Opět zde lze rozpoznat jednotlivé pixely, tentokrát především u zástavby. Metoda také podstatně potlačila barvy snímku do šedé, což se projevilo ztrátou kontrastu mezi prvky na snímku (obr. 6D).





Obr. 6 Detaily výsledků metody pan-sharpening (A: Brovey, B: IHS, C: Esri, D: Simple Mean).

Metoda Gram-Schmidt jako jediná umožňuje zvolení konkrétního senzoru. Vykazuje optimální výsledky v případě integrace spektrálního i prostorového rozlišení (obr. 7), a proto byl snímek předzpracovaný touto metodou zvolen pro další operace. Finální prostorové rozlišení snímku činí 0,6 m/px.



Obr. 7 Detail výsledku metody Gram-Shmidt.

4.2 Převzorkování

Jednotlivá spektrální pásma snímků družice Sentinel-2A byla převzorkována na stejné rozlišení za účelem ulehčení dalšího zpracování snímků. Pro tento proces byl využit software SNAP. Všechna pásma byla převzorkována metodou *Nearest* na rozlišení 10 m/px.

4.3 Digitální modely

4.3.1 Normalizace

DMP 1G a DMR 5G byly nejprve ořezány na stejné území jako snímek QuickBird a transformovány ze souřadnicového systému S-JTSK do WGS UTM zone 33N. V nástroji *Raster Calculator* byl od DMP 1G odečten DMR 5G. Výsledným rastrem je nDMP, který zobrazuje skutečnou výšku prvků od povrchu Země, což je v případě detekce zástavby žádoucí.

4.3.2 Generování DMP a DMR z bodového mračna

Generování bodového mračna z leteckých snímků bylo provedeno vedoucím práce v softwaru Agisoft Metashape při hustotě bodů stanovené na *Medium*.

Výsledný soubor ve formátu LAS čítal miliardu a čtvrt jednotlivých bodů. DMP v rastrovém formátu byl z bodového mračna vygenerován v softwaru ArcGIS Pro pomocí nástroje *LAS Dataset To Raster* při rozlišení 0,6 m/px.

Bylo ovšem nutné vygenerovat také DMR, který by sloužil k normalizaci DMP. Pro tento účel byl zvolen software CloudCompare a plugin CSF, který umožňuje automatickou klasifikaci bodového mračna na prvky „ground“ a „non-ground“. I přesto, že se jedná o poměrně jednoduchý filtr, pro tuto klasifikaci byly jeho výsledky dostačující.

Problémem byla velikost souboru a počet bodů v bodovém mračnu. Dle autora softwaru jsou maximálním limitem 2 miliardy bodů, ale při takovýchto objemech vykazuje software špatný výkon (Girardeau-Montaut, 2017). Toto se potvrdilo, jelikož soubor nebylo možné otevřít ani po osmi hodinách procesování. Bodové mračno bylo tedy vedoucím práce rozděleno v softwaru Agisoft Metashape na dlaždice o rozměrech 2x2 km, přičemž největší soubor měl 65 milionů bodů. Pro každou dlaždici byla provedena klasifikace pomocí pluginu CSF, kdy byly ponechány pouze body klasifikované jako „ground“. V softwaru CloudCompare bylo snahou spojit výsledné dlaždice reliéfu do jednoho souboru, avšak nebylo možné se všemi pracovat najednou. Proto byly spojeny pouze do pěti finálních souborů. Tyto soubory již nebylo možné všechny v softwaru načíst.

Výsledné soubory byly v softwaru ArcGIS Pro spojeny do jednoho LAS datasetu a převedeny na rastr pomocí nástroje *LAS Dataset To Raster* při nastavení z obrázku 8. Byla zvolena interpolace pomocí metody *Binning*, jelikož metoda *Triangulation* je doporučována v případě bodových mračen o nízké hustotě bodů (ESRI, 2019). U parametru *Cell Assignment* byla zvolena metoda *Nearest*. Parametr *Void Fill* byl stanoven na metodu *Natural Neighbour*, která vykazuje lepší výsledky než lineární (Bater a Coops, 2009). *Sampling Value* byla stanovena na 0,6 m, což odpovídá prostorovému rozlišení snímku QuickBird. K práci s rastrem o lepším rozlišení nebylo přistoupeno vzhledem k obtížnému navazujícímu zpracování, které bylo na hraně výkonnosti použitého notebooku.

← LAS Dataset To Raster +

Parameters Environments ?

* Input LAS Dataset

* Output Raster

Value Field

Elevation

Interpolation Type Binning

Cell Assignment Nearest

Void Fill Method Natural Neighbor

Output Data Type

Floating Point

Sampling Type

Cell Size

Sampling Value 0,6

Z Factor 1

Obr. 8 Nastavení nástroje LAS Dataset To Raster při tvorbě DMP a DMR.

Digitální modely byly následně transformovány ze souřadnicového systému S-JTSK do WGS UTM zone 33N. DMR byl od DMP odečten stejně jako v podkap. 4.3.1 a výsledný nDMP byl ořezán dle snímku QuickBird.

5 EXTRAKCE ZÁSTAVBY

Prvním dílčím cílem práce byla extrakce zástavby z použitých dat. Pro tento účel byly testovány metody obrazové klasifikace, metody GIS a spektrální indexy. Snahou bylo postupy co nejvíce automatizovat za předpokladu co nejvyšší výsledné přesnosti.

Následující kapitoly jsou rozděleny dle použitých metod na tři různé postupy, které jsou vhodné pro specifické typy dat DPZ.

5.1 Postup I: Obrazová klasifikace

První testovaný postup zahrnuje metody obrazové klasifikace, které byly testovány na VHR snímku QuickBird bez využití jakýchkoli pomocných dat. Cílem bylo detekovat zástavbu na základě spektrálních a strukturních vlastností.

5.1.1 Neřízená klasifikace

Pro neřízenou klasifikaci byla použita metoda *Iso Cluster*. V softwaru ArcGIS Pro se jedná o jedinou metodu neřízené klasifikace. V rámci nástroje *Iso Cluster Unsupervised Classification* lze měnit tři různá nastavení: počet tříd, minimální velikost třídy v pixelech (výchozí: 20) a interval vzorkování (výchozí: 10). Celkově bylo testováno devět různých nastavení (viz příloha 1), avšak již na základě vizuální interpretace nebyly výsledky dostačující.

V rámci testování vykazoval nejlepší výsledky postup, kdy byl počet klasifikačních tříd stanoven na 256 a jednotlivé třídy byly následně manuálně spojeny do výsledného počtu sedm. Tento postup je ale časově náročný, přičemž výsledek této náročnosti neodpovídá. Jelikož bylo předpokládáno, že řízená klasifikace bude vykazovat přesnější výsledky, bylo následně přistoupeno na její testování.

5.1.2 Řízená klasifikace

V rámci řízené klasifikace byly testovány tři metody: Maximum Likelihood (ML), Random Trees (RT) a Support Vector Machine (SVM). Tyto metody byly testovány jak pro klasifikaci typu per-pixel, tak pro objektově orientovanou.

Segmentace

V rámci objektově orientované klasifikace bylo nejprve nutné provést segmentaci snímku (obr. 9). Jelikož není v literatuře dostupné žádné univerzální nastavení či doporučení pro software ArcGIS Pro, byla testována různá nastavení funkce *Segment Mean Shift*. Dle vizuální interpretace vystihovaly segmenty zástavbu nejlépe při následujícím nastavení:

- spektrální detail: 17,
- prostorový detail: 17,
- minimální velikost segmentu v pixelech: 40.



Obr. 9 Náhled segmentace snímku v nepravých barvách pro centrum města Olomouce.

Trénovací data

V rámci klasifikačního schématu bylo definováno sedm klasifikačních tříd: zástavba, komunikace, vegetace, půda, voda, stín a ostatní. Bylo vytvořeno celkem 891 trénovacích dat, přičemž byl kladen důraz na třídu zástavba (tab. 1). Snahou bylo postihnout všechny typy zástavby, které se na snímku nacházely.

Tab. 1 Vytvořená trénovací data

třída	počet polygonů	počet pixelů
zástavba	251	846 767
komunikace	120	419 221
vegetace	140	4 638 670
půda	70	9 555 995
voda	70	349 598
stín	120	126 534
ostatní	120	104 668
celkem	891	16 041 453

Při trénování klasifikátorů bylo změněno výchozí nastavení u metod RT a SVM, kdy byl parametr *Maximum Number of Samples per Class* stanoven na hodnotu 0. Při tomto nastavení jsou využita všechna trénovací data, což je žádoucí. V případě per-pixel klasifikace metody SVM ovšem došlo k problému, kdy se při tomto nastavení funkce zastavila na 0 %. Toto nastavení bylo testováno na více počítačích, avšak neúspěšně. V případě této metody bylo tedy ponecháno výchozí nastavení.

Pro zhodnocení klasifikací bylo vytvořeno 71 náhodných bodů pro každou třídu pomocí nástroje *Create Accuracy Assessment Points*. Přesnost byla hodnocena manuálně. Následně byly vygenerovány chybové matice, kde lze sledovat počet správně a nesprávně

zařazených pixelů, počty náhodných bodů, přesnost z hlediska uživatele (PU), přesnost z hlediska zpracovatele (PZ), celkovou přesnost a Kappa koeficient.

Výsledky klasifikací se neukázaly jako optimální (viz příloha 2). Celkově nejpřesnější byla objektová klasifikace metody SVM, která dosáhla celkové přesnosti 79 % a hodnoty Kappa koeficientu 0,76 (tab. 2), což se nedá pokládat za optimální výsledek. Samotná třída zástavba měla PZ i PU 66 %. Nejpřesnější výsledek z hlediska přesnosti třídy zástavba měla objektová klasifikace metody ML při hodnotách PZ 62 % a PU 72 % (tab. 3). Celková přesnost třídy zástavba byla tedy 67 %.

Všechny ostatní klasifikace vykazovaly výsledky výrazně horší. Dále bylo pracováno pouze s objektovou klasifikací pomocí metod SVM a ML, kde bylo snahou co nejvíce zvýšit přesnost třídy zástavba.

Tab. 2 Chybová matice snímku klasifikovaného pomocí objektové klasifikace metody SVM

třída	zástavba	komunikace	vegetace	půda	voda	stín	ostatní	celkem	PU [%]	Kappa
zástavba	47	10	1	1	0	7	5	71	0,66	0
komunikace	6	53	2	5	0	0	5	71	0,75	0
vegetace	0	0	69	0	0	2	0	71	0,97	0
půda	0	0	4	67	0	0	0	71	0,94	0
voda	2	0	0	0	56	13	0	71	0,79	0
stín	3	0	0	0	0	68	0	71	0,96	0
ostatní	13	7	0	5	1	11	34	71	0,48	0
celkem	71	70	76	78	57	101	44	497	0	0
PZ [%]	0,66	0,76	0,91	0,86	0,98	0,67	0,77	0	0,79	0
Kappa	0	0	0	0	0	0	0	0	0	0,76

Tab. 3 Chybová matice snímku klasifikovaného pomocí objektové klasifikace metody ML

třída	zástavba	komunikace	vegetace	půda	voda	stín	ostatní	celkem	PU [%]	Kappa
zástavba	51	3	7	0	0	3	7	71	0,72	0
komunikace	14	45	0	7	0	0	5	71	0,63	0
vegetace	0	0	71	0	0	0	0	71	1	0
půda	1	1	1	68	0	0	0	71	0,96	0
voda	9	0	0	0	35	26	1	71	0,49	0
stín	1	0	0	0	0	70	0	71	0,99	0
ostatní	6	2	9	35	0	5	14	71	0,20	0
celkem	82	51	88	110	35	104	27	497	0	0
PZ [%]	0,62	0,88	0,81	0,62	1	0,67	0,52	0	0,71	0
Kappa	0	0	0	0	0	0	0	0	0	0,66

Úprava trénovacích dat

Pro třídu zástavba byl vytvořen vysoký počet trénovacích dat, konkrétně 1501 polygonů. Jelikož zástavba s šedými střechami vykazuje podobné spektrální hodnoty jako silnice, pro třídu komunikace byla také přidána trénovací data. Počet polygonů pro třídu komunikace tedy činil 240. Dále byla trénovací data přidána také pro třídy voda a vegetace. Náhled upravených trénovacích dat lze sledovat na obrázku 10, konkrétní počty v tabulce 4.

Tab. 4 Trénovací data po úpravě

třída	počet polygonů	počet pixelů
zástavba	1501	1 776 022
komunikace	240	1 438 887
vegetace	216	9 366 940
půda	70	9 555 995
voda	101	1 002 906
stín	120	126 534
ostatní	120	104 668
celkem	2368	16 041 453



Obr. 10 Náhled upravených trénovacích dat.

Zhodnocení klasifikace proběhlo stejně jako v předchozím kroku. U obou metod se podařilo zvýšit celkovou přesnost i Kappa koeficient. Přesnost třídy zástavba se u metody ML zvýšila pouze o půl procenta (tab. 5), u metody SVM se zhoršila (tab. 6). Při velkém množství trénovacích dat došlo k tomu, že bylo jako tato třída identifikováno příliš mnoho pixelů ostatních tříd.

Tab. 5 Chybová matice snímku klasifikovaného pomocí objektové klasifikace metody ML po úpravě trénovacích dat

třída	zástavba	komunikace	vegetace	půda	voda	stín	ostatní	celkem	PU [%]	Kappa
zástavba	53	7	0	3	0	2	6	71	0,75	0
komunikace	15	51	0	1	0	1	3	71	0,72	0
vegetace	0	0	69	0	0	1	1	71	0,97	0
půda	0	1	11	59	0	0	0	71	0,83	0
voda	3	0	0	0	66	1	1	71	0,93	0
stín	5	0	0	0	2	64	0	71	0,90	0
ostatní	13	10	7	8	0	9	24	71	0,34	0
celkem	89	69	87	71	68	78	35	497	0,00	0
PZ [%]	0,60	0,74	0,79	0,83	0,97	0,82	0,69	0	0,78	0
Kappa	0	0	0	0	0	0	0	0	0	0,74

Tab. 6 Chybová matice snímku klasifikovaného pomocí objektové klasifikace metody SVM po úpravě trénovacích dat

třída	zástavba	komunikace	vegetace	půda	voda	stín	ostatní	celkem	PU [%]	Kappa
zástavba	26	19	3	6	0	3	14	71	0,37	0
komunikace	1	66	1	3	0	0	0	71	0,93	0
vegetace	0	0	68	0	0	2	1	71	0,96	0
půda	2	0	2	67	0	0	0	71	0,94	0
voda	0	1	0	0	62	6	2	71	0,87	0
stín	0	0	0	0	0	71	0	71	1	0
ostatní	1	5	9	9	0	3	44	71	0,62	0
celkem	30	91	83	85	62	85	61	497	0	0
PZ [%]	0,87	0,73	0,82	0,79	1	0,84	0,72	0	0,81	0
Kappa	0	0	0	0	0	0	0	0	0	0,78

Vzhledem k neúspěšnosti řízené klasifikace pro identifikaci zástavby v softwaru ArcGIS Pro byl pro tento účel testován také software ENVI. Bylo postupováno dle návodu *Feature Extraction with Example-Based Classification* (Harris Geospatial Solutions, Inc, 2020). Testována byla pouze menší oblast snímku QuickBird, která obsahovala všechny třídy prvků, které byly stanoveny v klasifikačním schématu. Byl vytvořen přibližně stejný počet trénovacích dat jako v případě testování všech metod v ArcGIS Pro. Jako metoda řízené klasifikace byl zvolen KNN klasifikátor. V rámci objektové klasifikace vznikla také osmá třída, *Unclassified*, kdy KNN klasifikátor nebyl schopen segment zařadit do jedné z definovaných tříd. Na základě vizuální interpretace byly výsledky horší než klasifikace provedené v softwaru ArcGIS Pro.

Tento postup je časově náročný a vzhledem k tvorbě trénovacích dat vyžaduje také jistou expertní znalost uživatele, kdy je třeba rozmístit trénovací data rovnoměrně po snímku, zajistit jejich dostatečný počet a reprezentativnost vůči skutečnosti. Dalším faktorem je také výpočetní náročnost v případě vysokého počtu trénovacích dat. Vzhledem k těmto skutečnostem a především nedostatečné přesnosti nebyl postup stanoven jako optimální.

5.2 Postup II: Analýzy nDMP

Druhý stanovený postup zahrnuje analýzy nad nDMP, přičemž cílem je extrahovat z něj zástavbu na základě výšky. Postup obsahuje tři důležité části: odstranění vysoké vegetace, samotnou detekci zástavby a následný postprocessing pro dosažení lepších výsledků. Postup je založen na práci s komerčními VHR daty: satelitním snímekem a nDMP.

5.2.1 Odstranění vysoké vegetace

Z nDMP bylo nutné odstranit vysokou vegetaci, především stromy, jelikož by mohla být vzhledem ke své výšce interpretována jako zástavba. Pro detekci vegetace bylo testováno šest metod řízené klasifikace a NDVI index.

NDVI index byl vybrán na základě kladných referencí Skarlatose a Vlachose (2018), kteří jej ve své práci využili pro podobný účel – odstranění vegetace z DMP. Index SAVI a jeho variace testovány nebyly, jelikož jsou vhodné především pro oblasti s nízkým vegetačním pokryvem (ESRI, 2020a).


Obrazová klasifikace

Testování bylo realizováno v menším měřítku na katastrální území Olomouc-město. Pro řízenou klasifikaci bylo vytvořeno celkem 198 polygonů trénovacích dat, 153 pro vegetaci, 45 pro ostatní prvky. Byly využity stejné metody řízené klasifikace jako v kapitole 5.1.2.

Segmentace snímku v nepravých barvách pro objektovou klasifikaci byla provedena při následujícím nastavení:

- spektrálního detail: 15,
- prostorový detail: 10,
- minimální velikost segmentu v pixelech: 40.

Toto nastavení vykazovalo optimální segmentaci mezi vegetací a ostatními prvky (obr. 11).



Obr. 11 Náhled segmentace snímku v nepravých barvách pro detekci vegetace.

Pro vyhodnocení klasifikací a vegetace detekované na základě NDVI indexu bylo vytvořeno 150 náhodných bodů, při zvolení metody *Stratified random*. Tato metoda vytváří náhodné body, jejichž počet je přímo úměrný relativní ploše třídy.

NDVI index

Výpočet NDVI indexu (vzorec 1) zahrnuje hodnoty blízkého infračerveného pásma (NIR) a viditelného červeného pásma (RED) (Ettehad Osgouei a kol., 2019).

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (1)$$

NDVI nabývá hodnot -1 až 1, kdy nízké hodnoty indikují plochy bez vegetace. Po výpočtu indexu byl použit nástroj *Binary Thresholding* za účelem stanovení prahu mezi plochami s vegetací a bez vegetace. Nástroj slouží pro rastrová data, která mají bimodální rozdělení, přičemž výsledkem je rastr rozdělený na dvě třídy dle Otsu metody (ESRI, 2020).

Zde bylo nutné zvážit, zda je pro vstupní data tato metoda vhodná. Příliš nízký práh může způsobit, že do vegetace budou zařazeny povrchy jako je beton či holá půda. Naopak příliš vysoký práh nemusí do výsledného rastru zahrnout veškerou detekovanou vegetaci. Práh není možné v rámci této funkce upravovat, je stanoven automaticky. Záleží tedy čistě na vstupních datech. Pro snímek QuickBird byla tato metoda vhodná, jelikož Kappa koeficient dosahoval hodnoty 0,97 (tab. 7).

NDVI index a následné prahování bylo zvoleno jako nejpresnější a zároveň nejrychlejší metoda pro detekci vegetace. Nebylo nutné vytvářet trénovací data a výpočet indexu i jeho prahování bylo realizováno v řádu sekund za vysoké přesnosti v porovnání s algoritmy řízené klasifikace (viz příloha 3).


Tab. 7 Chybová matice vegetace detekované na základě NDVI

Třída	Vegetace	Ostatní	Celkem	PU [%]	Kappa
Vegetace	92	0	92	1	0
Ostatní	2	56	58	0,97	0
Celkem	94	56	150	0	0
PZ [%]	0,98	1	0	0,99	0
Kappa	0	0	0	0	0,97

5.2.2 Detekce zástavby

Detekované vegetaci byla přiřazena skutečná výška z nDMP, aby bylo možné vybrat pouze vegetaci vyšší než tři metry, což odpovídalo stanovené minimální výšce budovy a průměrné výšce jednoho patra. Pro stanovení této výšky bylo vycházeno z minimální světlé výšky obytné místnosti rodinných domů 2500 mm, ke které byla přičtena rezerva 500 mm pro konstrukční prvky patra (ČSN 73 4301, 2004).

Rastr vegetace bylo nutné reklasifikovat tak, aby v místech s vegetací vznikly plochy bez dat, zatímco ve všech ostatních plochách byla hodnota (např. 1). Procesem maskování byla veškerá detekovaná vegetace vyšší než tři metry extrahována z nDMP. Následně byly z takto vzniklého nDMP vybrány pouze hodnoty nad tři metry, které byly uvažovány jako zástavba. Výsledná vrstva zástavby byla vynásobena tisícem, aby nedošlo ke ztrátě desetinných hodnot výšky a převedena na celočíselný datový typ pro usnadnění dalších navazujících operací. Celý proces byl automatizován s využitím nástroje *ModelBuilder* (obr. 12).



Obr. 12 Proces extrakce zástavby.


Pro tento postup byl nejprve využit nDMP získaný z DMP 1G a DMR 5G o rozlišení 2 m/px. Bylo zjištěno, že tyto digitální modely vykazují poměrně rozsáhlé nepřesnosti – DMP 1G především v oblasti řeky Moravy, vodních ploch (např. pískovna Poděbrady) a některých budov (např. budova přírodovědecké fakulty UP), což lze vidět na obrázku 13, DMR 5G u některých budov či silničních nadjezdů. Tyto chyby jsou pravděpodobně způsobeny špatnou interpolací bodů, které nebyly zaměřeny v rámci leteckého laserového skenování. Následně byl využit také nDMP o rozlišení 0,6 m/px, který vznikl z digitálních modelů vygenerovaných na základě leteckých snímků (viz kapitola 4.3.2).



Obr. 13 Výběr identifikovaných nepřesností v DMP 1G (zdroj: <https://ags.cuzk.cz/dmr/>).

5.2.3 Postprocessing

Pro přiblížení se k tvaru budov a eliminování některých nesprávně vybraných prvků, bylo testováno další zpracování získané vrstvy zástavby. Nejprve byl použit *Majority Filter* pro eliminaci pixelů, které vykazovaly znaky šumu. Jednalo se především o malé skupiny či samostatné pixely, které se vyskytovaly v územích bez jakékoli zástavby nebo vybočovaly z kompaktního tvaru budov. Data byla následně zvektORIZOVÁNA a bylo nutné takto vzniklé polygony agregovat do skupin či samostatně stojících budov. Jelikož tímto procesem byla ztracena výška jednotlivých pixelů, byla průměrná výška všech pixelů v rámci polygonů agregována pomocí nástroje *Summarize Within*. Nakonec byl použit nástroj *Regularize Building Footprint* pro zpracování výsledné vrstvy do tvarů, které se přibližují skutečnému tvaru budov. Jelikož tento postup zahrnoval více nástrojů a nastavení, se kterými bylo pro dosažení optimálních výsledků třeba experimentovat, byl pomocí nástroje *ModelBuilder* automatizován (obr. 14).




Obr. 14 Proces následného zpracování vrstvy zástavby.

Pro dosažení optimálních výsledků pro výběr budov z nDMP byly stanoveny následující parametry:

1. Majority Filter
 - number of neighbours to use: 4
 - Replacement threshold: Majority
2. Raster to Polygon
 - Simplify polygons: ne
 - Create multipart feature: ne
3. Aggregate Polygons
 - Aggregation Distance: dle rozlišení vstupního nDMP (2/0,3 m)
 - Minimum Area: 50 m²
 - Minimum Hole Size: 10 m²
 - Preserve orthogonal shape: ano
4. Summarize Within
 - Keep all input polygons: ano
 - Statistic: mean
5. Regularize Building Footprint
 - Method: Right Angles
 - Tolerance: 5
 - Densification: 5
 - Precision: 0,25

Jediný parametr, který se měnil v závislosti na vstupním nDMP byla *Aggregation Distance*. V případě nDMP o rozlišení 2 m/px zde byla stanovena hodnota 2 m, zatímco při použití nDMP o rozlišení 0,6 m/px byla stanovena hodnota 0,3 m.



Obr. 15 Náhled výsledné vrstvy zástavby pro centrum Olomouce (vlevo: z nDMP 2 m/px, vpravo: z nDMP 0,6 m/px).

Výpočetní náročnost tohoto postupu exponenciálně roste s rozlišením vstupního rastru. Při počtu 1 490 619 polygonů, které bylo třeba agregovat v rámci nDMP s rozlišením 2 m/px, byla doba trvání celého procesu 27 minut 2 sekundy. Při počtu 16 725 965 polygonů v případě nDMP s rozlišením 0,6 m/px již proces trval 7 h 37 min. Výsledné vrstvy zástavby byly použity pro odhad počtu obyvatel (obr. 15).

Problémem tohoto postupu byla skutečnost, že snímek QuickBird byl oproti oběma nDMP mírně posunutý z důvodu centrální projekce. Po konzultaci s vedoucím práce bylo zjištěno, že tento nedostatek nelze efektivně odstranit. Z tohoto důvodu došlo při extrakci vegetace k chybnému odstranění částí některých budov či naopak k ponechání některých oblastí s vysokou vegetací, které byly identifikovány jako zástavba. Na obrázku 16 lze toto sledovat na území sídliště Lazce při použití nDMP o rozlišení 0,6 m/px. Jedná se o rastrovou vrstvu, která vznikla po odstranění vegetace a výběru pixelů nad 3 m dle postupu z kapitoly 5.2.2. S ohledem na tuto skutečnost byly také zvoleny parametry nástroje *Regularize Building Footprint*.



Obr. 16 Náhled důsledků posunutí snímku QuickBird oproti nDMP.

V důsledku tohoto problému byly ovlivněny všechny výsledky vycházející z tohoto postupu, a to především výsledná přesnost zástavby získaná v podkap. 5.2.2 (tab. 8, tab. 9) a odhady počtu obyvatel. Vrstvy zástavby byly zhodnoceny vzhledem k nDMP, nikoliv ke snímku QuickBird.

Tab. 8 Chybová matice zástavby detekované na základě nDMP o rozlišení 2 m/px

Třída	Ostatní	Zástavba	Celkem	PU [%]	Kappa
Ostatní	246	4	250	0,98	0
Zástavba	84	166	250	0,66	0
Celkem	330	170	500	0	0
PZ [%]	0,75	0,98	0	0,82	0
Kappa	0	0	0	0	0,65

Tab. 9 Chybová matice zástavby detekované na základě nDMP o rozlišení 0,6 m/px

Třída	Ostatní	Zástavba	Celkem	PU [%]	Kappa
Ostatní	250	0	250	1	0
Zástavba	45	205	250	0,82	0
Celkem	295	205	500	0	0
PZ [%]	0,85	1	0	0,91	0
Kappa	0	0	0	0	0,82

Manuální odstranění vegetace

V případě, kdy by byla vegetace odstraněna přesně, je očekáváno výrazné zlepšení přesnosti výsledné extrakce zástavby a jednotlivých budov. Toto bylo potvrzeno na základě testování na malém území u třídy Svornosti, kde se vyskytují různé typy zástavby

a vegetace. Vegetace zde byla z nDMP o rozlišení 0,6 m/px odstraněna manuálně na základě vizuální interpretace autorky.

Při přesném odstranění vegetace bylo při detekci zástavby dosaženo celkové přesnosti 100 %. Pro následné zpracování vrstvy byl použit automatizovaný proces v nástroji *ModelBuilder* (viz obr. 15), kde bylo změněno nastavení nástroje *Regularize Building Footprint*. Byla zvolena metoda *Any Angles*, parametr *Tolerance* byl stanoven na hodnotu 1,5; parametr *Precision* na 0,15 a parametr *Diagonal Penalty* na 5. Toto nastavení nástroje je vhodné použít v případě, kdy není třeba odstraňovat chyby vzniklé neoptimální detekcí zástavby či odstraněním vegetace.

Výslednou vrstvu budov (obr. 17) je možné porovnat s vrstvou, která vznikla při nepřesném odstranění vegetace (obr. 18). Jako podklad je zde použita podkladová satelitní mapa dostupná v ArcGIS Pro, která vykazuje menší posun vůči nDMP než snímek QuickBird.



Obr. 17 Výsledná vrstva budov při přesném odstranění vegetace (zdroj: ESRI, 2020b).



Obr. 18 Výsledná vrstva budov při nepřesném odstranění vegetace (zdroj: ESRI, 2020b).

5.2.4 Stanovení obytných budov dle OSM

Posledním krokem v rámci výběru zástavby bylo stanovení obytných budov. Byla využita vrstva budov z OSM stažená z portálu geofabrik.de, kdy byly vybrány budovy, které lze označit jako obytné, tedy budovy s typem „residential“, „apartments“, „house“ nebo „dormitory“. Polygony z vrstvy zástavby získané v kapitole 5.2.3, které protínaly vrstvu obytných budov byly dále použity pro odhad počtu obyvatel. Celý postup byl vyhodnocen jako optimální, jelikož při přesném odstranění vegetace umožňuje extrakci zástavby s vysokou přesností a lze jej ve vysoké míře automatizovat.

5.3 Postup III: Spektrální indexy

Pro satelitní snímek Sentinel-2A bylo nutné pro detekci zástavby sestavit odlišný postup vzhledem k řádově horšímu prostorovému rozlišení a nezahrnutí výškových dat. Výšková data nebyla zahrnuta, jelikož bylo cílem tento postup založit pouze na volně dostupných datech.

S ohledem na neuspokojivé výsledky klasifikace zástavby VHR snímku QuickBird z podkapitoly 5.1 nebyly postupy řízené či neřízené klasifikace na snímku Sentinel testovány. Jelikož snímek disponuje širokým spektrálním rozlišením, byl zvolen přístup kombinující spektrální indexy na základě referencí z prací Vigneshwarana a Vasanthy (2018) a Ettehadi Osgouei a kol. (2019). Pro identifikaci zástavby a její odlišení od ostatních prvků byly nejprve testovány vybrané široce používané spektrální indexy: Bare Soil Index (BSI), Modified Normalized Difference Water Index (MNDWI), Normalized Difference Built-up Index (NDBI) a Normalized Difference Vegetation Index (NDVI) (tab. 10).

Tab. 10 Testované spektrální indexy (Ettehadí Osgouei a kol., 2019)

Index	Vzorec	Účel
BSI	$\frac{(\text{SWIR} + \text{Red}) - (\text{NIR} + \text{Blue})}{(\text{SWIR} + \text{Red}) + (\text{NIR} + \text{Blue})}$	zvýraznění holé půdy
MNDWI	$\frac{\text{Green} - \text{SWIR}}{\text{Green} + \text{SWIR}}$	zvýraznění vodních ploch při potlačení zástavby
NDBI	$\frac{\text{SWIR} - \text{NIR}}{\text{SWIR} + \text{NIR}}$	zvýraznění zástavby a městských oblastí
NDVI	$\frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}}$	detekce zelené vegetace (relativní biomasy)

Pomocí BSI bylo možné poměrně dobře odlišit holou půdu, avšak jeho nevýhodou je zaměňování zástavby a holé půdy. Především zástavba s červenými a hnědými střechami vykazovala na základě vizuální interpretace podobné hodnoty jako holá půda. Jelikož hlavním záměrem bylo odlišení zástavby, tento index byl vyloučen jako nevhodný.

Na základě MNDWI je možné odlišit otevřené vodní plochy při potlačení zástavby. Tato funkce se nepotvrdila, jelikož pomocí indexu sice bylo možné odlišit rozsáhlé vodní plochy, zástavba ale nebyla potlačena dostatečně. Vizuální interpretací bylo zjištěno, že zejména bílá zástavba vykazovala podobné hodnoty indexu jako vodní plochy, což bylo nepřipustné.

NDBI slouží pro identifikaci zástavby a člověkem vybudovaných struktur. Na základě indexu bylo možné poměrně dobře rozlišit zástavbu, avšak nebylo možné ji dostatečně odlišit od holé půdy či řeky. Index vykazoval podobné hodnoty jako BSI a pro další použití byl vyloučen.

NDVI na rozdíl od ostatních běžně užívaných indexů vykazoval velmi dobré výsledky v identifikaci vegetace, což bylo potvrzeno již na snímku QuickBird v kapitole 5.2.1. Tento index byl jako jediný zvolen pro další koncept postupu. Pro určení prahu mezi vegetací a ostatními prvky byla použita automatická metoda *Binary Thresholding*, která je více popsána v kapitole 5.2.1.

Pro identifikaci zástavby byl dále testován normalizovaný diferenční index (NDI) vytvořený Vigneshwaranem a Vasanthou (2018) přímo pro satelitní snímky Sentinel-2A (vzorec 2). NDI je založen na pásmech 2 (Blue) a 8 (NIR), jejichž prostorové rozlišení je 10 m/px.

$$\text{NDI} = \frac{\text{Blue} - \text{NIR}}{\text{Blue} + \text{NIR}} \quad (2)$$

Tento index dle autorů vykazoval bez jakýchkoli úprav hodnotu Kappa koeficientu 0,54. Vzhledem k takto nízké hodnotě bylo přistoupeno nejdříve k odstranění vegetace dle NDVI a vody ze snímku, na který byl posléze aplikován NDI. Pro odstranění vody bylo využito NIR pásma, ve kterém voda vykazuje velmi nízké hodnoty oproti ostatním prvkům na snímku. Horní hraniční spektrální hodnota byla stanovena na 800. Toto prahování je ovšem závislé na konkrétním území a vizuální interpretaci uživatele. Výhodou takto detekované vrstvy vody byla i částečná detekce řeky, což při využití MNDWI nebylo možné.

Výsledná vrstva vykazovala optimální odlišení zástavby od ostatních prvků na snímku s výjimkou silnic, které mají podobné spektrální hodnoty jako šedá zástavba. Na základě prahování byly odstraněny velmi nízké hodnoty NDI pod -0,29, které indikovaly holou

půdu či stíny. Tento proces je opět závislý na konkrétním území a interpretaci uživatele. Pro vzniklou vrstvu zástavby (obr. 19) byl vypočítán Kappa koeficient o hodnotě 0,77 a celková přesnost 89 % na základě 100 náhodných bodů pro vrstvu zástavby a ostatních prvků (tab. 11).

Tab. 11 Chybová matice zástavby detekované ze snímku Sentinel-2A

Třída	Ostatní	Zástavba	Celkem	PU [%]	Kappa
Ostatní	90	10	100	0,90	0
Zástavba	13	87	100	0,87	0
Celkem	103	97	200	0	0
PZ [%]	0,87	0,90	0	0,89	0
Kappa	0	0	0	0	0,77



Obr. 19 Detail rastru zástavby vybraného na základě snímku Sentinel-2A.

Vzhledem k tomu, že ze snímku nebylo možné pomocí spektrálních indexů odstranit silnice, bylo přistoupeno k využití volně dostupných pomocných dat z OSM. Kromě vrstvy silnic byly využity také železnice, řeky, zemědělská půda a rezidenční oblasti. Všechny tyto vrstvy byly staženy pro zájmové území Olomouce pomocí plug-inu QuickOSM v programu QGIS. Pro liniové vrstvy byl vytvořen buffer dle jejich průměrné velikosti na snímku (tab. 12), aby bylo možné nechtěné prvky odstranit.

Tab. 12 Použité vrstvy OSM

Klíč dle OSM	Hodnota dle OSM	Popis vrstvy	Buffer
highway	-	všechny silnice	2,5 m
	primary	silnice I. třídy	10 m
	motorway	dálnice	15 m
landuse	farmland	zemědělská půda	-
	residential	rezidenční oblast	-
railway	tram	tramvajové linky	5 m
	rail	železnice	10 m
waterway	river	řeky	10 m

Všechny vrstvy získané z OSM s výjimkou rezidenční oblasti byly postupně ze snímku odstraněny procesem maskování spolu s již zmíněnou vegetací a vodou. Následně byly odstraněny také velmi nízké hodnoty NDI, konkrétně pod -0,54 a vzniklá vrstva zástavby byla ořezána vrstvou rezidenční oblasti.

Pro zhodnocení přesnosti bylo vygenerováno 100 náhodných bodů pro vrstvy zástavby a ostatní. Některá chybně zařazená zástavba ovšem byla brána jako správně zařazená, pokud se jednalo o zástavbu oříznutou rezidenčním územím.

Bylo prokázáno, že při použití pomocných dat z OSM lze zvýšit Kappa koeficient o 5 %. Celková přesnost v tomto případě dosáhla 92 % (tab. 13). Je ovšem nutné podotknout, že vrstva zástavby byla hodnocena vzhledem ke snímku Sentinel-2A. V případě hodnocení nad snímkem s vyšším prostorovým rozlišením jsou očekávány horší výsledky.

Tab. 13 Chybová matice zástavby detekované ze snímku Sentinel-2A s využitím dat OSM

Třída	Ostatní	Zástavba	Celkem	PU [%]	Kappa
Ostatní	92	8	100	0,92	0
Zástavba	9	91	100	0,91	0
Celkem	101	99	200	0	0
PZ [%]	0,91	0,92	0	0,92	0
Kappa	0	0	0	0	0,83

Výsledná vrstva zástavby byla následně zvektorizována. Pro lepší reprezentaci budov byla aplikována funkce *Regularize Building Footprint* při nastavení metody na *Right Angles*, *Tolerance* na 10 m a *Precision* na hodnotu 0,25 (obr. 20).



Obr. 20 Detail výsledné vrstvy zástavby.

5.3.1 Stanovení obytných budov dle OSM

V prvním kroku bylo postupováno stejně jako v kapitoly 5.2.4, kdy byla využita stejná vrstva obytných budov z OSM. Následně byl vypočítán průnik mezi vrstvami ze snímku Sentinel a OSM pomocí nástroje *Tabulate Intersection*. Polygony, jejichž plocha byla pokryta vrstvou obytných budov z OSM z více než 10 %, byly dále použity pro odhad počtu obyvatel (obr. 21). Tento proces byl využit z důvodu zamezení chybného výběru plošně rozsáhlých polygonů, které obsahovaly například pouze jednu obytnou budovu dle OSM. Hodnota 10 % byla použita na základě vizuální interpretace a závisí na konkrétním území.



Obr. 21 Detail zástavby vybrané na základě více než 10% překryvu s obytnými budovami OSM.

V posledním kroku byl jednotlivým polygonům zástavby přiřazen převažující typ z vrstvy obytných budov OSM („residential“, „house“, „apartments“). Bylo třeba převést vrstvu budov z OSM na rastr a následně použít nástroj *Zonal Statistics as Table*, kde byla jako typ statistiky zvolena většina. Tabulka byla poté připojena k získané vrstvě zástavby.

Výhodou stanoveného postupu je jeho rychlost, jednoduchost a automatizace. Spektrální indexy, které byly využity, byly provedeny v řádu sekund. Není nutná manuální tvorba trénovacích dat jako při postupech, které zahrnují řízenou klasifikaci. Všechny kroky kromě manuálního prahování a stanovení procent překryvu s budovami OSM byly provedeny automaticky. Nevýhodou je detekce komunikací v případě, kdy nejsou využita pomocná data z OSM. I přes tuto skutečnost byl postup stanoven jako optimální.

6 ODHAD POČTU OBYVATEL

Proces odhadu počtu obyvatel byl konzultován s vedoucím práce, Mgr. Vítem Pászto, Ph.D. a doc. RNDr. Jaroslavem Burianem, Ph.D. Bylo doporučeno přiřazovat počty obyvatel na základě průměrné obydlenosti bytu a rezidenční zástavbu stanovit dle pomocných dat OSM.

Pro zjištění průměrné obydlenosti pro případovou studii Olomouce bylo vycházeno z údajů ze sčítání lidu (tab. 14), případně vlastních výpočtů na základě počtu obyvatel dle adresních bodů, počtu pater a rozlohy budov (podkap. 6.1). Odhad počtu obyvatel byl realizován ve dvou úrovních podrobnosti – na celou obec (pro všechny získané vrstvy zástavby) a na části obce s převládajícím typem zástavby (pro vrstvy zástavby získané dle kapitoly 5.2).

Tab. 14 Úrovnňové ukazatele obydlených bytů ČR 2011 (Český statistický úřad, 2014)

Úrovnňový ukazatel obydlených bytů	Celkem	Rodinné domy	Bytové domy
celková plocha na 1 byt [m ²]	86,7	109,1	68,5
průměrný počet osob na byt	2,47	2,80	2,21

Počty obyvatel byly odhadovány dle vzorců 3, respektive 4, kdy byl zahrnut také počet pater na základě průměrné výšky budovy. Údaj o ploše budovy pochází ze získané vrstvy zástavby, kdy je v softwaru ArcGIS Pro spočítán automaticky pro každou budovu. Údaje celková plocha a průměrný počet osob na byt je třeba zjistit z dat ze sčítání lidu či jiných relevantních zdrojů. Počet pater (vzorec 5) byl stanoven jako podíl průměrné výšky budovy a jednoho patra (3 m) z kapitoly 5.2.2, přičemž výsledek byl zaokrouhlen vždy dolů na jednu platnou číslici.

$$\text{počet obyvatel} = \frac{\text{plocha budovy} \cdot \text{průměrný počet osob na byt}}{\text{celková plocha na byt}} \quad (3)$$

$$\text{počet obyvatel} = \frac{\text{plocha budovy} \cdot \text{počet pater} \cdot \text{průměrný počet osob na byt}}{\text{celková plocha na byt}} \quad (4)$$


$$\text{počet pater} = \frac{\text{průměrná výška budovy}}{3} \quad (5)$$

Pro zhodnocení přesnosti odhadů byl pro případovou studii města Olomouce využit údaj o počtu obyvatel s obvyklým pobytem dle SLDB 2011, který byl k dispozici pro jednotlivé adresní body. Pro případovou studii města Piešťany byl využit GHS Population grid s počty obyvatel na buňku o straně 250 m. Přesnost byla vyjádřena jako rozdíl mezi odhadem a skutečným počtem obyvatel a jako procentuální rozdíl, kdy tato hodnota byla vypočítána dle vzorce 6. Výsledné odhady počtu obyvatel i rozdíly mezi skutečnými počty byly zaokrouhleny na jednu platnou číslici, procentuální rozdíl na dvě desetinná místa.

$$\text{rozdíl [\%]} = \frac{\text{odhad} \cdot 100}{\text{skutečnost}} - 100 \quad (6)$$

6.1 Část obce

Pro odhady počtu obyvatel byly stanoveny tři specifické části obce s převažujícím typem obytné zástavby: sídlištní, rodinná a ostatní, kam spadá především nízkopodlažní bytová a kompaktní městská zástavba. Tyto části závisí na charakteru obce. Pro každou část bylo stanoveno pět lokalit (obr. 22), kdy bylo snahou vybrat pouze lokality s převahou obytné zástavby. Z tohoto důvodu není pokryto centrum města. Byly vybrány všechny polygony zástavby, které se celé nacházely uvnitř dané lokality. Při práci s ostatním typem zástavby byla uvažována plocha zástavby, která se nacházela uvnitř dané lokality, jelikož docházelo k situacím, kdy nebyly vybrány žádné nebo jen některé polygony. Toto bylo způsobeno především tím, že oblasti kompaktní městské zástavby byly detekovány jako jeden rozsáhlý polygon.



Obr. 22 Vybrané lokality s převažujícím typem zástavby.

Odhad počtu obyvatel pro sídlištní a rodinnou zástavbu byl počítán na základě rovnic 3 a 4, přičemž byly hledány optimální hodnoty jednotlivých ukazatelů (tab. 14). Pro ostatní zástavbu byl stanoven vlastní výpočet (vzorce 7 a 8), jelikož při využití ukazatelů z tabulky 14 docházelo k výrazným odchylkám. Na pěti vybraných lokalitách byla zjišťována průměrná plocha patra a průměrný počet obyvatel na patro při využití vrstvy zástavby z nDMP o rozlišení 0,6 m/px, jelikož tato byla vyhodnocena jako přesnější (kapitola 5.2.3). Tyto hodnoty byly poté zprůměrovány. Údaj o počtu obyvatel s obvyklým pobytem byl zjištěn na základě adresních bodů s přiřazenými počty obyvatel dle SLDB 2011. Počet vybraných budov byl uvažován jako počet jednotlivých adresních bodů. Předpokládá se, že na každém patře je stejná plocha bytů.

$$\text{průměrná plocha patra} = \frac{\sum_{i=1}^N S_{stav_i}}{N} \quad (7)$$

$$\text{průměrný počet obyvatel na patro} = \frac{S_p \cdot \sum_{i=1}^N O_{adres_i}}{\sum_{i=1}^N S_{stav_i} \cdot P_i} \quad (8)$$

S_{stav} ...zastavěná plocha budovy

N ...počet vybraných budov

S_p ...průměrná plocha patra

O_{adres} ...počet obvykle bydlících obyvatel dle adresních bodů

P ...počet pater budovy

Hodnoty rozdílů a procentuální rozdíly mezi skutečným a odhadnutým počtem obyvatel byly následně zprůměrovány za všech pět lokalit, přičemž tato průměrná odchylka udává přesnost, které lze u těchto typů zástavby dosáhnout při použití optimálních ukazatelů obydlenosti a velikosti bytů. S ukazateli pro ostatní typy zástavby vypočtenými dle vzorců 7 a 8 bylo následně počítáno i v případě odhadu počtu obyvatel pro celou obec, kdy byla zástavba rozdělena na tři typy.

6.2 Obec

Bylo vycházeno z vrstev zástavby získaných v kapitole 5, vzorců 3 a 4 a údajů ze SLDB 2011 dle tabulky 14. Byly testovány vrstvy zástavby vybrané automaticky bez jakýchkoli úprav a pomocných dat, obytné zástavby, zástavby rozdělené dle výšky či zástavby, která byla manuálně rozdělena na zvolené typy dle kapitoly 6.1 (obr. 23).




Obr. 23 Detail manuálně rozdělené zástavby (červená: sídlištní, modrá: rodinná, žlutá: ostatní).

Zástavba byla rozdělena dle výšky dvěma způsoby. V prvním případě byla rozdělena na dva typy – rodinné (<9 m) a bytové domy, přičemž byly využity ukazatele pro rodinné

domy bez uvažování výšky a ukazatele pro všechny domy (tab. 14). Ve druhém případě byla rozdělena na tři typy dle kapitoly 6.1 – rodinná (<9 m), sídlištní (≥15 m) a ostatní zástavba (≥9 m a <15 m).

Manuální rozdělení zástavby proběhlo na základě vizuální interpretace autorky. Některé prvky, které byly chybně vybrány jako rezidenční zástavba, byly odstraněny. Jako kritérium pro potenciálně chybně vybranou rezidenční zástavbu byl zvolen obsah polygonu větší než 4000 m². Takto vybrané polygony byly prozkoumány a následně odstraněny či ponechány. Pět identifikovaných oblastí s chybějící rezidenční zástavbou, která nebyla definována ve vrstvě budov OSM, bylo doplněno z původních vrstev zástavby z kapitoly 5.2.3 (obr. 24).



Obr. 24 Náhled identifikovaných oblastí s chybějící rezidenční zástavbou.

6.2.1 Agregace dat

Porovnání počtu obyvatel mezi referenčními daty

GHS Population grid byl porovnán s počtem obyvatel s obvyklým pobytem ze SLDB 2011 dle adresních bodů. Pro porovnání bylo nutné vytvořit čtvercový grid, který bude odpovídat svou velikostí i pozicí gridu GHS Population. Grid byl převeden na body, které svou pozicí odpovídají středu buněk rastru, kolem kterých byly vytvořeny Thiessen polygony. Automatický nástroj *Generate Tessellation* pro tvorbu sítí nebylo možné využít, jelikož výsledná síť gridu GHS Population neodpovídala. V rámci procesu tvorby gridu

bylo zjištěno, že GHS Population grid nelze zvektorizovat tak, aby vektorová vrstva původnímu rastru odpovídala. Nebylo možné využít ani standardizovaných gridových sítí používaných na Katedře geoinformatiky UP. Tyto sítě odpovídají svou velikostí i pozici celoevropské gridové síti, nikoliv však gridu GHS Population.

Bylo předpokládáno, že vzhledem k rozlišení gridu (250 m/px) se budou počty obyvatel v různých částech území lišit, což bylo potvrzeno (viz příloha 8). Počty obyvatel Olomouce jsou zejména v centru, v oblasti Masarykovy třídy a sídlišť značně podhodnocené, zatímco v oblastech bez jakékoli zástavby se dle gridu obyvatelé vyskytují. Nejvyšší rozdíl v počtu obyvatel lze sledovat na sídlištích na Povelu a na sídlišti Jilová, kde rozdíl činí přes 1 000 obyvatel. Celkový počet obyvatel daného území se ale v rámci těchto dvou vrstev neliší nijak výrazně, dle SLDB 2011 je zde 95 791 obyvatel, dle GHS Population gridu 95 112.

Vizualizace prostorové diferenciacie obyvatel

Pro vizualizace prostorové diferenciacie obyvatel obce (přílohy 9, 10, 11, 12) byly využity vlastní hexagonové sítě o ploše buňky 1 ha vytvořené pomocí nástroje *Generate Tesselation*. Hexagonová síť je dle Zajícové (2017) pro vizualizaci prostorových statistických informací vhodnější než síť čtvercová. Zvolená plocha buňky odpovídá obsahu čtverce o straně 100 m, což umožňuje prostorovou diferenciaci obyvatel zachytit co nejpřesněji. Počty obyvatel byly do hexagonové sítě agregovány pomocí nástroje *Summarize Within*. Pro vizualizaci byly využity pouze nejpřesnější odhady počtu obyvatel obce (viz kapitola 7).

6.3 Korelační analýza

Korelační analýza byla provedena mezi počtem obyvatel s obvyklým pobytem na adresní bod dle SLDB 2011 a charakteristikami rezidenčních budov získanými dle postupů v kapitolách 5 a 6. V případě dostupnosti výšky budov byl uvažován jejich objem, u zástavby získané ze snímku Sentinel-2A byla uvažována pouze plocha. Pro případovou studii Piešťan korelace provedena nebyla, jelikož se dle referenčního datasetu GHS Population obyvatelé vyskytují i v oblastech bez jakýchkoli budov a korelace by mohla být tímto výrazně ovlivněna. Celkem bylo testováno 16 vrstev zástavby.

Korelační analýza byla provedena v softwaru RStudio pomocí funkce *cor.test* a metody Spearmanova koeficientu pořadové korelace. Tato metoda byla zvolena, jelikož data neměla normální rozdělení. Korelační koeficient nabývá hodnot od -1 do 1, kdy hodnota -1 indikuje perfektní negativní závislost, zatímco hodnota 1 perfektní pozitivní závislost (Schober a kol., 2018). Ve všech případech korelace vykazovala data p-hodnotu menší než 0,05, korelace tedy nebyla způsobena náhodou.

Korelační koeficient zaokrouhlený na tři desetinná místa se mezi sledovanými daty pohybuje v hodnotách od 0,687 do 0,949 (tab. 15). Mezi všemi získanými vrstvami zástavby a obvyklým počtem obyvatel dle SLDB 2011 tedy existuje závislost. Všechny vrstvy kromě zástavby typu „house“ vykazují dle klasifikace Schobera a kol. (2018) silnou až velmi silnou korelaci.

Nejnižší závislost byla vypočítána pro vrstvu zástavby typu „house“ získanou ze snímku Sentinel-2A. Toto lze vysvětlit především prostorovým rozlišením snímku (10 m/px), díky kterému nebylo možné optimálně detekovat jednotlivé rodinné domy. Nejvyšší závislost byla vypočítána pro vrstvu zástavby typu „apartments“ získanou ze snímku Sentinel-2A. Tato hodnota je ovšem zapříčiněná velmi nízkým zastoupením této zástavby, kdy se v Olomouci vyskytovalo pouze deset polygonů.

Druhá nejvyšší hodnota korelace byla vypočítána pro vrstvu rodinné zástavby získané z nDMP o rozlišení 0,6 m/px při manuálním rozdělení zástavby na zvolené typy. Tato hodnota koresponduje s výsledky v příloze 5, kdy při uvažování výšky rodinných domů tato vrstva vykazovala nejnížší průměrnou odchylku od skutečného počtu obyvatel. Je ovšem překvapivé, že všechny vrstvy rodinné zástavby vykazují silnou korelaci s obvyklým počtem obyvatel, a to i přes to, že v případě uvažování výšky těchto budov docházelo k řádově vyšším odchylkám než při uvažování plochy domu (viz příloha 5).

V případě rezidenční zástavby Olomouce vykazuje podle očekávání nejvyšší korelaci zástavba získaná z nDMP o rozlišení 2 m/px při manuálním rozdělení zástavby na zvolené typy, jelikož pro tuto vrstvu byl vypočítán také nejpresnější odhad počtu obyvatel (viz kapitola 7.1.2). U korelací jednotlivých typů zástavby vykazuje vyšší závislost vždy jedna z vrstev získaných z nDMP o rozlišení 0,6 m/px, což dokazuje, že i přes, to že pro celkový odhad počtu obyvatel byla přesnější vrstva získaná z nDMP o rozlišení 2m/px, nelze tvrdit, že jsou data o nižším rozlišení pro tento účel vhodnější.

Tab. 15 Korelační matice vybraných vrstev zástavby a obvyklého počtu obyvatel dle SLDB 2011

	obvyklý počet obyvatel
Olomouc A	0,870
Olomouc B	0,823
Olomouc C	0,860
Olomouc D	0,778
sídlíštní zástavba A	0,850
sídlíštní zástavba B	0,851
sídlíštní zástavba C	0,862
rodinná zástavba A	0,896
rodinná zástavba B	0,860
rodinná zástavba C	0,907
ostatní zástavba A	0,841
ostatní zástavba B	0,842
ostatní zástavba C	0,833
typ „residential“ D	0,855
typ „apartments“ D	0,949
typ „house“ D	0,687

A: zástavba získaná z nDMP o rozlišení 2 m/px při manuálním rozdělení zástavby na 3 typy

B: zástavba získaná z nDMP o rozlišení 0,6 m/px při automatickém rozdělení zástavby na 3 typy

C: zástavba získaná z nDMP o rozlišení 0,6 m/px při manuálním rozdělení zástavby na 3 typy

D: zástavba získaná ze snímku Sentinel-2A

7 VÝSLEDKY

Výsledkem práce jsou stanovené optimální postupy pro výpočet rozložení obyvatel v rámci obce či jejích částí. Byly stanoveny dva postupy pro extrakci zástavby z dat DPZ. První postup, založený na detekci zástavby na základě výšky, je vhodný v případě dostupnosti digitálních modelů povrchu a reliéfu a multispektrálního snímku pro odstranění vegetace. Druhý postup, založený na detekci zástavby pomocí spektrálních indexů a pomocných dat OSM, je vhodný pro volně dostupné multispektrální snímky. Dále byl stanoven postup pro odhad počtu obyvatel založený na metodě Housing unit. Byly stanoveny či vypočteny nejvhodnější ukazatele obydlených bytů dle sčítání lidu, které je vhodné využít pro případové studie. Nejpresnější výsledky odhadů byly vizualizovány v přílohách 9, 10, 11 a 12. Na závěr byla testována míra korelace mezi získanými vrstvami zástavby pro první případovou studii a skutečným počtem obyvatel dle SLDB 2011. Byly vypočteny vysoké hodnoty korelace pro všechna testovaná data, což indikuje jejich závislost a přiblížení se skutečnému stavu.

7.1 Případová studie I: Olomouc

7.1.1 Postup I: Obrazová klasifikace

Postup je založen na obrazové klasifikaci snímku o velmi vysokém rozlišení. Neřízená klasifikace vykazovala špatné výsledky již na základě vizuální analýzy. Z řízených klasifikací byla celkově nejpresnější objektová klasifikace metody SVM, pro třídu zástavba byla nejpresnější objektová klasifikace metody ML (viz kapitola 5.1). Ani po úpravě trénovacích dat pro tyto dvě metody nedošlo ke zlepšení přesnosti klasifikace zástavby. Postup nebyl vyhodnocen jako optimální vzhledem k neuspokojivým výsledkům klasifikací, časové a aplikační náročnosti.

7.1.2 Postup II: Analýzy nDMP

Postup je založen na extrakci zástavby na základě výškových dat při odstranění vegetace pomocí VHR multispektrálního snímku. Pro odstranění vysoké vegetace z nDMP je nejpresnější a nejrychlejší metodou využití NDVI indexu (viz kapitola 5.2.1). Pro extrakci zástavby byl stanoven vlastní postup, který zahrnuje samotnou detekci vegetace a postprocessing pro přiblížení se tvaru skutečných budov. Postupy byly s využitím nástroje *ModelBuilder* automatizovány. Zástavba byla detekována za celkové přesnosti 82 % z nDMP o rozlišení 2 m/px a 91 % z nDMP o rozlišení 0,6 m/px. Při přesném odstranění vegetace bylo na testovacím území dosaženo přesnosti 100 % (viz kapitola 5.2.3).

Odhad počtu obyvatel pro části obce

Odhad byl realizován pro vrstvy zástavby získané dle nDMP bez pomocných dat pro pět lokalit zvolených v kapitole 6.1. Pro **sídlíštní typ zástavby** lze nejpresnějšího výsledku dosáhnout při využití nDMP o rozlišení 0,6 m/px a úrovnových ukazatelů pro všechny domy (86, 7 m² na byt; 2,47 osob na byt). Průměrná odchylka činí **± 263 obyvatel**, průměrný procentuální rozdíl **± 7,15 %** (viz příloha 4).

Pro **rodinný typ zástavby** lze nejpresnějších výsledků dosáhnout při využití nDMP o rozlišení 2 m/px a úrovnových ukazatelů pro rodinné (109,1 m² na byt; 2,8 osob na byt) nebo všechny domy (86, 7 m² na byt; 2,47 osob na byt) bez uvažování výšky budov. Průměrná odchylka při uvažování úrovnových ukazatelů pro rodinné domy činí **± 82 obyvatel**, průměrný procentuální rozdíl **± 25,60 %**. Průměrná odchylka při

uvažování úrovnových ukazatelů pro všechny domy činí ± 79 obyvatel, průměrný procentuální rozdíl $\pm 26,22$ % (viz příloha 5).

Pro **ostatní typy zástavby** byl stanoven vlastní výpočet úrovnových ukazatelů (viz kapitola 6.1, vzorce 7 a 8), jelikož při využití údajů ze SLDB 2011 byla přesnost odhadů velmi nízká. Průměrná bytová plocha na patro byla stanovena na 313,49 m², průměrný počet obyvatel na patro na 3,5. Tyto údaje byly následně využity také pro odhad počtu obyvatel obce. Nejpresnějšího výsledku lze dosáhnout při využití nDMP o rozlišení 2 m/px, kdy průměrná odchylka činí ± 167 obyvatel, průměrný procentuální rozdíl $\pm 25,25$ %. Při využití nDMP o rozlišení 0,6 m/px lze ve všech lokalitách kromě lokality 4 dosáhnout přesnějšího výsledku, ovšem celková průměrná odchylka je vyšší (viz příloha 6).

Odhad počtu obyvatel obce

Nejpřesnějších výsledků lze dosáhnout při manuálním rozdělení zástavby na tři typy: sídlištní, rodinnou a ostatní a doplnění chybějící rezidenční zástavby v OSM při využití zástavby získané na základě nDMP o rozlišení 2 m/px. Pro sídlištní zástavbu byly využity úrovnové ukazatele pro všechny domy (86, 7 m² na byt; 2,47 osob na byt), pro rodinnou zástavbu ukazatele pro rodinné domy při zanedbání výšky budov (109,1 m² na byt; 2,8 osob na byt), pro ostatní typy zástavby ukazatele vypočítané dle vlastního výpočtu (vzorce 7 a 8). Výsledný odhad počtu obyvatel je **95 618**, přičemž rozdíl oproti skutečnému počtu dle adresních bodů (95 791) činí **-173** obyvatel, procentuální rozdíl **-0,18** %. Vizualizace prostorové diferenciacce obyvatel dle tohoto odhadu je dostupná v příloze 9. Je překvapivé, že při využití zástavby z nDMP o rozlišení 0,6 m/px, která byla detekována přesněji (viz kapitola 5.2.3), je přesnost odhadu nižší. Výsledný odhad činí 102 639 obyvatel, rozdíl oproti skutečnému počtu 7 012 obyvatel, procentuální rozdíl 7,33 %.

Přesnější výsledky odhadu počtu obyvatel v případě využití nDMP o nižším rozlišení jsou pravděpodobně způsobeny náhodnou chybou, kterou nebylo možné ovlivnit. Nelze říci, že data o nižším rozlišení jsou pro odhad počtu obyvatel vhodnější.

Nejpřesnějšího výsledku bez nutnosti manuální editace lze dosáhnout v případě rozdělení zástavby na tři typy dle výšky budov při využití zástavby z nDMP o rozlišení 0,6 m/px. Jako rodinný typ byly zvoleny budovy menší než 9 m, jako sídlištní budovy o výšce 15 m a více. Budovy s výškou 9 m a více a zároveň menší než 15 m byly uvažovány jako ostatní typy zástavby. Výsledný odhad počtu obyvatel je **102 467**, přičemž rozdíl oproti skutečnému počtu dle adresních bodů (95 627) činí **6 840** obyvatel, procentuální rozdíl **7,15** %. Zde lze sledovat téměř totožný výsledek jako při manuálním rozdělení zástavby, což poukazuje na přesnější detekci výšky budov oproti zástavbě získané dle nDMP o rozlišení 2 m/px. Vizualizace prostorové diferenciacce obyvatel dle tohoto odhadu je dostupná v příloze 10.

7.1.3 Postup III: Spektrální indexy

Postup stanovený pro snímky Sentinel-2A je založen na kombinaci spektrálních indexů, prahování snímku a pomocných datech OSM. Při využití spektrálních indexů a prahování lze zástavbu extrahovat při celkové přesnosti 89 %, nelze však spolehlivě odstranit silnice. Při kombinaci s pomocnými daty lze dosáhnout celkové přesnosti 92 % (viz kapitola 5.3).

Nejpřesnějších výsledků lze dosáhnout při uvažování rozdělení zástavby na tři typy dle OSM. Pro zástavbu s převažujícím typem „residential“ byly využity úrovnové ukazatele pro všechny domy (86, 7 m² na byt; 2,47 osob na byt), pro převažující typ „house“ ukazatele pro rodinné domy (109,1 m² na byt; 2,8 osob na byt), pro převažující typ

„apartments“ ukazatele pro bytové domy (68,5 m² na byt; 2,21 osob na byt). Výsledný odhad počtu obyvatel je **113 748**, přičemž rozdíl oproti skutečnému počtu dle adresních bodů činí **17 957** obyvatel, procentuální rozdíl **18,75 %**. Vizualizace prostorové diferenciacie obyvatel dle tohoto odhadu je dostupná v příloze 11. Ostatní relevantní odhady počtu obyvatel jsou dostupné v příloze 7, veškeré výpočty včetně odhadů na přiloženém DVD.

7.2 Případová studie II: Piešťany

Pro případovou studii obce Piešťany byly dle postupu v kapitole 5.3.1 a vizuální analýzy vybrány polygony zástavby, jejichž plocha byla pokryta vrstvou obytných budov z OSM z více než 25 %. Jako obytné budovy dle OSM zde byly zvoleny všechny, které neměly typ definován a dále typy „residential“, „house“ a „apartments“. Nebylo možné rozdělit zástavbu dle typů budov OSM jako u případové studie Olomouce, jelikož více než 98 % všech záznamů atribut „type“ neobsahovalo. Byly odstraněny pouze některé budovy, které dle vizuální interpretace nebyly určeny k bydlení (např. hotelový komplex na „Kúpeľnom ostrove“ nebo průmyslový areál v západní části města). Pro výpočet obyvatel byl využit vzorec 3 při uvažování proměnných dle SODB 2011 pro Slovensko:

- průměrný počet osob na 1 byt: 3 (Juhaščíková a kol., 2014),
- celková plocha na 1 byt: 115,8 m² (Štatistický úrad Slovenskej republiky, 2020).

Při manuálním odstranění některých budov činil výsledný odhad **45 182** obyvatel, přičemž rozdíl oproti skutečnému počtu dle gridu GHS Population (27 575) byl **17 607** obyvatel, průměrný procentuální rozdíl **63,85 %**. Vzhledem k neoptimálnímu výsledku byl rozdíl v počtu a prostorové diferenciaci obyvatel vizualizován v příloze 13. Došlo k významnému nadhodnocení počtu obyvatel v centru města, především v oblastech s rodinným typem zástavby, který je ve městě dominantní.

Bez odstranění vybraných budov činil výsledný odhad **56 220** obyvatel, přičemž rozdíl oproti skutečnému počtu dle gridu GHS Population byl **28 645** obyvatel, průměrný procentuální rozdíl **103,88 %**.

Z výsledků práce vyplývá, že zástavbu lze detekovat nejpřesněji na základě výšky. Digitální výškové modely výrazně zvyšují přesnost detekce zástavby a zároveň umožňují při výpočtu obyvatel zohlednit výšku, počet pater či objem budov, což je pro odhady počtu obyvatel měst žádoucí. Satelitní snímky je vhodné použít především jako podpůrná data pro odstranění vegetace z nDMP. V případě, kdy jsou využita pouze data DPZ, není možné spolehlivě rozdělit zástavbu obce na obytnou a neobytnou. Optimální odhad počtu obyvatel pomocí dat DPZ je tedy možný v případě menších částí obce, které lze s jistotou označit jako rezidenční. Pro celou obec je nutné pro stanovení obytné zástavby využít pomocných dat. Odhady počtu obyvatel na základě satelitních snímků Sentinel-2A a dat OSM vykazují odchylku přibližně 18 tisíc obyvatel u obou případových studií. Tato data jsou tedy vhodná především pro orientační stanovení počtu obyvatel populačně velkých měst.

8 DISKUZE

V průběhu řešení práce se vyskytla řada problémů, na které bylo nutné se zaměřit. Hlavní cíl práce, a to sestavení optimálních postupů pro stanovení prostorové diferenciaci obyvatel na základě dat DPZ, byl naplněn. Navrhnuté postupy mají ale své limity.

Limitací postupu založeného na analýzách nDMP je posunutí snímku QuickBird vůči digitálním výškovým modelům, a tedy neoptimální odstranění vegetace. Tento problém nebylo možné vyřešit, jelikož posunutí vzniklo již při pořízení snímku v důsledku centrální projekce. Výsledky postupu, především vzniklá vrstva budov, jsou tímto negativně ovlivněny. Bylo nutné použít značně nadhodnocené parametry nástroje *Regularize Building Footprint*, aby se vzniklá vrstva přiblížila tvaru skutečných budov. Na druhou stranu ale tímto utrpěl především tvar nepravoúhlých budov. V návaznosti na tento problém bylo testováno manuální odstranění vegetace na malém území, přičemž bylo potvrzeno, že v případě korektního odstranění vykazuje přesnost detekce budov až 100 %. Metody automatického odstranění vegetace přímo z nDMP by bylo vhodné dále zkoumat. Výšky budov v nDMP mohly být ovlivněny převodem dat ze souřadnicového systému S-JTSK do souřadnicového systému satelitních snímků WGS UTM zone 33N. Bylo záměrem otestovat postup zahrnující analýzy nDMP také na případové studii města Piešťany. Vzhledem k objemu a rozsahu práce ale bylo od tohoto upuštěno.

Výsledky klasifikace bodového mračna pomocí pluginu CSF nejsou stoprocentní. Ve finálním DMR lze sledovat výrazné chyby především v oblasti vodních ploch a toků, které by bylo vhodné odstranit na základě již existujících dat či manuálně. V práci tento problém nebyl řešen vzhledem k tomu, že finální vrstva obytných budov byla vybrána na základě dat OSM, čímž byly tyto oblasti odstraněny.

Limitací postupu pro volně dostupná data je nutnost zakomponování pomocných dat OSM již v procesu extrakce zástavby pro její zpřesnění a odstranění komunikací. Bylo zjištěno, že zástavbu nelze optimálně detekovat pouze na základě volně dostupných satelitních snímků vzhledem k jejich prostorovému rozlišení. Celková přesnost zástavby v tomto případě sice byla 92 %, avšak tato přesnost byla hodnocena vzhledem ke snímku Sentinel-2A a lze předpokládat, že při porovnání s VHR snímkem bude řádově nižší.

Odhady počtu obyvatel pro obec jsou závislé na spolehlivém rozdělení zástavby na obytnou a neobytnou, což ve své práci potvrzují také Steinnocher a kol. (2019). Toto rozdělení nebylo možné provést na základě dat DPZ, jelikož neobytné budovy nevykazují jiné spektrální chování než obytné. Původním záměrem bylo toto rozdělení provést na základě velikosti budov, což nebylo možné realizovat vzhledem k charakteru kompaktní městské zástavby v Olomouci a rozlišení snímku Sentinel-2A v případě Piešťan. U obou případových studií docházelo ke sloučení na sebe navazujících budov do jednoho celku. Zde se nabízí potenciál pro další zkoumání pokročilých metod obrazové klasifikace, a to segmentace instancí objektů.

Pro určení obytné zástavby bylo tedy využito volně dostupných dat z OSM. Jelikož se ale jedná o databázi, kterou může volně upravovat každý, nelze se na tato data plně spolehnout. Toto bylo potvrzeno jak v případě Olomouce, kde určité skupiny rezidenčních budov chyběly, tak na studii Piešťan, kde atribut týkající se typu budovy chyběl u více než 98 % záznamů, a nebylo tedy možné spolehlivě definovat rezidenční zástavbu.

Přesnější výsledky odhadu počtu obyvatel v případě využití nDMP o nižším rozlišení, které se ve vysoké míře přibližují skutečnému stavu, jsou pravděpodobně způsobeny náhodnou chybou, kterou nebylo možné ovlivnit. Toto mohlo být způsobeno především nesprávnou výškou vstupních dat (DMR 5G a DMP 1 G). Nelze vyvozovat závěry, že data o nižším rozlišení jsou pro odhad počtu obyvatel vhodnější.

Určité chyby v odhadu počtu obyvatel mohly být zapříčiněny také nekonzistentností použitých dat z pohledu data jejich pořízení. Pro bakalářskou práci ovšem nebyla k dispozici jiná relevantní data. Údaje z GHS Population gridu, které byly použity jako referenční data pro případovou studii Piešťan nejsou tak přesné jako údaje ze SLDB 2011 vztažené na adresní body. Bylo potvrzeno, že dle těchto dat se obyvatelé vyskytují i v místech bez jakékoli zástavby, zatímco v oblastech s jejich vysokou hustotou jsou počty podhodnocené. Vzhledem k tomu, že v roce 2021 bude probíhat další SLDB, by bylo také vhodné odhady počtu obyvatel aktualizovat a zhodnotit vzhledem k novějším datům.

Řešené téma je natolik široké, že nebylo možné v rámci bakalářské práce postihnout všechny vhodné metody a data pro stanovení počtu obyvatel. Na práci by bylo vhodné navázat testováním prostorové korelace a regresní analýzy pro účely stanovení odhadu počtu obyvatel. Dalším potenciálem jsou také pokročilé metody obrazové klasifikace, např. hierarchická či již zmíněná segmentace instancí objektů. Díky těmto metodám by mohla být umožněna velmi přesná detekce budov pouze na základě multispektrálního satelitního snímku, což v bakalářské práci nebylo možné. V neposlední řadě by bylo vhodné stanovené postupy otestovat na větším počtu případových studií, postihnout různé prostorové struktury – jak zástavbu vesnickou, tak zástavbu metropolitních měst. Data DPZ také nabízí potenciál pro odhady počtu obyvatel v rozvojových zemích či pro humanitární účely. Jedná se avšak o velmi specifické aplikace s limitovanou dostupností vstupních i referenčních dat.

Na závěr je nutné zmínit, že práce má především experimentální zaměření. Slouží pro další testování dat DPZ pro daný účel. Pro přímé zavedení postupů v praxi by bylo zapotřebí provést dlouhodobější výzkum, k čemuž práce poskytuje podklady.

9 ZÁVĚR

Bakalářská práce se zabývá problematikou stanovení počtu obyvatel obce na základě dat DPZ. Cílem práce bylo stanovit optimální postupy pro zjištění diference počtu obyvatel v rámci města při využití družicových a leteckých snímků a digitálních modelů povrchu a výsledky porovnat s referenčními daty. Postupy byly otestovány na dvou případových studiích, z nichž první je zaměřena na město Olomouc, druhá na město Piešťany.

Postupy byly rozděleny na dvě části, a to extrakci zástavby a odhad počtu obyvatel. Pro extrakci zástavby byly stanoveny dva optimální postupy. První postup sestávající z analýz nDMP je vhodný v případě dostupnosti výškových dat, jako jsou digitální modely povrchu a reliéfu, a multispektrálního snímku o velmi vysokém rozlišení. Pomocí snímku je odstraněna z nDMP vysoká vegetace. Budovy jsou následně vybrány na základě minimální výšky, která byla stanovena na tři metry. Pro přiblížení se tvaru skutečných budov je následně vrstva zpracována pomocí nástrojů *Majority Filter*, *Raster to Polygon*, *Aggregate Polygons*, *Summarize Within* a *Regularize Buidling Footprint*. Výsledné vrstvy budov vykazovaly celkovou přesnost 82 % (nDMP 2 m/px) a 91 % (nDMP 0,6 m/px). Postup byl automatizován pomocí nástroje *ModelBuilder*.

Druhý postup sestávající z využití spektrálních indexů, prahování snímku a pomocných dat OSM je vhodný pro volně dostupné satelitní snímky Sentinel-2A. Je využito spektrálních indexů NDVI a NDI (Vigneshwaran a Vasantha, 2018) a prahování NIR pásma pro odstranění vodních ploch. Pro zlepšení přesnosti identifikace zástavby je následně využito dat OSM. V případě obou postupů je finálním krokem výběr obytné zástavby, pro který byla využita data OSM.

Odhady počtu obyvatel byly pro případovou studii Olomouce realizovány jak pro části obce s převažujícím typem zástavby, tak pro celou obec. Byly stanoveny tři typy zástavby – sídlištní, rodinná a ostatní, kam spadá především nízkopodlažní bytová a kompaktní městská zástavba. Pro sídlištní a rodinný typ zástavby byly stanoveny optimální ukazatele velikosti a obydlenosti bytů dle SLDB 2011, pro ostatní typ byly tyto údaje vypočteny dle adresních bodů s přiřazenými počty obyvatel. V rámci obce se nejpřesnější odhady počtu obyvatel lišily vůči referenčním datům o -0,18 % v případě manuálního výběru typů zástavby a o 7,15 % v případě automatického výběru dle výšky. Pro zástavbu získanou ze snímku Sentinel-2A byly stanoveny tři typy zástavby dle OSM. Nejpřesnější odhad počtu obyvatel se lišil o 18,75 %.

Pro případovou studii Piešťan byl využit pouze postup vytvořený pro snímky Sentinel-2A. Nejpřesnější odhad počtu obyvatel se lišil o 63,85 %, což indikuje, že stanovený postup je vhodný pro orientační stanovení počtu obyvatel populačně velkých měst.

Bylo zjištěno, že zástavbu lze z dat DPZ detekovat nejpřesněji na základě výšky, zatímco satelitní snímky je vhodné použít především jako podpůrná data pro odstranění vegetace z nDMP. Odhad počtu obyvatel pro celou obec je závislý především na spolehlivém stanovení obytných budov, čehož bylo možné v práci docílit pouze při využití pomocných dat z OSM. Práce poslouží jako podklad pro další experimentální testování dat DPZ pro účely stanovení počtu obyvatel.

POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

ALAHMADI, Mohammed, Peter ATKINSON a David MARTIN, 2016. A Comparison of Small-Area Population Estimation Techniques Using Built-Area and Height Data, Riyadh, Saudi Arabia. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* [online]. 9(5), 1959–1969 [cit. 2019-11-29]. DOI: 10.1109/jstars.2014.2374175. Dostupné z: <https://doi.org/10.1109/JSTARS.2014.2374175>

ALAHMADI, Mohammed, Peter ATKINSON a David MARTIN, 2013. Estimating the spatial distribution of the population of Riyadh, Saudi Arabia using remotely sensed built land cover and height data. *Computers, Environment and Urban Systems* [online]. Elsevier Ltd, 41, 167-176 [cit. 2019-07-14]. DOI: 10.1016/j.compenvurbsys.2013.06.002. ISSN 01989715. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0198971513000598>

Analýzy výškopisu [online], 2020. Praha: ČÚZK [cit. 2020-05-11]. Dostupné z: <https://ags.cuzk.cz/dmr/>

BATER, Christopher W. a Nicholas C. COOPS, 2009. Evaluating error associated with LiDAR-derived DEM interpolation. *Computers and Geosciences* [online]. 35(2), 289-300 [cit. 2020-03-15]. DOI: 10.1016/j.cageo.2008.09.001. ISSN 00983004. Dostupné z: <https://doi.org/10.1016/j.cageo.2008.09.001>

BLASCHKE, Thomas a Josef STROBL, 2001. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *Geo-Information-Systeme* [online]. 14(6), 12-17 [cit. 2019-07-19]. ISSN 09351523. Dostupné z: https://www.researchgate.net/publication/216266284_What's_wrong_with_pixels_Some_recent_developments_interfacing_remote_sensing_and_GIS

BLASCHKE, Thomas a kol., 2014. Geographic Object-Based Image Analysis – Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing* [online]. 87, 180-191 [cit. 2019-07-14]. DOI: 10.1016/j.isprsjprs.2013.09.014. ISSN 09242716. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0924271613002220>

ČSÚ, 2014. *Domovní a bytový fond podle výsledků sčítání lidu*. Praha: ČSÚ. Dostupné také z: <https://www.czso.cz/csu/czso/domovni-a-bytovy-fond-podle-vysledku-scitani-lidu-2011-nrabysni6f>. Kód publikace: 170216-14.

ČSÚ, 2015. Metodika SLDB 2011. *Český statistický úřad* [online] [cit. 2020-03-07]. Dostupné z: <https://www.czso.cz/csu/czso/metodika-sldb-2011>

ČSN 73 4301, 2004. *Obytné budovy*. Praha: Úřad pro technickou normalizaci, metrologii a státní zkušebnictví.

DOBROVOLNÝ, Petr, 1998. *Dálkový průzkum Země: digitální zpracování obrazu*. 1. vydání. Brno: Masarykova univerzita. ISBN 8021018127.

DUŠÁNEK, Petr, 2014. Projekt tvorby nového výškopisu České republiky. *Gisat* [online]. [cit. 2020-05-28]. Dostupné z: http://gisak.vsb.cz/GIS_Ostrava/GIS_Ova_2014/sbornik/papers/gis2014526faa8a434ef.pdf

ESRI, 2019. LAS Dataset To Raster function. *ArcGIS Desktop | Documentation* [online]. Redlands, USA [cit. 2020-05-26]. Dostupné z: <https://desktop.arcgis.com/en/arcmap/latest/manage-data/raster-and-images/las-dataset-to-raster-function.htm#>

ESRI, 2020a. *ArcGIS Pro help* [online]. Redlands, USA [cit. 2020-03-29]. Dostupné z: <https://pro.arcgis.com/en/pro-app/help>

ESRI, 2020b. *Imagery [basemap]. World Imagery* [online]. Redlands, USA [cit. 2020-04-02]. Dostupné z: <https://www.arcgis.com/home/item.html?id=10df2279f9684e4a9f6a7f08febac2a9>

ETTEHADI OSGOUEI, Paria a kol., 2019. Separating Built-Up Areas from Bare Land in Mediterranean Cities Using Sentinel-2A Imagery. *Remote Sensing* [online]. 11(3) [cit. 2020-03-10]. DOI: 10.3390/rs11030345. ISSN 2072-4292. Dostupné z: <http://www.mdpi.com/2072-4292/11/3/345>

ESA, 2020. *Level 2A Processing Overview* [online]. [cit. 2020-05-11]. Dostupné z: <https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/level-2a-processing>

FISHER, Peter a Mitchel LANGFORD, 1996. Modeling sensitivity to accuracy in classified imagery: A study of areal interpolation by dasymetric mapping. *Professional Geographer* [online]. 48(3), 299-309 [cit. 2019-11-29]. DOI: 10.1111/j.0033-0124.1996.00299.x. ISSN 14679272. Dostupné z: <https://doi.org/10.1111/j.0033-0124.1996.00299.x>

FLORCZYK, Aneta J. a kol., 2019. *GHSL Data Package 2019* [online]. Luxembourg: Publications Office of the European Union [cit. 2020-03-30]. ISBN 978-92-76-08725-0. Dostupné z: https://ghsl.jrc.ec.europa.eu/stg19/cfs1_1/documents/GHSL_Data_Package_2019.pdf

GIRARDEAU-MONTAUT, Daniel, 2017. Maximum file's size. *CloudCompare forum* [online]. [cit. 2020-03-14]. Dostupné z: <https://www.danielgm.net/cc/forum/viewtopic.php?t=2383>

GUO, Hui, Kai CAO a Peng WANG, 2017. Population estimation in Singapore based on remote sensing and open data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. [cit. 2020-03-08]. DOI: 10.5194/isprs-archives-XLII-2-W7-1181-2017. ISSN 16821750. Dostupné z: <https://doi.org/10.5194/isprs-archives-XLII-2-W7-1181-2017>

HARRIS GEOSPATIAL SOLUTIONS, INC, 2020. Feature Extraction with Example-Based Classification Tutorial. *Remote Sensing Technologies / Geospatial Data and Imagery / L3Harris Geospatial* [online]. Broomfield [cit. 2020-03-14]. Dostupné z: <https://www.harrisgeospatial.com/docs/FXExampleBasedTutorial.html>

HOLT, James, Chor P. LO a Thomas HODLER, 2004. Dasymetric Estimation of Population Density and Areal Interpolation of Census Data. *Cartography and Geographic Information Science* [online]. 31(2), 103-121 [cit. 2019-11-29]. DOI: 10.1559/1523040041649407. Dostupné z: <https://doi.org/10.1559/1523040041649407>

IISAKA, Joji a Eموke HEGEDUS, 1982. Population estimation from Landsat imagery. *Remote Sensing of Environment* [online]. 12(4), 259-272 [cit. 2019-11-29]. DOI: 10.1016/0034-4257(82)90039-6. Dostupné z: <https://www.sciencedirect.com/science/article/abs/pii/0034425782900396>

JUHAŠČÍKOVÁ, Ivana a kol., 2014. *Fakty o zmenách v živote obyvateľov SR: Sčítanie obyvateľov, domov a bytov 2011* [online]. Bratislava: Štatistický úrad Slovenskej republiky [cit. 2020-04-08]. ISBN 978-80-8121-370-0. Dostupné z: <https://slovak.statistics.sk>

KLAUDA, Petr. Prostorově určená statistická data. *Statistika&My*. Praha: ČSÚ, 2016, 6(5), 18-19. ISSN 1804-7149.

KOLAŘÍK, Jan, 2012. *Dasymetrické mapování rozložení obyvatelstva v zastavěném území*. Olomouc. Bakalářská práce. Univerzita Palackého v Olomouci, Přírodovědecká fakulta. Vedoucí práce Mgr. Alena Vondráková.

LILLESAND, Thomas, Ralph KIEFER a Jonathan CHIPMAN, 2008. *Remote sensing and image interpretation*. 6th ed. New York: John Wiley. ISBN 04-700-5245-7.

LO, Chor P., 1986. *Applied Remote Sensing*. Harlow: Longman. ISBN 0-582-30132-7.

LU, Zhenyu, Jungho IM, Lindi QUACKENBUSH a Kerry HALLIGAN, 2010. Population estimation based on multi-sensor data fusion. *International Journal of Remote Sensing* [online]. 31(21), 5587-5604 [cit. 2019-11-29]. DOI: 10.1080/01431161.2010.496801. Dostupné z: <https://doi.org/10.1080/01431161.2010.496801>

POUR, Tomáš, 2015. *Pokročilá extrakce prostorových informací z družicových snímků vysokého rozlišení*. Olomouc. Diplomová práce. Univerzita Palackého v Olomouci, Přírodovědecká fakulta. Vedoucí práce RNDr. Jaroslav Burian, Ph.D.

RAO, J., 2003. *Small area estimation*. Hoboken: Wiley. ISBN 0471413747.

RAYER, Stefan, 2015. Demographic Techniques: Small-area Estimates and Projections. *International Encyclopedia of the Social & Behavioral Sciences*. 2nd ed. Elsevier Ltd, s. 162-169. ISBN 978-0-08-097086-8.

SCHOBER, Patrick, Christa BOER a Lothar A. SCHWARTE, 2018. Correlation Coefficients: Appropriate Use and Interpretation. *Anesthesia & Analgesia*. 126(5), 1763-1768. DOI: 10.1213/ANE.0000000000002864.

SKARLATOS, Dimitrios a Marinos VLACHOS, 2018. Vegetation removal from UAV derived DSMs, using combination of RGB and NIR imagery. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. 255-262 [cit. 2020-03-14]. DOI: 10.5194/isprs-annals-IV-2-255-2018. ISSN 21949042. Dostupné z: <https://doaj.org/article/911abdd98e13425499b5008c20f1bf07>

STEINNOCHER, Klaus, Andrea DE BONO, Bruno CHATENOUX, Dird TIEDE, Lisiane WENDT, 2019. Estimating urban population patterns from stereo-satellite imagery. *European Journal of Remote Sensing* [online]. Taylor & Francis Group, 1-14 [cit. 2019-07-14]. DOI: 10.1080/22797254.2019.1604081. ISSN 22797254. Dostupné z: <https://www.tandfonline.com/doi/full/10.1080/22797254.2019.1604081>

ŠSTATISTICKÝ ÚRAD SLOVENSKEJ REPUBLIKY, 2020. Dokončené byty podľa počtu izieb a priemernej plochy - ročné údaje. *Verejná databáza DATAcube* [online]. Bratislava: Štatistický úrad Slovenskej republiky [cit. 2020-04-08]. Dostupné z: http://datacube.statistics.sk/#!/view/sk/VBD_SLOVSTAT/st2001rs/v_st2001rs_00_0_00_sk

VÚGTK, 2020. *Terminologický slovník VÚGTK* [online]. Terminologická komise ČÚZK [cit. 2020-03-29]. Dostupné z: <https://www.vugtk.cz/slovník>

TOBLER, Waldo, 1969. Satellite Confirmation of Settlement Size Coefficients. *Area* [online]. Institute of British Geographers, 1(3), 30 [cit. 2019-11-15]. ISSN 00040894. Dostupné z: <https://www.jstor.org/stable/20000359>

TÖGELOVÁ, Eva, 2011. *Porovnání "per-pixel" klasifikátorů pro identifikaci zástavby*. Olomouc. Bakalářská práce. Univerzita Palackého v Olomouci, Přírodovědecká fakulta. Vedoucí práce RNDr. Jakub Miřijovský, Ph.D.

UNITED NATIONS, 2020. Demographic and Social Statistics. *United Nations Statistics Divison* [online]. New York [cit. 2020-05-21]. Dostupné z: <https://unstats.un.org/unsd/demographic-social/>

VIGNESHWARAN, Saravanan a S. VASANTHA KUMAR, 2018. Extraction of Built-up Area Using High Resolution Sentinel-2A and Google Satellite Imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. [cit. 2020-03-08]. DOI: 10.5194/isprs-archives-XLII-4-W9-165-2018. ISSN 16821750. Dostupné z: <https://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-4-W9/165/2018/>

VOŽENÍLEK, Vít a Jaromír KAŇOK, 2011. *Metody tematické kartografie: vizualizace prostorových jevů*. Olomouc: Univerzita Palackého v Olomouci pro Katedru geoinformatiky. ISBN 978-80-244-2790-4.

WU, Changshan a Alan MURRAY, 2007. Population Estimation Using Landsat Enhanced Thematic Mapper Imagery. *Geographical Analysis* [online]. 39(1), 26-43 [cit. 2019-11-15]. DOI: 10.1111/j.1538-4632.2006.00694.x. ISSN 00167363. Dostupné z: <https://doi.org/10.1111/j.1538-4632.2006.00694.x>

WU, Shuo-sheng, Xiaomin QIU a Le WANG, 2005. Population Estimation Methods in GIS and Remote Sensing: A Review. *GIScience & Remote Sensing* [online]. 42(1), 80-96 [cit. 2019-11-15]. DOI: 10.2747/1548-1603.42.1.80. Dostupné z: <https://pdfs.semanticscholar.org/4744/ce28cce9862ea82c3690f8db5d3f98efa8d5.pdf>

ZAJÍCOVÁ, Hana, 2017. *Srovnání prostorové reprezentace adresních bodů grid/areály*. Olomouc. Bakalářská práce. Univerzita Palackého v Olomouci, Přírodovědecká fakulta. Vedoucí práce RNDr. Jaroslav Burian, Ph.D.

ZAPLETAL, Jan, 2019. *Testování disagregačních metod v GIS*. Olomouc. Bakalářská práce. Univerzita Palackého v Olomouci, Přírodovědecká fakulta. Vedoucí práce RNDr. Jaroslav Burian, Ph.D.

ZHANG, Wuming, Jianbo QI, Peng WAN, Hongtao WANG, Donghui XIE, Xiaoyan WANG a Guangjian YAN, 2016. An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. *Remote Sensing* [online]. 8(6), 501-522 [cit. 2020-04-04]. DOI: 10.3390/rs8060501. ISSN 20724292. Dostupné z: <https://www.mdpi.com/2072-4292/8/6/501>

PŘÍLOHY

SEZNAM PŘÍLOH

Vázané přílohy:

- Příloha 1 Testovaná nastavení nástroje Iso Cluster Unsupervised Classification
- Příloha 2 Chybové matice řízených klasifikací
- Příloha 3 Chybové matice pro metody detekce vegetace
- Příloha 4 Výsledky odhadů počtu obyvatel pro sídlištní typ zástavby
- Příloha 5 Výsledky odhadů počtu obyvatel pro rodinný typ zástavby
- Příloha 6 Výsledky odhadů počtu obyvatel pro ostatní typy zástavby
- Příloha 7 Výsledky odhadů počtu obyvatel obce Olomouc
- Příloha 8 Mapa: Rozdíl v počtu obyvatel Olomouce mezi údaji ze SLDB 2011 a z gridu GHS Population 2015
- Příloha 9 Mapa: Prostorová diferenciacie obyvatel Olomouce dle nDMP o rozlišení 2 m/px z roku 2016
- Příloha 10 Mapa: Prostorová diferenciacie obyvatel Olomouce dle nDMP o rozlišení 0,6 m/px z roku 2016
- Příloha 11 Mapa: Prostorová diferenciacie obyvatel Olomouce dle snímku Sentinel-2 A z roku 2019
- Příloha 12 Mapa: Prostorová diferenciacie obyvatel Piešťan dle snímku Sentinel-2 A z roku 2019
- Příloha 13 Mapa: Rozdíl v počtu obyvatel území Piešťan mezi údaji z gridu GHS Population 2015 a odhadem dle snímku Sentinel 2 2019

Volné přílohy

- Příloha 14 Poster
- Příloha 15 DVD

Popis struktury DVD

Adresáře:

Text_Prace

Vstupni_Data

Vystupni_Data

Prilohy

WEB

Následující data jsou vzhledem k jejich neveřejné povaze uložena na Katedře geoinformatiky UP. Jedná se o snímek QuickBird, výsledky metody pan-sharpening, bodové mračno vygenerované dle leteckých snímků, veškeré vstupní DMP a DMR, vrstvu adresních bodů ČSÚ.

Příloha 1: Testovaná nastavení nástroje Iso Cluster Unsupervised Classification

Počet tříd	Min. velikost třídy	Interval vzorkování
5	20	10
6	20	10
6	40	10
6	5000	40
7	20	10
7	50	20
7	100	40
8	20	10
256	20	10

Příloha 2: Chybové matice řízených klasifikací

Chybová matice snímku klasifikovaného pomocí per-pixel klasifikace metody ML

[illegible]

Chybová matice snímku klasifikovaného pomocí objektové klasifikace metody ML

[illegible]

Příloha 3: Chybové matice pro metody detekce vegetace

Chybová matice vegetace klasifikované pomocí per-pixel klasifikace metody ML

Třída	Vegetace	Ostatní	Celkem	PU [%]	Kappa
Vegetace	51	4	55	0,93	0
Ostatní	2	93	95	0,98	0
Celkem	53	97	150	0	0
PZ [%]	0,96	0,96	0	0,96	0
Kappa	0	0	0	0	0,91

Chybová matice vegetace klasifikované pomocí objektové klasifikace metody ML

Třída	Vegetace	Ostatní	Celkem	PU [%]	Kappa
Vegetace	46	6	52	0,88	0
Ostatní	3	95	98	0,97	0
Celkem	49	101	150	0	0
PZ [%]	0,94	0,94	0	0,94	0
Kappa	0	0	0	0	0,87

Chybová matice vegetace klasifikované pomocí per-pixel klasifikace metody RT

Třída	Vegetace	Ostatní	Celkem	PU [%]	Kappa
Vegetace	55	2	57	0,96	0
Ostatní	1	92	93	0,99	0
Celkem	56	94	150	0	0
PZ [%]	0,98	0,98	0	0,98	0
Kappa	0	0	0	0	0,96

Chybová matice vegetace klasifikované pomocí objektové klasifikace metody RT

Třída	Vegetace	Ostatní	Celkem	PU [%]	Kappa
Vegetace	46	0	46	1	0
Ostatní	7	97	104	0,93	0
Celkem	53	97	150	0	0
PZ [%]	0,87	1	0	0,95	0
Kappa	0	0	0	0	0,89

Chybová matice vegetace klasifikované pomocí per-pixel klasifikace metody SVM

Třída	Vegetace	Ostatní	Celkem	PU [%]	Kappa
Vegetace	53	5	58	0,91	0
Ostatní	2	90	92	0,98	0
Celkem	55	95	150	0	0
PZ [%]	0,96	0,95	0	0,95	0
Kappa	0	0	0	0	0,90

Chybová matice vegetace klasifikované pomocí objektové klasifikace metody SVM

Třída	Vegetace	Ostatní	Celkem	PU [%]	Kappa
Vegetace	49	4	53	0,92	0
Ostatní	3	94	97	0,97	0
Celkem	52	98	150	0	0
PZ [%]	0,94	0,96	0	0,95	0
Kappa	0	0	0	0	0,90

Chybová matice vegetace detekované na základě NDVI

Třída	Vegetace	Ostatní	Celkem	PU [%]	Kappa
Vegetace	92	0	92	1	0
Ostatní	2	56	58	0,97	0
Celkem	94	56	150	0	0
PZ [%]	0,98	1	0	0,99	0
Kappa	0	0	0	0	0,97

Příloha 4: Výsledky odhadů počtu obyvatel pro sídlištní typ zástavby

Odhad počtu obyvatel pro sídlištní typ zástavby dle nDMP o rozlišení 0,6 m/px při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	3629	3020	-609	-16,77
2	2824	2755	-69	-2,44
3	3184	3424	240	7,54
4	4472	4798	326	7,28
5	4153	4082	-71	-1,71
prům. odchylka			± 263	± 7,15

Odhad počtu obyvatel pro sídlištní typ zástavby dle nDMP o rozlišení 0,6 m/px při uvažování celkové plochy bytu 68,5 m² a průměrnému počtu osob na byt 2,21

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	3629	3421	-208	-5,74
2	2824	3120	296	10,48
3	3184	3878	694	21,79
4	4472	5433	961	21,49
5	4153	4623	470	11,31
prům. odchylka			± 526	± 14,16

Odhad počtu obyvatel pro sídlištní typ zástavby dle nDMP o rozlišení 2 m/px při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	3629	3140	-489	-13,48
2	2824	2971	147	5,21
3	3184	3438	254	7,97
4	4472	5005	533	11,92
5	4153	4181	28	0,67
prům. odchylka			± 290	± 7,85

Odhad počtu obyvatel pro sídlištní typ zástavby dle nDMP o rozlišení 2 m/px při uvažování celkové plochy bytu 68,5 m² a průměrnému počtu osob na byt 2,21

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	3629	3556	-73	-2,02
2	2824	3365	541	19,14
3	3184	3893	709	22,27
4	4472	5668	1196	26,74
5	4153	4734	581	14,00
prům. odchylka			± 620	± 16,84

Příloha 5: Výsledky odhadů počtu obyvatel pro rodinný typ zástavby

Odhad počtu obyvatel pro rodinný typ zástavby dle nDMP o rozlišení 2 m/px při uvažování celkové plochy bytu 109,1 m² a průměrnému počtu osob na byt 2,8 bez započítání výšky

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	352	246	-106	-30,12
2	277	320	43	15,64
3	613	394	-219	-35,71
4	90	49	-41	-45,37
5	203	205	2	1,18
prům. odchylka			± 82	± 25,60

Odhad počtu obyvatel pro rodinný typ zástavby dle nDMP o rozlišení 2 m/px při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47 bez započítání výšky

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	352	273	-79	-22,43
2	277	356	79	28,37
3	613	437	-176	-28,63
4	90	55	-35	-39,36
5	203	228	25	12,32
prům. odchylka			± 79	± 26,22

Odhad počtu obyvatel pro rodinný typ zástavby dle nDMP o rozlišení 0,6 m/px při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47 bez započítání výšky

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	352	278	-74	-20,89
2	277	259	-18	-6,60
3	613	362	-251	-40,90
4	90	58	-32	-35,11
5	203	123	-80	-39,52
prům. odchylka			± 91	± 28,60

Odhad počtu obyvatel pro rodinný typ zástavby dle nDMP o rozlišení 0,6 m/px při uvažování celkové plochy bytu 109,1 m² a průměrnému počtu osob na byt 2,8 bez započítání výšky

lokalita	skutečnost	odhad	rozdíł	rozdíł [%]
1	352	251	-101	-28,73
2	277	233	-44	-15,86
3	613	326	-287	-46,76
4	90	53	-37	-41,54
5	203	111	-92	-45,52
prům. odchylka			± 112	± 35,68

Odhad počtu obyvatel pro rodinný typ zástavby dle nDMP o rozlišení 0,6 m/px při uvažování celkové plochy bytu 109,1 m² a průměrnému počtu osob na byt 2,8

lokalita	skutečnost	odhad	rozdíł	rozdíł [%]
1	352	467	115	32,77
2	277	371	94	34,06
3	613	811	198	32,23
4	90	134	44	48,91
5	203	179	-24	-11,78
prům. odchylka			± 95	± 31,95

Odhad počtu obyvatel pro rodinný typ zástavby dle nDMP o rozlišení 0,6 m/px při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47

lokalita	skutečnost	odhad	rozdíł	rozdíł [%]
1	352	519	167	47,38
2	277	412	135	48,81
3	613	900	287	46,79
4	90	149	59	65,30
5	203	199	-4	-2,07
prům. odchylka			± 129	± 42,07

Odhad počtu obyvatel pro rodinný typ zástavby dle nDMP o rozlišení 2 m/px při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47

lokalita	skutečnost	odhad	rozdíł	rozdíł [%]
1	352	602	250	70,90
2	277	573	296	106,85
3	613	1001	388	63,29
4	90	149	59	65,99
5	203	326	123	60,38
prům. odchylka			± 223	± 73,48

Odhad počtu obyvatel pro rodinný typ zástavby dle nDMP o rozlišení 2 m/px při uvažování celkové plochy bytu 109,1 m² a průměrnému počtu osob na byt 2,8

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	352	542	190	53,96
2	277	516	239	86,35
3	613	902	289	47,10
4	90	135	45	49,53
5	203	293	90	44,48
prům. odchylka			± 171	± 56,28

Příloha 6: Výsledky odhadů počtu obyvatel pro ostatní typy zástavby

Odhad počtu obyvatel pro ostatní typy zástavby dle nDMP o rozlišení 2 m/px při výpočtu úrovnových ukazatelů dle vzorců 7 a 8

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	630	566	-64	-10,19
2	1557	1346	-211	-13,52
3	710	565	-145	-20,37
4	384	615	231	60,17
5	846	660	-186	-21,99
prům. odchylka			± 167	± 25,25

Odhad počtu obyvatel pro ostatní typy zástavby dle nDMP o rozlišení 0,6 m/px při výpočtu úrovnových ukazatelů dle vzorců 7 a 8

lokalita	skutečnost	odhad	rozdíl	rozdíl [%]
1	630	575	-55	-8,66
2	1557	1355	-202	-12,97
3	710	602	-108	-15,24
4	384	698	314	81,70
5	846	685	-161	-18,98
prům. odchylka			± 168	± 27,51

Příloha 7: Výsledky odhadů počtu obyvatel obce Olomouc

Odhad počtu obyvatel pro vrstvy zástavby vybrané bez pomocných dat při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47 bez uvažování výšky

	Zástavba I	Zástavba II	Zástavba III
skutečnost	95791	95627	95791
odhad	166597	160474	192916
rozdíl	70806	64847	97125
rozdíl [%]	73,92	67,81	101,39

Zástavba I: vrstva získaná na základě nDMP o rozlišení 2 m/px

Zástava II: vrstva získaná na základě nDMP o rozlišení 0,6 m/px

Zástavba III: vrstva získaná na základě snímku Sentinel-2

Odhad počtu obyvatel pro vrstvy obytné zástavby dle OSM dat při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47 bez uvažování výšky

	Zástavba I	Zástavba II	Zástavba III
skutečnost	95791	95627	95791
odhad	45902	52186	114486
rozdíl	-49889	-43441	18695
rozdíl [%]	-52,08	-45,43	19,52

Odhad počtu obyvatel pro vrstvy zástavby vybrané bez pomocných dat při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47

	Zástavba I	Zástavba II
skutečnost	95791	95627
odhad	472382	447558
rozdíl	376591	351931
rozdíl [%]	393,14	368,02

Odhad počtu obyvatel pro vrstvy obytné zástavby dle OSM při uvažování celkové plochy bytu 86,7 m² a průměrnému počtu osob na byt 2,47

	Zástavba I	Zástavba II
skutečnost	95791	95627
odhad	153146	164951
rozdíl	57355	69324
rozdíl [%]	59,87	72,49

Odhad počtu obyvatel pro vrstvy obytné zástavby dle OSM při rozdělení budov na rodinný (<9 m) a bytový typ (≥9 m)

	Zástavba I	Zástavba II
skutečnost	95791	95627
odhad	138894	150589
rozdíl	43103	54962
rozdíl [%]	45,00	57,77

Odhad počtu obyvatel pro vrstvy obytné zástavby dle OSM manuálně rozdělené na tři typy: sídlištní, rodinný, ostatní

	Zástavba I	Zástavba II
skutečnost	95791	95627
odhad	95618	102639
rozdíl	-173	7012
rozdíl [%]	-0,18	7,33

Odhad počtu obyvatel pro vrstvy obytné zástavby dle OSM automaticky rozdělené na tři typy: sídlištní, rodinný, ostatní


	Zástavba I	Zástavba II	Zástavba III
skutečnost	95791	95627	95791
odhad	106002	102467	113748
rozdíl	10211	6840	17957
rozdíl [%]	10,66	7,15	18,75

Zástavba I a II: rozděleno na typy dle výšky (sídlištní ≥15 m, rodinná <9 m, ostatní ≥9 m a <15 m)

Zástavba III: rozděleno na typy dle OSM, bez uvažování výšky

ROZDÍL V POČTU OBYVATEL OLOMOUCE

mezi údaji ze SLDB 2011 a z gridu GHS Population 2015



PROSTOROVÁ DIFERENCIACE OBYVATEL OLOMOUCE

dle nDMP o rozlišení 2 m/px z roku 2013


Počet obyvatel / ha



Zástavba byla manuálně rozdělena na tři typy: sídlištní, rodinnou a ostatní.

Ukazatele obydlivosti / plochy bytu:

- sídlištní: 2,47 os. / 86,7 m²
- rodinná: 2,8 os. / 109,1 m²
- ostatní: 3,5 os. / 313,49 m²




0 2 km

Petra ĎURIANČIKOVÁ
podklad: © Přispěvatelé OpenStreetMap
Katedra geoinformatiky UP, 2020
kartografické zobrazení: UTM zone 33N
Příloha 9

PROSTOROVÁ DIFERENCIACE OBYVATEL OLOMOUCE

dle nDMP o rozlišení 0,6 m/px z roku 2016

Počet obyvatel / ha




Zástavba byla rozdělena na tři typy:

- sídlištní (≥ 15 m),
- rodinná (< 9 m)
- ostatní (≥ 9 m a < 15 m)

Ukazatele obydlivosti / plochy bytu:

- sídlištní: 2,47 os. / 86,7 m²
- rodinná: 2,8 os. / 109,1 m²
- ostatní: 3,5 os. / 313,49 m²




0 2 km

Petra ĎURIANČIKOVÁ
podklad: © Přispěvatelé OpenStreetMap
Katedra geoinformatiky UP, 2020
kartografické zobrazení: UTM zone 33N
Příloha 10

PROSTOROVÁ DIFERENCIACE OBYVATEL OLOMOUCE

dle snímku Sentinel-2A z roku 2019


Počet obyvatel / ha



Zástavba byla rozdělena na tři typy dle OSM: „apartments“, „houses“ a „residential“.

Ukazatele obydlivosti / plochy bytu:

- „apartments“: 2,21 os. / 68,5 m²
- „houses“: 2,8 os. / 109,1 m²
- „residential“: 2,47 os. / 86,7 m²




0 2 km

Petra ĎURIANČIKOVÁ
podklad: © Přispěvatelé OpenStreetMap
Katedra geoinformatiky UP, 2020
kartografické zobrazení: UTM zone 33N
Příloha 11

PROSTOROVÁ DIFERENCIACE OBYVATEL PIEŠŤAN


dle snímku Sentinel-2A z roku 2019

Počet obyvatel / ha



Zástavbu nebylo možné rozdělit na více typů, jelikož tento atribut u více než 98 % záznamů chyběl.

Ukazatel obydlivosti / plochy bytu: 3 os. / 115,8 m²



Petra ĎURIANČIKOVÁ
podklad: © Přispěvatelé OpenStreetMap
Katedra geoinformatiky UP, 2020
kartografické zobrazení: UTM zone 33N
Příloha 12

ROZDÍL V POČTU OBYVATEL PIEŠŤAN

mezi údaji z GHS Population gridu 2015 a odhadem dle snímku Sentinel-2A 2019

