

**Univerzita Palackého v Olomouci**

**Přírodovědecká fakulta**

**Katedra geoinformatiky**

**POKROČILÁ EXTRAKCE PROSTOROVÝCH INFORMACÍ  
Z DRUŽICOVÝCH SNÍMKŮ VYSOKÉHO ROZLIŠENÍ**

**Magisterská práce**

**Tomáš POUR**

**Vedoucí práce RNDr. Jaroslav BURIAN, Ph.D.**

**Olomouc 2015**

**Geoinformatika**

## **ANOTACE**

Tato práce se věnovala zpracování pěti družicových snímků různých středoevropských měst pořízených různými senzory. Účelem práce bylo najít postupy a metody, které by vedly ke zhodnocení a extrakce prostorových informací v daných územích. K tomuto účelu byla data nejprve předzpracována pomocí metod obrazové fúze, mozaikování a segmentace. Do další fáze pak vstupovaly dvě polygonové vrstvy. Jedna segmentovala snímek na úrovni nižších objektů a druhá segmentovala snímek na úrovni bloků budov.

Ve druhé části práce byla poté polygonová vrstva klasifikována a následně exportována ve formátu ESRI shapefile. Klasifikace probíhala kombinací expertní hierarchické klasifikace a použití metody SEaTH pro výběr nejvhodnějších parametrů odlišení tříd a následného určení prahové hodnoty.

Výsledné vrstvy spolu s náhledy byly zařazeny jako přílohy práce a okomentovány v poslední části diplomové práce. K vizuálnímu popisu a výstupům byla přidána také statistická data a zhodnocení. V diskuzi pak autor popsal úskalí tohoto postupu a přiblížil komplikace plynoucí z velkého datového objemu, rozdílných senzorů a velké a různorodé zájmové oblasti.

## **KLÍČOVÁ SLOVA**

Dálkový průzkum Země, SEaTH, klasifikace, městské oblasti

Počet stran práce: 61

Počet příloh: 4 (z toho 1 volná)

## **ANOTATION**

In this thesis author processed five satellite image of five different middle-European cities taken by five different sensors. The aim of the thesis was to find methods and approaches leading to evaluation and spatial data extraction from areas of interest. For this cause data were firstly pre-processed using image fusion, mosaicking and segmentation processes.

Results going into the next step were two polygon layers; first one representing single objects and the second one representing city blocks. In the second step, polygon layers were classified and exported into ESRI shapefile format. Classification was partly hierarchical expert based and partly based on the tool SEaTH used for separability distinction and thresholding.

Final results along with visual previews were attached to the thesis. Results were evaluated visually and statistically in the last part of the thesis. In the discussion author described difficulties of working with data of large size, taken by different sensors and different also thematically.

## **KEYWORDS**

Remote sensing, SEaTH, classification, urban areas

**Prohlašuji, že**

- bakalářskou/diplomovou práci včetně příloh, jsem vypracoval samostatně a uvedl jsem všechny použité podklady a literaturu,

- jsem si vědom, že na moji bakalářskou/diplomovou 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/diplomovou práci užívat (§ 35 odst. 3),

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

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

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

- použít výsledky a výstupy mé bakalářské/diplomové 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

Děkuji vedoucímu práce dr. Jaroslavu Burianovi za motivaci a cenné rady při vypracování práce. Dále děkuji Vysoké škole báňské – Technické univerzitě Ostrava, konkrétně panu docentu Horákovi, za poskytnutí licence na software Definiens Developer, bez kterého by tato práce nevznikla.



# OBSAH

<b>ÚVOD</b> .....	<b>9</b>
<b>1 CÍLE PRÁCE</b> .....	<b>10</b>
<b>2 METODY A POSTUPY ZPRACOVÁNÍ</b> .....	<b>11</b>
2.1 Použité metody .....	11
2.1.1 Obrazová fúze .....	11
2.1.2 OBIA .....	11
2.1.3 Segmentace.....	12
2.1.4 Klasifikace.....	13
2.1.5 SEaTH .....	14
2.1.6 Klasifikace (pokračování).....	14
2.1.7 Urban structure types .....	14
2.2 Použitá data .....	15
2.3 Použitý software .....	16
2.3.1 eCognition Developer – Definiens Developer .....	16
2.3.2 ERDAS Imagine .....	16
2.3.3 ESRI ArcGIS.....	17
2.3.4 R/R Studio .....	17
2.3.5 Exelis ENVI.....	18
2.4 Postup zpracování.....	18
<b>3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY</b> .....	<b>19</b>
3.1 Trendy dálkového průzkumu v městských oblastech .....	19
3.2 OBIA .....	23
3.3 SEaTH .....	23
3.4 UST.....	25
<b>4 PŘEDZPRACOVÁNÍ DAT</b> .....	<b>26</b>
4.1 Mozaikování.....	26
4.2 Obrazová fúze .....	27
4.3 Segmentace .....	28
<b>5 KLASIFIKACE</b> .....	<b>30</b>
5.1 SEaTH .....	31
5.2 Testování tříd .....	33
5.3 Aplikace hierarchické klasifikace .....	36
<b>6 VÝSLEDKY</b> .....	<b>38</b>
6.1 Vizuelní výstupy .....	38
6.1.1 Katowice.....	39
6.1.2 Košice .....	41
6.1.3 Leipzig .....	43
6.1.4 Ostrava .....	45
6.1.5 Székesfehérvár .....	47

6.2	Statistické srovnání.....	49
6.2.1	Nízká úroveň .....	49
6.2.2	Střední úroveň.....	49
<b>7</b>	<b>DISKUZE.....</b>	<b>50</b>
<b>8</b>	<b>ZÁVĚR.....</b>	<b>52</b>
	<b>POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE</b>	
	<b>PŘÍLOHY</b>	



## ÚVOD

Dálkový průzkum Země představuje i ve 21. století velkou výzvu na poli zpracování digitálních prostorových dat. Většina článků se opírá o případové studie s čistými a jasnými daty a ani na těchto datech mnohé metody nedosahují stoprocentních výsledků. Další výzvou je také zpracování časových řad a výzvou největší je potom zpracování dat z různých zdrojů. Tato práce by měla sloužit jako průvodce zpracováním družicových snímků a získávání prostorových informací. V tomto procesu zůstává nejdůležitějším prvkem matematická analýza.

Jednotlivé kroky zpracování a analýzy obrazu stále poskytují hodně prostoru pro zlepšování a testování nových postupů. Mezi tyto kroky patří obrazová fúze jako metoda zlepšení dat pro další analýzy, dále pak segmentace obrazu, jejíž algoritmy jsou většinou patentované, nebo matematické metody a prahování zvolených tříd. Mnoho prostoru pro zlepšení, nové přístupy a způsoby myšlení poskytuje také poslední krok této práce, tedy hierarchická klasifikace.

V této práci bych se chtěl primárně věnovat úskalím a jejich možným řešením, dále charakterizovat proces práce s několika odlišnými snímky a způsob uvažování při práci s nimi. V diskuzi se chci zaměřit na další možnosti rozvinutí tohoto tématu, které se nabízejí.

Analýza družicových dat je důležitým nástrojem, ať už se toto poznání týká socio-ekonomické sféry, nebo sféry fyzicko-geografické. Informace pořízené touto cestou nám pomáhají poznávat a chápat svět kolem nás „s nadhledem“ a v globálním měřítku.

## 1 CÍLE PRÁCE

Cílem práce bylo vytvořit postup využívající pokročilých prostorových informací pro analýzu městských oblastí. Pro tento účel bylo použito několik softwarových řešení, umožňujících různé stupně analýzy digitálního obrazu. Hlavní snahou bylo popsat postup a úskalí manipulace s pěti snímky z odlišných senzorů, odlišné velikosti i spektrálních charakteristik a uplatnit na ně, pokud možno, co nejuniverzálnější postup. Tento postup využívá pokročilé metody extrakce prostorových informací vycházející především z objektově založené analýzy obrazu, použití matematických metod pro klasifikaci tříd, hierarchické klasifikace a víceúrovňové analýzy. Výstupy práce jsou dílčí datové výstupy jednotlivých metod, kód matematických funkcí, popis postupu při zpracování snímků a hodnocení odlišností a podobností ve struktuře měst. Důležitým bodem práce je také diskuze, která obsahuje informace o možných alternativách postupů a možnosti zlepšení do budoucna.

## **2 METODY A POSTUPY ZPRACOVÁNÍ**

Pro vypracování této práce bylo použito množství geoinformatických a matematických metod. Mezi tyto metody patří především metody zpracování dat dálkového průzkumu, jako jsou například obrazová fúze, objektově založená analýza obrazu nebo segmentace obrazu. Tyto metody jsou podrobněji rozepsány dále v textu.

### **2.1 Použité metody**

Následuje stručný výčet základních metod zpracování obrazu a matematické analýzy užitý v práci.

#### **2.1.1 Obrazová fúze**


Obrazová fúze je metoda zpracování dat dálkového průzkumu Země, při které data s vyšší informační hodnotou a nižší prostorovou rozlišovací schopností poskytují spektrální informace a obohacují tak data s lepší prostorovou rozlišovací schopností. V nejběžnějším případě jde o fúzi panchromatických a multispektrálních snímků. Výsledný snímek má všechna pásma multispektrálního snímku a vyšší prostorovou rozlišovací schopnost. Tato metoda pomáhá k lepší využitelnosti a detailnosti výsledného obrazu, který poté vstupuje do analýzy. Nevýhodou je, že originální čistá data jsou zpracována a DN hodnoty se oproti originálnímu snímku mění.

#### **2.1.2 OBIA**

Object-Based Image Analysis – Objektově založená analýza obrazu je v posledních letech velmi populárním přístupem k analýze satelitních a leteckých snímků. Nejde ovšem pouze o metodu určenou pro dálkový průzkum Země. Své využití má například i v medicíně při analýze rentgenových snímků (Sharma, 2010). Pod tímto názvem se také neskryvá pouze jedna metoda, ale jde o celý přístup k dané problematice. Obecně do této metody vstupuje zpracovaný snímek vytvořený libovolným způsobem. V případě dálkového průzkumu jde zpravidla o georeferencovaný a ortorektifikovaný satelitní nebo letecký snímek. V obecném měřítku může jít prakticky o jakýkoli snímek nebo fotografii.

### 2.1.3 Segmentace

Segmentace obrazu probíhá v dnešní době pomocí algoritmů implementovaných ve specializovaných programech na analýzu obrazu. V literatuře je často tato metoda zmíněna jen okrajově, protože jde o postup, který není detailně zmapovaný. Metoda spočívá ve shlukování pixelů do skupin o podobných vlastnostech. Základní parametry těchto výpočtů jsou zpravidla velikost, tvar, DN hodnoty pixelů a kompaktnost. Nastavení těchto parametrů je spíše experimentální. Lze říci, co bude hrubá, a co jemná segmentace. Lze také orientovat segmentaci spíše na barvu nebo spíše na tvar. Vysvětlení daného nastavení a jeho zdůvodnění je ale téměř nemožné. Segmentace často probíhá na stejném obraze v několika úrovních a stejně tak může probíhat i následná klasifikace. Největší výhodou víceúrovňové segmentace je další možnost srovnávat objekty nejen na stejné úrovni (sousedství), ale také se zde může uplatnit i nadřazenost nebo podřazenost podle počtu vrstev. Tento postup je dále popsán v praktické části této práce.



Obr. 2.1 – Příklad hierarchie segmentace (zdroj: Definiens Developer User Guide)

## Vlastnosti segmentů

Segmenty vytvořené v předešlém kroku získávají automaticky nepřeborné množství matematických metrik. Mezi základní charakteristiky patří velikost v pixelech i ve skutečných jednotkách, průměrná DN hodnota daného pásma, kompaktnost, velikost minimální opsané kružnice objektu a mnoho dalších. Mimo tyto charakteristiky je užitečné vypočtení spektrálních indexů. Mezi tyto indexy patří především velmi známý a používaný index NDVI – normalized difference vegetation index. Dalšími indexy jsou například NBDI, NDWI a další.



Obr. 2.3 – Zobrazení atributu „brightness“ (světlost) na příkladu města Košice

### 2.1.4 Klasifikace

Pro klasifikaci byla použita kombinovaná metoda hierarchické klasifikace s prahováním na základě analýzy vzdálenosti vzorků jednotlivých tříd. Nejprve je potřeba definovat třídy, poté je potřeba náhodně nebo pomocí experta zvolit trénovací plochy. Těch může být v tomto případě libovolný počet a nemusí být shodný pro všechny třídy. Měl by být ovšem zvolený tak, aby reprezentoval co nejlépe dané třídy. V dalším kroku

je třeba zvolit parametry, pro které se bude odlišnost tříd porovnávat. V ideálním případě by měly obsahovat hlavní charakteristiky objektů, jako jsou například odstín, hodnoty v jednotlivých pásmech, světlost, tvar, textura apod.

### **2.1.5 SEaTH**

SEaTH je dalším krokem v tomto postupu. Více než o konkrétní postup jde o soubor metod. SEaTH je zkratka a znamená „Separability and Thresholds“. Do výpočtu vždy vstupují dvě třídy a jeden parametr srovnání. V první části je vypočítána hodnota separability, tedy míry odlišnosti vždy mezi dvěma třídami. V článku, kde byla metoda poprvé popsána, se používaly dvě funkce. První byla Bhattacharyya distance, a druhá Jeffries-Matusita distance. Bhattacharyya distance nabývá hodnot od nuly do nekonečna. Jeffries-Matusita distance nabývá hodnot od nuly do dvou. U obou metod vyšší hodnota znamená větší míru odlišnosti a tedy pro analýzu příznivější výsledek. Druhá část obsahuje metodu prahování. Ve výše zmíněné literatuře jde o upravený Gaussovský pravděpodobnostní model. Do rovnice vstupuje průměrná hodnota a odchylka a výstupem jsou dvě hodnoty prahů, které nejlépe oddělují dvě množiny čísel. SEaTH jako metoda má tu vlastnost, že nezáleží na histogramu dat a vždy počítá nejlepší možné rozdělení. Právě proto byla zvolena pro tuto práci. Tato vlastnost se ovšem v některých situacích ukazuje jako kladná a v některých jako záporná.

### **2.1.6 Klasifikace (pokračování)**

Po zjištění nejlepších parametrů pro odlišení tříd můžeme vytvořit hierarchický strom klasifikace. Tento strom by měl odlišovat vždy třídy s největší odlišností a poté postupovat níže na hůře odlišitelné třídy. Tento klasifikační strom lze zvolit pomocí experta nebo čistě podle metody SEaTH. Ve druhém případě je ale možná odlišnost stromu na různých datech. Při sestavování klasifikačního stromu expertním přístupem je dobré brát v úvahu i data z metody SEaTH.

### **2.1.7 Urban structure types**

Městské strukturní typy – Urban structure types (UST) jsou formou klasifikace městského prostoru nad imaginárními statistickými jednotkami, které mají proměnlivou velikost a zahrnují oblasti několika městských bloků nebo jinou adekvátně velkou oblast. Tato klasifikace se liší dle oblasti a má proměnlivý počet a typ tříd. Stejnou klasifikací lze postihnout pouze oblasti s podobným historickým vývojem respektive s podobnou strukturou zástavby a podobnými užitými materiály ve stavitelství. Teorie UST vychází z expertního určení tříd a jejich následné analýzy. Třídy mohou vycházet z analýzy nebo mohou být určeny předem.

## 2.2 Použitá data

Byla použita data pořízená Katedrou Geoinformatiky, Univerzity Palackého v Olomouci. Tato datová sada „pěti měst“ obsahuje data střeoevropských středně velkých měst, která se nacházejí v post-socialistických zemích a která mají historii těžby nebo průmyslu. Tato města jsou Ostrava, Leipzig, Košice, Katowice a Székesfehérvár. Data jsou pořízena z různých senzorů, tři z výše uvedených měst byla nasnímána družicí WorldView2, jedno GeoEye-1 a jedno QuickBird II. Data všech družic se po obrazové fúzi dostávají do sub-metrové přesnosti a pohybují se kolem prostorové rozlišovací schopnosti 0,5 metru na hranu pixelu. Všechny snímky byly pořízeny během léta roku 2011 v rozmezí tří měsíců od 27. června do 27. září. V daný den byly snímky pořízeny v ranních hodinách v rozmezí od 9:46 do 10:11. Celkový objem dat celé datové sady přesahuje 10 GB, po obrazové fúzi a převodu do formátu NITF se tento objem zvýšil na 30 GB. Snímky Ostravy a Katowic byly předány rozdělené na dva dílčí snímky. V případě Katowic šlo bohužel o západovýchodní řez středem města, v případě Ostravy byla oddělená pouze Ostrava-Poruba od centrální Ostravy. Snímek Leipzig nezabíral ani celé území města, u Katowic byl také problém s velkou rozlohou spádové oblasti města a nejasnou linií souvislé zástavby. Snímek Katowic vykazoval také nejvyšší procento oblačnosti a kvalitativně byl pro výše uvedené důvody nejhorším snímkem.

Město	Družice	Panchromatické	Multispektrální	Datum	Čas
Katowice	GeoEye-1	0,41m	1,65m	7.9.2011	9:46
Košice	WorldView2	0,46m	1,84m	11.9.2011	9:59
Ostrava	WorldView2	0,46m	1,84m	27.9.2011	10:11
Szekesfehervar	WorldView2	0,46m	1,84m	10.7.2011	10:09
Leipzig	QuickBird II	0,61m	2,4m	27.6.2011	9:49

Obrázek 2.4 – Základní charakteristiky použitých snímků

## 2.3 Použitý software

### 2.3.1 eCognition Developer – Definiens Developer

Definiens Developer vyvíjený od roku 2000, roku 2010 zakoupený firmou Trimble Navigation Ltd a přejmenovaný na eCognition Developer je komerční software zaměřený na analýzu obrazových dat primárně z dálkového průzkumu Země. K tomuto využívá software obrazovou segmentaci a kontextový přístup k datům, založený především na vlastnostech objektů a hierarchickém uspořádání. eCognition je unikátní několika základními principy. Prvním z nich jsou „features“, tedy charakteristiky objektu. Druhým je hierarchický strom klasifikace a dědění pravidel napříč stromem, a posledním principem je „process tree“, který umožňuje pracovní postup strukturovat, pouštět jeho jednotlivé části zvlášť a ukládat je, takže napomáhá k opakovatelnosti postupu. Pro potřeby této práce byl doc. Horákem poskytnut VPN přístup k licenčnímu serveru VŠB-TUO, která vlastní licence na starší verzi Definiens Developer 7.0 (2007).



Obr. 2.5 – Logo produktu eCognition Developer

### 2.3.2 ERDAS Imagine

ERDAS Imagine je komerční software pro správu a práci s rastrovými daty dálkového průzkumu Země, zaměřený prioritně na GIS a prostorové aplikace. Je vyvíjený firmou ERDAS a jeho poslední verze je 2015. ERDAS Imagine obsahuje širokou škálu operací s daty dálkového průzkumu. Především jde o různé druhy korekcí a zpracování až po klasifikaci a testování přesnosti. Pro potřeby této práce byla použita poslední verze, zpřístupněna byla pomocí studentské licence garantované Katedrou Geoinformatiky, Univerzity Palackého v Olomouci.



Obr. 2.6 – Logo společnosti ERDAS.



### 2.3.3 ESRI ArcGIS

Z balíčku ArcGIS od firmy ESRI bylo k vypracování práce použito softwaru ArcMap. Konkrétně k ořezávání rastrových snímků a zpracování a vizualizace konečných výsledků. Software je licencovaný na Katedře Geoinformatiky, Univerzity Palackého v Olomouci.



Obr. 2.7 – Logo společnosti ESRI

### 2.3.4 R/R Studio

R jako jádro a jeho vizuální nástavba R Studio jsou open-source nástroje pro statistické zpracování a vizualizaci statistických výsledků. V práci byly použity k výpočtu metody SEaTH. Software obsahuje rozsáhlé knihovny pro výpočty obrovského množství metod a funkcí. Zároveň umožňuje vizualizaci výsledků a má rozsáhlé možnosti testování dat. Je zde také možno vytvářet vlastní balíčky nebo skriptovat vlastní funkce.

### 2.3.5 Exelis ENVI

ENvironment for Visualizing Images (ENVI) je nástroj vyvíjený od roku 2000 firmou Better Solutions Consulting, LLC. Později tento projekt pod svá křídla vzala firma Kodak. Software se zabývá zpracováním geoprostorových rastrových dat. Nejběžnějším využitím je dálkový průzkum Země a analýza obrazu. ENVI poskytuje základní zobrazovací rozhraní a velké množství funkcí pro práci s leteckými snímky prostřednictvím toolboxu. Oproti ostatním aplikacím se vyznačuje jednodušším uživatelským rozhraním, které působí stroze. Na druhou stranu tato strohost přispívá k přehlednosti a většina nástrojů je vždy po ruce, nebo snadno dohledatelná.



Obr. 2.8 – Logo společnosti Exelis

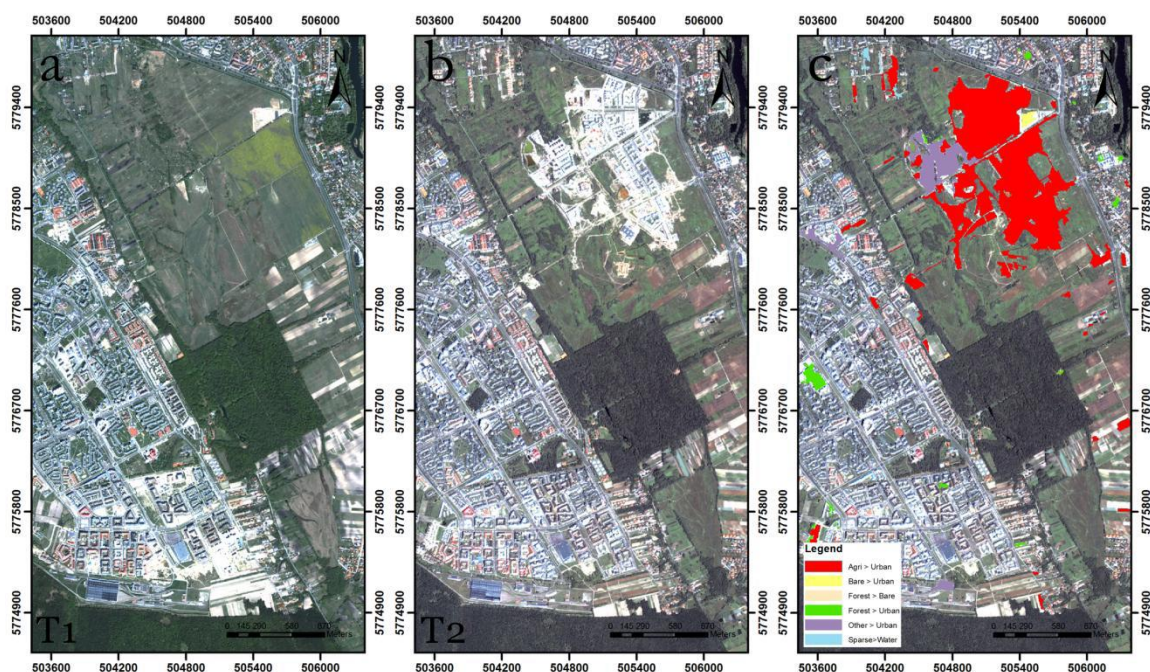
## 2.4 Postup zpracování

Letecké snímky po atmosférické korekci nejprve prošly předzpracováním. Během něj na ně byly aplikovány metody obrazové fúze, mozaikování a následně segmentace. Po segmentaci vznikly dvě polygonové vrstvy, nižší a střední úroveň segmentace. Tyto vrstvy poté vstupují do řízené hierarchické klasifikace. Výsledkem této klasifikace je datová sada skládající se ze dvou polygonových vrstev ve formátu ESRI shapefile na každé město. Celý proces je podrobně popsán v kapitole 3 a 4.

### 3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

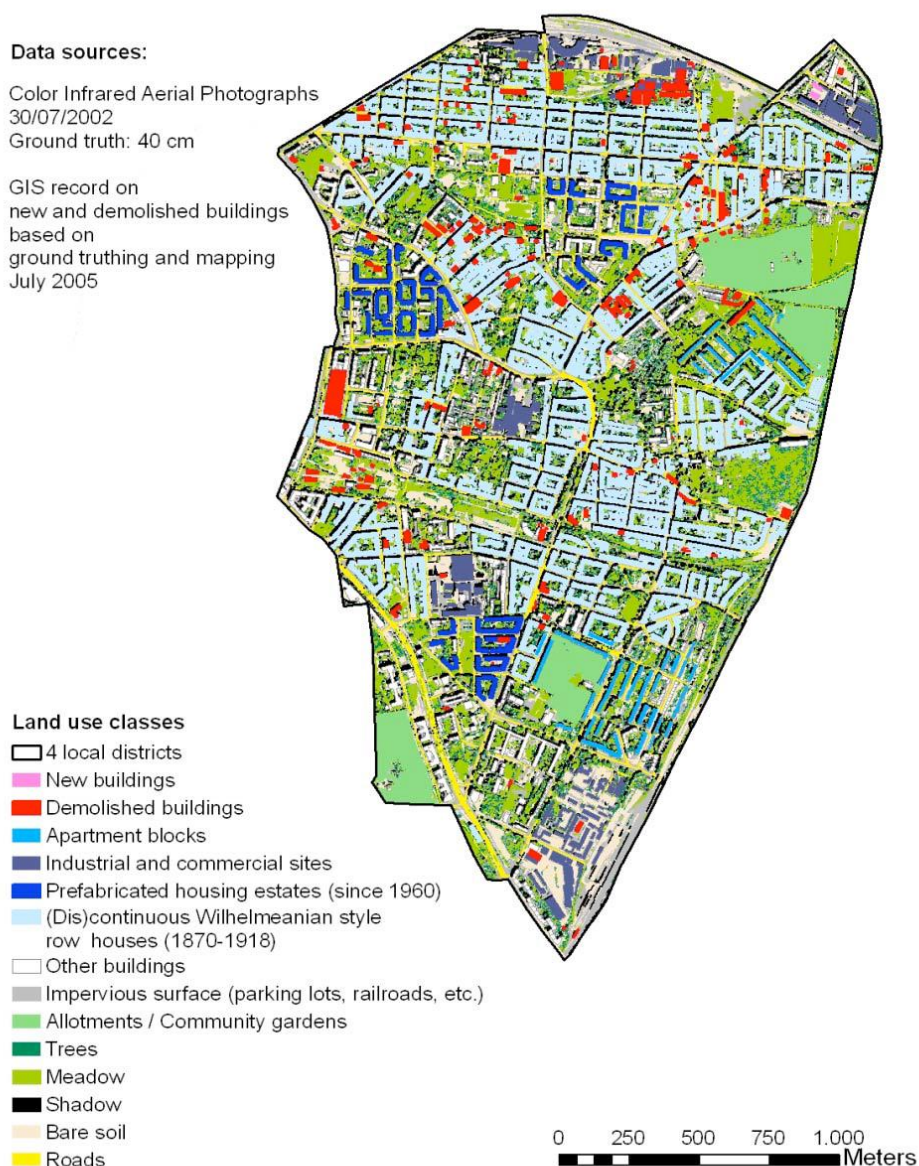
#### 3.1 Trendy dálkového průzkumu v městských oblastech

Aleksandrowitz a kol. (2014) ve svém článku rozebírá možnosti vytvoření automatického nástroje pro detekci změn na trénovacích plochách Area Framing Sample Europe (AFS Europe). Klasifikovaný obraz je získán pomocí automatického algoritmu, který je založen na OBIA principech a jako základní princip používá texturu objektu. Původní zdroj se mi ovšem nepodařilo dohledat, jde o citaci z Lewsinski et al. Autor poté v článku definuje nejběžnější typy změn a klasifikuje je na tři základní – ztrátu vegetace, obnovení vegetace a urbanizaci. Autor poté statisticky zhodnocuje úbytek vegetace ve všech plochách a na závěr přikládá diskuzi se zajímavými postřehy a možnými chybami v klasifikaci a segmentaci.



Obr. 3.1 – Příklad detekce změny vegetačního pokryvu na zastavěnou plochu

Banzhaf (2007) pojednává o monitorování rozvoje městských oblastí na příkladu Leipzig. Zajímavé je využití dvou datových sad, a to sice Landsat TM a Spot XS. Autor uvádí, že byla provedena korekce obrazu, aby se dal NDVI index použít na celou datovou sadu, skládající se ze dvou různých dat senzorů. Klasifikace se v tomto případě opírá o NDVI index a následnou hierarchickou klasifikaci s řízenou klasifikací dílčích tříd. Hodnocení přesnosti vykazuje velmi vysokou přesnost přes 80 %, nikde ale nejsou zobrazeny podrobné hodnoty nebo dílčí postupy. Dále se v článku mluví o detekci změny mezi lety 1994 a 2005. K podrobné klasifikaci některých oblastí bylo použito Colored Infra-Red fotografií. Není zde ovšem vysvětleno, jakým způsobem se potom z tohoto snímku získávaly přesné typy budov klasifikované prakticky na land-use.



Obr. 3.2 – Výsledky klasifikace na základě Colored Infra-Red fotografie

Du (2014) přidává do klasifikačního procesu a do analýzy změny městských oblastí teplotní data. Pracuje s daty Landsat TM, které umožňují jednak zavedení většího množství indexů pro klasifikaci a také právě vytváření takzvaných „heat island“, tedy teplotních ostrovů, díky kterým je poté klasifikován městský prostor. V práci je experimentálně testováno velké množství klasifikačních metod a postupů, které dosahují vysoké přesnosti přes 90 % ve všech případech. Autor dále v článku hledá souvislosti mezi teplotními mapami a vegetačním indexem a indexem zástavby.


Frerie (2010) předvádí nové přístupy pro klasifikaci pouze typu budov po jejich odlišení od zbytku snímku. Pro tyto účely používá Feature Analyst pro ArcGIS 9.3. Budovy jsou separovány a dále klasifikovány na základě atributů přiřazených při extrakci. Tato práce je velmi zajímavá z hlediska práce s atributy a klasifikace pouze jedné konkrétní třídy, v tomto případě budovy, na podtřídy na základě geometrických a spektrálních vlastností.



Obr. 3.3 – Ukázka klasifikace budov na základě textury jejich střechy

Článek od Juergens (2011) se zaměřuje na detekci volných ploch v rámci hranic města. Tento článek je jedním z výstupů projektu GAUS, na kterém spolupracovaly dvě německé univerzity a jedna turecká. Projekt vychází z dat land cover, land use, satelitních snímků a speciálního centrality indexu vyvinutého ruhrskou univerzitou. Na základě těchto podkladů byly vybrány potenciálně volné plochy a porovnány s expertním

názorem. Tyto plochy byly poté analyzovány na základě blízkých objektů a svých charakteristik a doporučeny k revitalizaci a dalšímu využití.



Obr. 3.4 – Srovnání detekovaných volných ploch s expertním posudkem

Novack (2011) se snaží srovnat kvalitativně klasifikace nad daty WorldView-2 a QuickBird II. Pro segmentaci používá Segmentation Parameter Tuner založený na principu genetických algoritmů, a který se snaží segmentovat celý obraz na základě vstupních objektů vykreslených uživatelem. Autor dále pracuje celkem s téměř 600 atributy, mezi kterými se snaží určit ty, které budou nejlépe odlišovat dané třídy. Atributy byly poté testovány a byly zjištěny ty nejvíce relevantní k daným třídám. Ve výsledku bylo zjištěno, že až na vegetaci, data WorldView-2 poskytují více relevantní atributy pro odlišení tříd.

Tarantino (2011) se ve své práci snaží ze stereo snímků extrahovat budovy pomocí výškových dat. Obraz je nejprve upraven, poté analyzován podle různých masek a nakonec jsou potenciální budovy izolovány, objekt je upraven a jsou z nich vytvořeny trojrozměrné modely. V této práci je velmi zajímavé využití hran jako odlišovacího prvku při detekci budov.

Walker ve své prezentaci z roku 2010 mluví o naprostých základech segmentace a o software pro ni určených. Tato prezentace mi velmi pomohla pochopit proces

segmentace, a také ukazuje základní principy myšlení při klasifikaci segmentovaného obrazu.

Waqar (2010) vytváří z dat senzoru Landsat indexy, které slouží k lepšímu klasifikování snímků. Tyto indexy jsou z velké části závislé na blízkém a středním infračerveném pásmu, takže nejsou aplikovatelné u ostatních čtyř-pásmových senzorů. Mezi tyto indexy patří NDVI (vegetace), NDWI (voda), NBI (zastavěná půda), NDISI (neprůchozí terén), NDBI (zastavěná půda) a další.

### **3.2 OBIA**

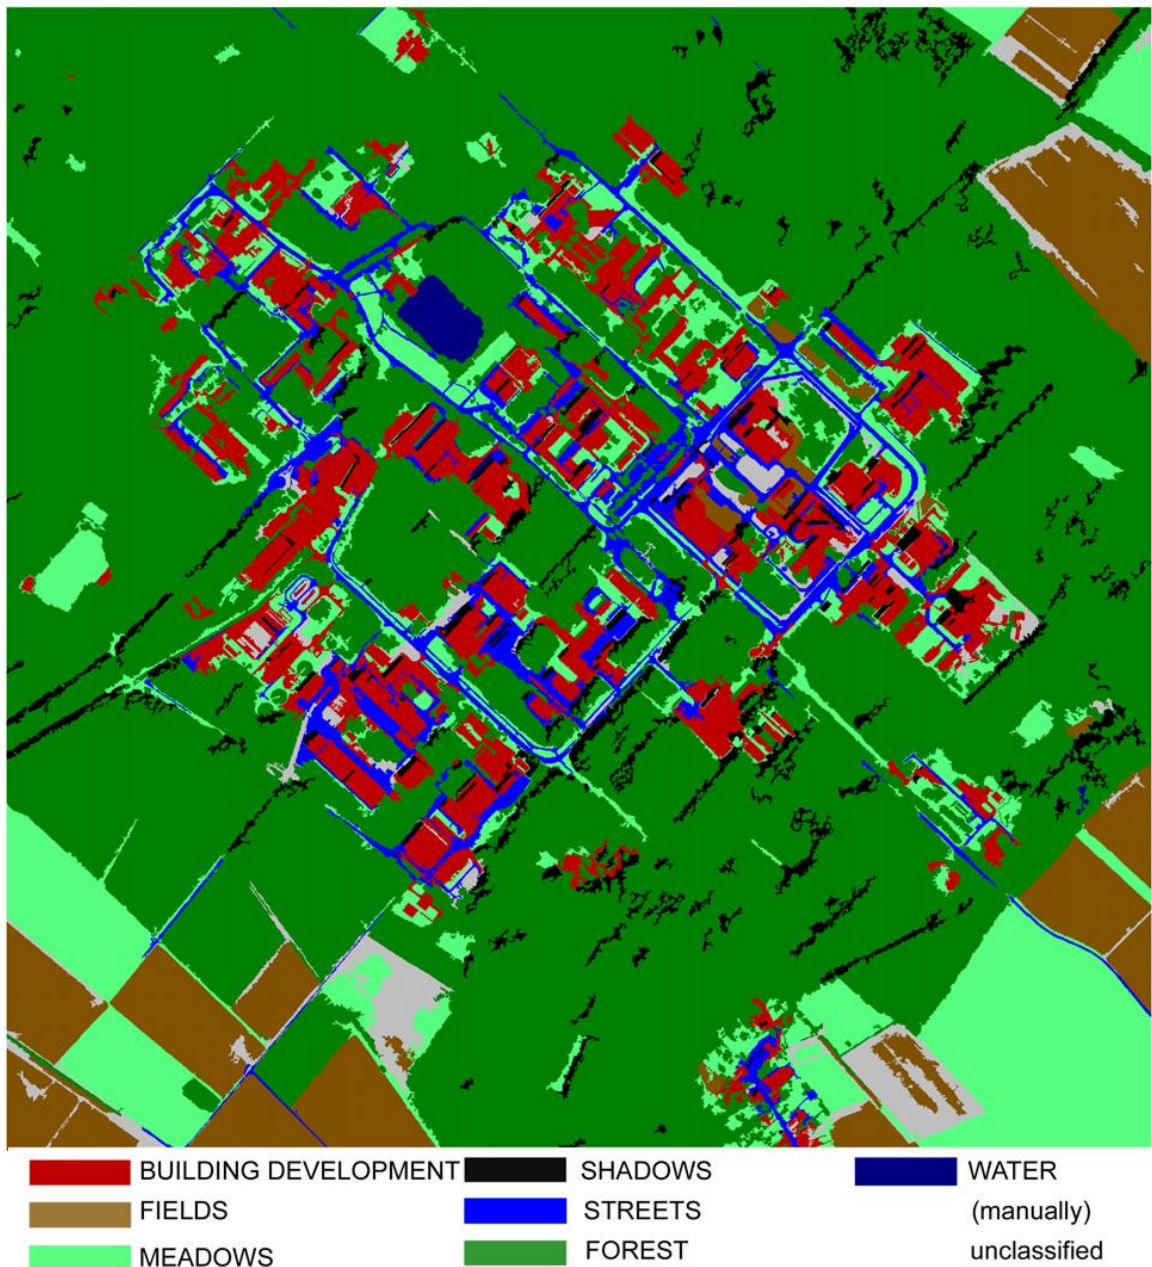
Blaschke (2010) prezentuje článek zabývající se výhodami, nevýhodami a obecnými principy OBIA, tedy Object-Based Image Analysis. Tento článek cituje přes 100 dalších prací a je souhrnnou rešerší na dané téma pro léta 2004 až 2008. Stejný autor v roce 2014 navazuje na tuto práci a představuje nový koncept GEOBIA – Geographic Object-Based Image Analysis. Tento koncept se snaží využívat geografických vlastností objektu a metod sousedství pro klasifikaci obrazu.

Gao (2006) ukazuje aplikaci OBIA principů na studiu lesních oblastí. Používá k tomu algoritmu SEaTH a testování velkého množství atributů. Také jeho dělení tříd ve finální klasifikaci je založeno na více parametrech zároveň. Gianinetto (2014) ukazuje velmi dobrou aplikaci principů OBIA na případové studii z Benátek, Itálie. Práce vykazuje minimální přesnost tříd kolem 70 %, u většiny tříd je ovšem mnohem vyšší. Tento výsledek lze považovat za velmi dobrý vzhledem k počtu klasifikovaných tříd. Práce totiž zachází tak daleko, že klasifikuje dokonce typy silnic, budov, typy vegetace a další. Práce je založena na pěti-úrovňové segmentaci.

Hermosilla (2013) ukazuje OBIA principy v kombinaci s UST (Urban Structure Types). Toto ukazuje na příkladu Valencie, Španělsko. Používá klasifikaci podle bloků budov, které jsou extrahovány pomocí pomocných LIDARových dat. Zástavbu poté dělí podle hlavních expanzivních období. Mezi dalšími pracemi zaměřenými na aplikaci OBIA klasifikačních metod jsou například Johansen (2009), Kulkarni (1997), Vanhuyse (2009) nebo Zhan (2002). Jde především o případové studie při zkoumání určitého jevu s daty určitého senzoru.

### **3.3 SEaTH**

Základním článkem metody SEaTH je Nussbaum (2006). Je to článek pojednávající o nové metodě na poli analýzy obrazu a ukazuje tuto metodu také na případové studii. Článek obsahuje také všechny vzorce pro Bhattacharyya distance, Jeffries-Matusita distance i pro vypočítání prahů pomocí upraveného Gaussovského pravděpodobnostního modelu. Případová studie potom ukazuje výzkumné centrum Jülich ze září 1998. Do studie vstupuje 74 atributů produkovaných software eCognition Developer. Ke každé třídě jsou poté vybrány dva nejlepší.



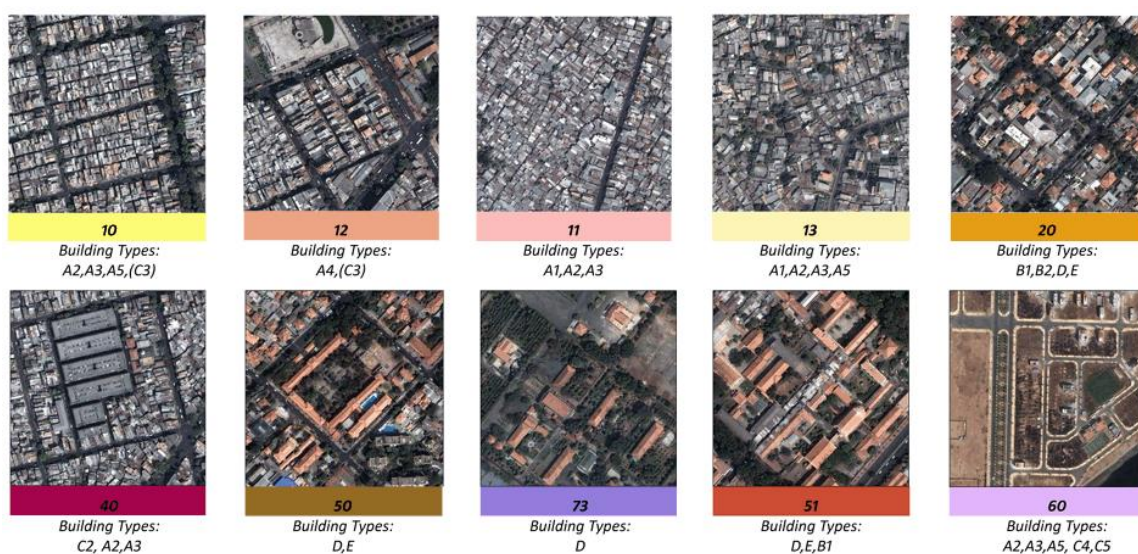
Obr. 3.5 – Výsledná klasifikace první případové studie (Nussbaum, 2006)

Druhá případová studie v článku ukazuje zařízení Arak v Iránu v letech 2004 a 2005. Ve vývoji algoritmu SEaTH a jeho aplikaci pokračují i další autoři jako například Gao (2011) nebo Yu (2012). Gao ve své práci především testuje možnosti algoritmu a jeho přesnost na snímcích Landsat ETM+ z roku 2003, která dosahuje úctyhodných 79 %. Yu (2012) prezentuje metodu vylepšeného SEaTH, takzvaného ISEaTH. Tato vylepšená metoda používá maticové výpočty, které berou v potaz vzdálenosti mezi třídami navzájem i v rámci jedné třídy.



### 3.4 UST

Analýza městského prostoru pomocí dat dálkového prostoru se pohybuje na hraně mezi socio-ekonomickou oblastí a oblastí technickou neboli DPZ. Pouze málo publikací zahrnuje obě tyto složky a většina článků se zabývá pouze stránkou geografickou nebo stránkou technickou. Mezi dva zástupce první skupiny patří bezesporu Anas, Arnott, Small (1997) se svou rozsáhlou studií o městské struktuře a Chakraborty (2009) s analýzou městské oblasti na základě land-use. Na pomezí se už pohybuje Moon (2009), který používá družicové snímky k charakterizování městských typů v kombinaci s vrstvou land-use.



Obr. 3.6 – Příklady městských struktur dle Moon (2009)

Mezi moderní trendy patří klasifikace města pomocí teplotních dat. Rozšíření těchto metod dokazují články například od Du (2014) nebo Geiss (2011). Přímou analýzu městských bloků na základě dat dálkového průzkumu Země pak najdeme například u Novack (2014) nebo Höfer (2009), kteří používají data z TerraSAR-X, nebo Wurm (2010), který používá pro stejné potřeby multispektrální snímky vysokého rozlišení.

## 4 PŘEDZPRACOVÁNÍ DAT

Snímky byly dodány jako orto-rektifikované a geo-referencované s atmosférickými korekcemi. Přesné geografické určení ovšem nemá na výsledky této práce žádný vliv, protože do procesu nebudou vstupovat žádná pomocná data, která by byla závislá na přesném prostorovém vymezení. Dva procesy, které ale bylo nutné udělat, jsou mozaikování a obrazová fúze.

### 4.1 Mozaikování


Mozaikování představuje proces spojování leteckých nebo družicových snímků na základě jejich geografického umístění. V této práci byl tento postup nutný u snímku Katovic a Ostravy. V druhém zmíněném šlo o přidání okrajové části města, v prvním případě šel ovšem řez horizontálně středem města a mozaika se tam vytvářela ze dvou rozdílných snímků s rozdílnou světlostí. K mozaikování byl použit software ERDAS Imagine a to konkrétně jeho nástavba MosaicPro. Při mozaikování nešlo o složitý proces, jelikož oba spojované snímky už byly geo-referencované a přesně se překrývaly. Bylo pouze nutné vytvořit tzv. seamline, tedy linii, která určuje, která část obrazu se bude brát ze kterého snímku. MosaicPro nabízí v tomto případě automatizované metody tvorby seamline.



Obr. 4.1 – Ukázka špatné linie automaticky generované pomocí ERDAS MosaicPro

Po několika pokusech, při kterých MosaicPro vytvořil prakticky rovnou linii, nebo rovnou linii s pokusem o respektování hran (obrázek 4.1), bylo jasné, že je potřeba vytvořit vlastní seamline. Tento krok se v konečném důsledku ukázal být složitějším, než jaká byla v prvních okamžicích myšlenka. Import shapefile do MosaicPro se ukázal prakticky nemožným. Program sám vybízí k importování vlastního seamline, ale neříká

nic o tom, jak by měl soubor vypadat. Po několika marných pokusech jsem se rozhodl operaci provést a během procesu si uložit špatný seamline vytvořený programem, ten poté upravit, uložit a zopakovat proces s novým seamline. Tento postup se ukázal jako nefunkční.




Obr. 4.2 – Seamline (sešívací linie) vytvořená v ERDAS MosaicPro editoru

Poslední pokus importování vlastního seamline shapefile probíhal tak, že jsem se pokusil do procesu nahrát přesně ten samý nepozměněný soubor, který MosaicPro vygeneruje při zadání automatického seamline. Ani tento originální soubor však program nebyl schopný zpracovat, takže bylo nutné přistoupit k vestavěnému editoru na úpravu seamline. Tento editor nemá žádnou funkci ukládání, takže práce s tak velkým územím byla poměrně stresující. Nemá ani příliš intuitivní ovládání, takže první okamžiky jeho používání byly zmatené. V tomto případě šlo ale pouze o dva snímky, jednu hranu a nebyla nutná přesnost na pixely, takže se seamline dal vytvořit v docela rozumném čase. Seamline linie byly vytvořeny manuálně tak, aby respektovaly hrany objektů a nesekaly je v půlce, což by ovlivnilo jejich interpretaci a klasifikaci. U snímku Katowic byla ještě snaha zredukovat oblačnost v severní části snímku.

## 4.2 Obrazová fúze

Obrazová fúze (resolution merge, image fusion, pan-sharpening) je proces zlepšování obrazu, do kterého vstupuje hyper-spektrální snímek a panchromatický snímek. Pomocí matematických metod se poté z těchto snímků přepočítá jeden, který má počet pásem hyper-spektrálního a prostorovou rozlišovací schopnost panchromatického. Tento proces byl opět zpracováván v ERDAS Imagine. Původní myšlenka byla použít jednu metodu na všech pět snímků. Jako první byla použita metoda, která se v předchozím výzkumu ukázala jako velmi kvalitní (Pour, 2013), tedy subtractive merge. V uvedené práci byla tato metoda použita na datech QuickBird II. I v této datové sadě na datech QuickBird II tato metoda vykazovala vynikající výsledky. Na všech ostatních ovšem zabarvovala snímek do odstínů různých barev a snižovala tak kvalitu spektrálních informací. Po několika obdobných pokusech s ostatními metodami přišla na řadu myšlenka změnit software. Druhým důvodem pro změnu software byla nutnost snímků větších než 4GB, což GeoTIFF neumožňuje. Náhradou byl software ENVI firmy Exelis, který jako jedinou pan-sharpening metodu umožňuje Gram-Schmidtovu fúzi a jako

výstupní rastrový formát umožňuje NITF (ntf). Tato metoda se ukázala jako univerzálnější. Snímky jsou sice různě zbarvené, ale ne tak, aby to výrazněji ovlivňovalo jejich interpretaci. Během obrazové fúze také došlo k navýšení objemu dat na 30 GB, což vychází v průměru asi 6 GB na jeden snímek.




Obr. 4.3 – Náhled výsledné obrazové fúze vytvořené pomocí Exelis ENVI (náhled v ERDAS Imagine)

### 4.3 Segmentace

Pro segmentaci byl použit software Definiens Developer z roku 2007. Zastaralost softwaru se promítla hned v několika krocích tohoto postupu. Nejmarkantnějším byla asi výpočetní náročnost procesů, přičemž se software nedokázal dostat přes hranici využití výpočetního výkonu počítače okolo 30%. Rád bych v tomto bodě zdůraznil, že všechny segmentace, včetně těch neúspěšných, trvaly jednu až dvě hodiny čistého času. Další věc, kterou je důležité zmínit hned na začátku, je fakt, že segmentační algoritmus Definiens Developeru respektive eCognition Developeru je patentovaný a především tajný. Segmentační algoritmus ovšem nefunguje ve všech oblastech tak, jak by bylo žádoucí, a zároveň neexistuje způsob, jak toto ovlivnit a manuální editace při takovémto objemu dat nepřipadá v úvahu.

Pro následnou klasifikaci a analýzu jsem zvolil dvouvrstvou segmentaci. Vyšší vrstvou, která byla pracovně nazvána jako střední, měla být původně data z RUIAN. Kvůli časové náročnosti a špatné implementaci externích tematických dat do Definiens Developeru jsem od toho upustil. Jako substitute byla tedy vytvořena segmentační vrstva se scale parametrem 1000 a nastavením 0,8 pro kompaktnost a 0,8 pro tvar. Tímto nastavením se měly vytvořit objekty o velikosti několika bloků, které mají spíše kruhový tvar a respektují hrany obrazu. Tento záměr se na všech snímcích, až na některé konkrétní oblasti, podařil.

Druhým krokem bylo vytvoření podrobné segmentace určené k hierarchické klasifikaci. Vzhledem k vysokému rozlišení snímků byl zvolen scale parametr 200 a nastavení kompaktnosti a tvaru zůstalo výchozí. Nutno poznamenat, že algoritmus v některých částech obrazu slučuje objekty, které si nejsou podobné ani DN hodnotami, ani si nejsou blízké tvarově. Druhý krok tedy proběhl také u všech snímků, a po několika desítkách hodin času tak vznikla segmentace o středním a nižším stupni podrobnosti u všech pěti zkoumaných snímků.



Obr. 4.4 – Ukázka segmentace na příkladu města Katowice

## 5 KLASIFIKACE

Hierarchická klasifikace byla vytvořena na základě zkušeností odlišitelnosti tříd a výsledků metody SEaTH, která s ní souvisí a bude popsána dále. Základním odlišením prostoru na snímku je zezeň a ostatní. Díky NDVI indexu, který v těchto konkrétních případech fungoval skvěle, můžeme velmi dobře odlišit vegetaci. Tuto vegetaci můžeme poté dále dělit na vysokou a nízkou na základě homogenity či standardní odchylky v blízkém infračerveném pásmu. Toto dělení není tak přesné jako s použitím výškových dat, ale dokáže jednoznačně odlišit travnaté homogenní plochy a vzrostlé stromy.

Pokud se v hierarchickém stromu posuneme k části ostatních „nezelených“ objektů, pak zde lze jednoduše odlišit tmavá místa. Tato jsou tvořena především vodou a stíny. Tyto dvě třídy není úplně jednoduché odlišit. Vzhledem k tomu, že ani jedna ze tříd nenese informaci o typu zástavby nebo struktuře, a vzhledem k jednoduchosti klasifikace, byly tyto třídy sloučeny a souhrnně označeny jako „tmavé“. V tomto bodě zbývají především budovy, silnice a volné plochy. Je velmi obtížné bez pomocných výškových dat odlišovat asfaltové silnice a asfaltové střechy. Stejně tak je problém odlišovat volné hliněné plochy od načervenalých střech. Obě třídy podle zastínění a orientace slunce dosahují velmi odlišných charakteristik vzhledem k pozici ve snímku. Nutno poznamenat, že například s LIDARovými daty by tyto problémy nebylo vůbec nutné řešit. Snahou práce je nicméně ukázat a otestovat možnosti analýzy vizuálních dat. Mimo tento fakt není vůbec jednoduché získat jakákoli data napříč pěti různými zeměmi s různou legislativou a územní správou. Výsledkem tohoto zamýšlení bylo vytvořit jednu celistvou třídu asfaltových ploch, kam bohužel spadnou tematicky velmi odlišné objekty, ale pořád nám vytvářejí představu o struktuře města a nesou prostorovou informaci. Poslední dvě třídy zůstaly oddělené a pomocí statistických metod jsem na každém snímku vybral metodu, která tyto objekty odlišuje nejlépe. V konečném důsledku tedy práce obsahuje klasifikaci na šest tříd – nízkou a vysokou vegetaci, tmavé plochy, asfaltové plochy, červené střechy a ostatní plochy.

## 5.1 SEaTH

Pro potřeby odlišení tříd byla použita relativně nová metoda SEaTH – Separability and Thresholds. Tato metoda spojuje matematické metody výpočtu relativní vzdálenosti dvou statistických souborů a metody prahování. Metoda byla zpracována v softwaru R respektive R Studio. Vycházel jsem ze vzorce zveřejněného v prvním článku o SEaTH (Nussbaum, 2006).

Do výpočtu vstupují dva vektory čísel, reprezentující jeden atribut dvou klasifikovaných tříd. Z těchto vektorů je potřeba vypočítat průměr, varianci a jejich délku. Pouze tyto charakteristiky vstupují do dalších výpočtů a se samotným vektorem se už nepracuje. Dále potřebujeme rozdíl průměrů a průměr variancí. V první části výpočtu počítáme Bhattacharyya index a Jeffries-Matusita distanci. Čím vyšší je výsledná hodnota, tím vyšší je rozdílnost daných tříd.

V druhé části se vypočítávají prahové hodnoty mezi vektory. Vzorec byl taktéž přejat (Nussbaum, 2006) a překódován do R Studia. Pro jednoduchost přepisu byl vzorec rozdělen na segmenty A až D přičemž konečné kořeny rovnice jsou složením těchto částí (obr. 5.2).

Celý tento vzorec byl přepsán do R Studia jako funkce, kterou je potřeba importovat před samotným výpočtem. Funkce se poté volá příkazem SEaTH a v závorce uvádíme první a druhý vstupní vektor.

```
> SEaTH (vegetation, non_vegetation)
      jm      bh      T1      T2
1 1.758734 2.115001 0.5750117 0.652299
```

Obr. 5.1 – Volání funkce SEaTH v prostředí R Studio a výsledná tabulka

Samotným výsledkem funkce je tabulka, kde „jm“ a „bh“ zastupují separabilitu a „T1“ a „T2“ jsou prahové hodnoty. Tato funkce byla vytvořena pouze pro potřeby této práce a její širší užití a další testování by kvůli časové náročnosti vyžadovalo implementaci vzorce do programovacího jazyka a vytvoření aplikace schopné načítat atributová data vyexportovaných shapefile trénovacích ploch z Definiens Developer a okamžitě testovat atributy všech tříd navzájem. Jednou z vlastností a výhod algoritmu SEaTH je, že nevyžaduje stejné množství trénovacích ploch, takže je možné nejen testovat jednu třídu proti jiné třídě, ale je možné testovat i odlišnost jedné třídy od všech ostatních trénovacích ploch nebo více tříd oproti více třídám. Pokud si zde vypůjčíme názvosloví databází, tak testování může probíhat v poměru M:N množin.

```
>>>
SEaTH <- function ( vector.1 , vector.2 ) {
m1 <- as.matrix(c(vector.1))
m2 <- as.matrix(c(vector.2))
mean.m1 <- mean(m1)
mean.m2 <- mean(m2)
cv.m1 <- cov(m1)
cv.m2 <- cov(m2)
meandif <- mean.m2 - mean.m1
p <- ( cv.m1 + cv.m2 ) / 2
bh.distance <- 0.125 *t ( meandif ) * p^ ( -1 ) * meandif + 0.5 * log ( det ( p ) / sqrt ( det ( cv.m1 ) * det ( cv.m2 ) ) )
jm.distance <- 2 * ( 1 - exp ( -bh.distance ) )
l.m1 <- length(m1)
l.m2 <- length(m2)
A <- log10((cv.m1/cv.m2)*(l.m2/l.m1))
B <- (mean.m2* ((cv.m1)^2) ) - (mean.m1*((cv.m2)^2))
D <- ((cv.m1)^2) - ((cv.m2)^2)
C <- (cv.m1*cv.m2) * sqrt((mean.m1 - mean.m2)^2 + ((2 * A) * (cv.m1^2 - cv.m2^2)))
T1 <- (B + C)/D
T2 <- (B - C)/D
results <- data.frame(jm=jm.distance,bh=bh.distance,T1=T1,T2=T2)
return(results)
}

SEaTH (vector.1, vector.2)
>>>
```

Obr. 5.2 – Konečná podoba algoritmu SEaTH připravená jako funkce pro R Studio včetně vzorového volání funkce




## 5.2 Testování tříd

Pro Košice, jakožto první město, které vstupovalo do algoritmu SEaTH se svými trénovacími plochami, bylo vyexportováno větší množství atributů. Po zjištění nejpravděpodobnějších oddělovacích atributů pro hierarchický strom byly poté exportovány pouze atributy potřebné k tomuto rozdělení. Celkové spektrum atributů pro testování obsahovalo:

- Roundness – okrouhlost
- Brightness – světlost
- Compactness – kompaktnost
- Mean blue, green, red, nir – průměry v pásmech RGB a blízkém infračerveném
- Rectangular shape – podobnost čtyřúhelníku
- Maximum difference – maximální rozdíl dvou pixelů v objektu
- Minimum ellipse – nejmenší možná opsaná elipsa
- Density – hustota
- Texture – homogenita textury
- NDVI – normalizovaný diferenční vegetační index

K těmto atributům byly přidány poté ještě některé další na základě předchozí zkušenosti (Pour, 2013), jako jsou například standardní odchylka a HSI transformace pro červené pásmo. V softwaru Definiens Developer bylo nejprve nutné vytvořit trénovací plochy. Ty byly vytvořeny expertním odhadem tak, aby co nejlépe reprezentovaly dané třídy. Poté se tyto trénovací plochy vyexportovaly ve formát ESRI shapefile. Dále byla v programu MS Excel editována atributová část souboru, bylo nutné ji transponovat, desetinné čárky nahradit desetinnými tečkami, uložit ve formátu „csv“ a následně ještě přepsat oddělovací středníky na čárky. Na základě takto upraveného souboru se teprve začala data manuálně vkládat do R Studia.

U základních tříd nebylo potřeba zjišťovat, který atribut bude použit k jejich odlišení. Minimálně první část hierarchického stromu spočívající v oddělení zelené a nezelené plochy byla naprosto v pořádku oddělena pomocí NDVI indexu. V případě města Košic, odkud pocházely všechny trénovací plochy pro první analýzu, dosáhl Jeffries-Matusita distance 1,75 na škále od nuly do dvou. Na ostatních snímcích tato čísla byla ještě vyšší. V této první analýze se ještě počítalo s nezjednodušenými třídami, takže jejich celkový počet byl osm. Na uvedeném snímku vstupuje do výpočtu na jedné straně vysoká a nízká vegetace a na straně druhé všechny zbývající třídy.



Obr. 5.3 – Ukázka indexu NDVI na příkladu města Košice

Druhým krokem bylo odlišení vysoké a nízké vegetace. V tomto případě byl použit již dříve zmiňovaný atribut homogenity v červeném pásmu. Později se ovšem ukázalo, že v některých místech segmentační algoritmus dělil vysokou vegetaci příliš na základě homogenity, takže byla místo tohoto atributu použita standardní odchylka, která s homogenitou souvisí a v tomto případě vykazovala lepší výsledky. K odlišení tmavých ploch sloužil atribut brightness, tedy světlost.

Dalším krokem byl pokus oddělit stíny od vodních ploch. Pro tento účel byl aplikován SEaTH nejprve na jednotlivé třídy vůči ostatním a poté vůči sobě navzájem. Nejvyšší hodnota separability kolem 0,8 je bohužel příliš nízká a třídy nelze na základě těchto charakteristik oddělit. V porovnání s ostatními třídami vidíme, že hlavní odlišnosti jsou především v hodnotě RGB a NIR, světlosti a maximální diferenci. Tyto odlišnosti jsou ke všemu přibližně shodné pro obě třídy.

shade/water	JM	Bha	T1	T2
round	0,03389835	0,01709446	1,952451	0,5981234
bright	0,06814214	0,03466502	NA	NA
compact	0,000648696	0,000324401	6,057033	-1,339307
blue	0,05325089	0,02698632	NA	NA
green	0,8583766	0,5606959	299,118	-84,56598
red	0,458016	0,2600773	NA	NA
nir	0,4386906	0,2476224	NA	NA
rect	0,008598879	0,004308708	0,7824816	0,6626239
diff	0,2685137	0,144167	1,32227	0,4144943
eclipse	0,04151656	0,02097676	0,9237175	0,7397095
density	0,1349162	0,06984118	2,183197	1,342574
texture	0,0190508	0,009571058	0,09001465	0,07269072
ndvi	0,6948615	0,426838	-5,013626	-0,3475583

Obr. 5.4 – Výsledky metody SEaTH mezi vodními stinnými plochami

Po těchto krocích zbývaly čtyři třídy, tedy industriální objekty, červené střechy, silnice a ostatní/volné plochy. U těchto tříd už bylo provedeno testování každé třídy s každou další. Toto testování bohužel neukázalo dominanci určitého atributu u určité třídy. Geometrické atributy neměly prakticky žádnou odlišnost napříč třídami a spektrální charakteristiky vykazovaly pouze odchylky, které lze považovat za anomálie, a nevyjadřují charakteristiku dané třídy. V tomto případě by bylo potřeba automatizované testování více atributů u většího množství objektů, aby bylo s jistotou možné sledovat určité trendy v geometrii nebo spektrálních charakteristikách. Testovací tabulární výstupy z metody SEaTH jsou přiloženy jako příloha číslo 4 k této práci. Kódové označení

v příloze je: bs – bare soil (ostatní/volná půda), bi - buildings industrial (asfaltové střechy), br – buildings red roofs (červené střechy), ro – roads (asfaltové silnice).

V tuto chvíli další postup spočíval v dalších dvou atributech a to sice HSI transformací v červeném pásmu, čímž je možné rozlišit béžové, hnědé a červené plochy od tmavých asfaltových ploch silnic a tmavých střech. Zároveň je také možné s její pomocí odlišit červené a hnědé střechy od béžových hlíněných ploch. Druhým přidaným atributem je standardní odchylka v červeném pásmu, která odráží homogenitu objektu a pomáhá odlišit homogenní střechy od heterogenních ostatních ploch.

### 5.3 Aplikace hierarchické klasifikace


Bohužel, kvůli kombinaci zastaralosti programu a relativně nízkého výpočetního výkonu počítačového vybavení bylo nutné ořezat poměrně složité mozaikované snímky prakticky na souvislou zastavěnou plochu městského jádra. Pro ukázkou základních charakteristik a struktur města to ovšem bylo dostačující.

Po shrnutí všech výše uvedených faktů a faktorů byla vytvořena hierarchická klasifikace. Ta v prvním kroku oddělí zelené a nezelené plochy, ty zelené poté rozdělí podle homogenity a případně standardní odchylky na vysokou a nízkou vegetaci. Na stejné úrovni se na základě světlosti oddělují vodní plochy a stíny jako takzvané „tmavé“ plochy. Poté se na základě odstínu oddělí asfaltové plochy. Pokud v tomto bodě nebyl odstín dostačující, byl jako rozhodující atribut použit průměr v modrém pásmu. V posledním řádku hierarchie byly na základě odstínu a případně standardní odchylky odlišeny červené střechy od ostatních objektů. Tento výše zmíněný postup byl aplikován na všech pět snímků a byla tak vytvořena klasifikace na nízké úrovni.



Obr. 5.5 – Schéma hierarchické klasifikace (červeně vyznačeny třídy, žlutě pomocné třídy)

Na obrázku 5.3 můžeme vidět příklad klasifikace na nízké úrovni. Červená barva odpovídá červeným střechám, světle zelená nízké vegetaci, tmavě zelená vysoké vegetaci, šedá asfaltovým plochám a žlutá ostatním plochám.



Obr. 5.6 – Klasifikace na nízké úrovni, město Košice

Klasifikace na střední úrovni byla vytvořena expertním odhadem tak, aby reprezentovala co nejlépe skladbu ploch uvnitř. Jde taktéž o hierarchickou klasifikaci. Nejprve byly odděleny plochy s více než 50 % asfaltových zastavěných ploch a klasifikovány pracovním jazykem jako „built-up“, tedy zastavěné. V druhém kroku byl stanoven práh na 10 % červených střech. Ve třetím kroku se oddělily plochy, které obsahují více než 50 % zeleně. Zbylé objekty byly klasifikovány jako „mixed“ neboli neurčité. Tato klasifikace měla pomoci při interpretaci snímků a poukázat na oblasti, které jsou velmi silně orientované jedním směrem.

## 6 VÝSLEDKY

Hlavními výsledky této práce jsou polygonové vrstvy ve formátu ESRI shapefile. Tyto polygonové vrstvy spolu s náhledy jsou přiloženy v digitální podobě na DVD, které je označeno jako příloha číslo 1 k této práci.


První z vrstev je vrstva nižší segmentace, která jako atributy obsahuje název třídy, velikost polygonu v pixelech a soubor vybraných atributů. Druhou vrstvou je vždy střední segmentace, která obsahuje název třídy, velikost polygonu v pixelech a procentuální zastoupení tříd nižší úrovně, zastoupené v daném polygonu střední úrovně. Dalším výstupem je statistické srovnání poměru tříd na celém rozsahu snímku.

### 6.1 Vizuelní výstupy

Následující obrázky jsou brány jako náhledy a mají jednotnou barevnou škálu. Při nižší úrovni platí, že světle zelená je nízká vegetace, tmavě zelená je vysoká vegetace, černě zbarvené jsou tmavé plochy, červeně zbarvené jsou červené střechy, šedě zbarvené jsou asfaltové plochy a žlutě zbarvené jsou ostatní plochy. Při střední úrovni jsou plochy s převahou vegetace zelené, plochy s převahou asfaltových ploch fialové, plochy s vyšším podílem (více než 10 %) červených střech červené a zbývající plochy šedo-modré.


### 6.1.1 Katowice

Nízká úroveň klasifikace ukazuje zjevně centrum města, které je protnuto horizontálně nádražím a železniční tratí. Ve střední části v severní polovině snímku se nachází velká žlutá plocha, kterou je, tehdy ještě rozestavěná, multifunkční aréna Spodek. Na snímku je také zřetelná východo-západní orientace hlavních silničních komunikací. Kolem nich se také město rozvíjí a ve východní a západní části snímku nacházíme velké šedivé plochy značící průmyslové areály.



Obr. 6.1 – Náhled nižší úrovně segmentace a klasifikace, město Katowice

Tato hypotéza se potvrzuje při pohledu na střední klasifikaci. Přestože na nižší úrovni byla patrná zástavba s červenými střechami, pouze jediný polygon vyhověl prahové hodnotě 10 % z celkové plochy polygonu. Katowice mají ve svém centru určitý podíl zeleně, ale není tak patrná jako v ostatních městech a nemá formu hustých parků, proto je v klasifikaci zezeň patrná až v odlehlejších částech na okraji měst. I ve střední úrovni jsou patrné velké průmyslové areály podél hlavních komunikací.




Obr. 6.2 – Náhled střední úrovně klasifikace a segmentace, město Katowice




### 6.1.2 Košice

Košice mají po klasifikaci zřetelné městské jádro s historickou zástavbou a červenými střechami. Jako jediné město také vykazuje tuto hustotu ve střední úrovni. V severovýchodní části snímku lze podle stinných ploch odlišit panelová zástavba a blíže ke středu průmyslová zóna podél řeky. Opačným směrem od centra se nachází řidší zástavba a vyšší podíl zeleně.



Obr. 6.3 - Náhled nižší úrovně klasifikace a segmentace, město Košice

Na střední úrovni se nachází dvě větší jádra historických domů, několik průmyslových areálů a v západní části také pruh zeleně. Ostatní hustá zeleň se nachází za hranicí města a zbytek plochy města je heterogenní.



Obr. 6.4 - Náhled střední úrovně klasifikace a segmentace, město Košice


### 6.1.3 Leipzig

Dominantou Leipzig je v centrální části snímku nádraží. V okrajových částech snímku jsou rozsáhlé průmyslové plochy, ale i centrální část města je zastavěna spíše novými budovami, než historickou zástavbou. V severozápadní a severovýchodní části snímku se nachází velké zelené plochy, vzhledem k velkému podílu vysoké vegetace půjde nejspíše o lesoparky.



Obr. 6.5 - Náhled nižší úrovně klasifikace a segmentace, město Leipzig

Střední úroveň poukazuje na velkou míru asfaltových ploch a zástavby města. Zelené plochy a průmyslové areály ve východní části města jsou ještě viditelnější.



Obr. 6.6 - Náhled střední úrovně klasifikace a segmentace, město Leipzig


#### 6.1.4 Ostrava

U klasifikace Ostravy je zřetelná neuspořádanost města. Červené střechy budov se zde objevují vmísené mezi další asfaltové plochy, průmyslové areály a plochy s vegetací. Spíše než historické centrum v severní části snímku upoutává pozornost obrovský průmyslový areál v centrální části snímku. Pro analýzu Ostravy byla, bohužel, z důvodu výpočetního výkonu oddělena západní část Ostrava-Poruba.



Obr. 6.7 - Náhled nižší úrovně klasifikace a segmentace, město Ostrava

Ve střední úrovni je patrná převaha zastavěných ploch, odpovídajících průmyslovým areálům a asfaltovým silnicím nebo střechám. Menší plochy vegetace jsou na snímku prakticky neuspořádaně umístěny mezi ostatní objekty.



Obr. 6.8 - Náhled střední úrovně klasifikace a segmentace, město Ostrava


### 6.1.5 Székesfehérvár

Na snímku vidíme centrum města hustě zastavěné domy s asfaltovými střechami, ve východní a západní části centra je poté možné rozeznat vyšší panelovou zástavbu. Průmyslové areály jsou situovány v severní, východní a jižní části snímku oddělené od centra. V severovýchodní části je možné rozpoznat souvislou zástavbu rodinných domů.



Obr. 6.9 - Náhled nižší úrovně klasifikace a segmentace, město Székesfehérvár

Střední úroveň potvrzuje myšlenku zastavěného centra bez historických budov. Také zvýrazňuje oddělené průmyslové areály v okrajových částech snímku. Větší zelené plochy přetrvávají i v hranicích města.



Obr. 6.10 - Náhled střední úrovně klasifikace a segmentace, město Székesfehérvár



## 6.2 Statistické srovnání

Dalším klíčovým srovnáním je statistický podíl ploch v rámci celého snímku. Tato statistika byla kvůli komplikacím s GIS softwarem zpracována pomocí Microsoft Excel po manuálním shlukování podle třídy z atributové tabulky ESRI shapefile. Plochy měst jsou srovnatelné a dosahují hodnot od 100 do 180 miliónů pixelů. Největší rozdíl je mezi Leipzig a Ostravou. Tento rozdíl je způsobený především faktem, že snímek Leipzig nezahrnoval celé město, ale byl pouze výřezem jeho části.

### 6.2.1 Nízká úroveň

V následující tabulce Košice jasně zaostávají za ostatními městy v podílu zastavěné plochy. Zatímco Košice mají méně než 25 %, u ostatních měst se podíl asfaltových a zastavěných ploch pohybuje od 40 do 50 procent. Červené střechy až na výjimku Székesfehérvár dosahují několika procent celkové plochy. V tomto městě se červené střechy vyskytují pouze v 0,62 % celkového rozsahu snímku. Košice také vynikají největším podílem vegetace, kdy celková relativní rozloha vegetace přesahuje 50 %. Naopak výrazně nižší podíl vegetace můžeme sledovat u Ostravy a Leipzig. Dvě zbývající města, tedy Székesfehérvár a Katowice mají podíl vegetace kolem 40 %. Viz příloha číslo 2 – Tabulka srovnání měst, nižší úroveň.

### 6.2.2 Střední úroveň

Trochu méně relevantní charakteristikou urbánního prostoru je střední úroveň klasifikace, která generalizuje mnoho jevů. Je v ní ovšem možné sledovat trendy z nízké úrovně, tedy vysoký podíl zastavěných a asfaltových ploch v Ostravě a Leipzig, stejně jako vysokou míru vegetace v Košicích. Zajímavým jevem jsou necelá dvě procenta zastavěné plochy ve městě Košice. Město při nižší úrovni klasifikace dosahovalo srovnatelné úrovně zastavěné plochy, ale ta není koncentrována na konkrétních místech, ale je rozptýlena. Město tak nevykazuje mnoho ploch se zástavbou přesahující 50 % obsahu plochy. Viz příloha číslo 3 – Tabulka srovnání měst, střední úroveň.

## 7 DISKUZE

Bylo by vhodné na úvod diskuze zmínit, že na jednotlivé kroky této práce se píše samostatné dizertační práce a na podobných projektech pracují týmy specialistů mnohdy z několika pracovišť. Tato práce si neklade za cíl určit nejvhodnější postup nebo testovat metody. Cílem práce bylo vyhledat metody pro extrakci prostorových informací a aplikovat je v těžkých podmínkách velmi odlišných snímků a oblastí.

Základní metody, jako je obrazová fúze nebo segmentace, stále nemají určené přesné postupy a neexistuje žádný jednotný postup nebo tabulka s doporučenými nastaveními. Metody jako je SEaTH nebo jiné klasifikační metody, mají často velmi odlišné výsledky při použití na různých datech a ani vysoká přesnost klasifikace není zárukou její kvality a možnosti její interpretace. Ve všech bodech práce také existuje více metod zpracování. Existuje více než pět metod obrazové fúze a každá se chová k jinému snímku jinak a produkuje výsledky s různou kvalitou. Každá z těchto metod má také své vlastní nastavení. Existuje také množství různých software řešení a každé zpracovává aplikaci dané metody trochu odlišně. Segmentace je postup, který není vůbec popsán ani nijak blíže přiblížen. Vzhledem k patentům a utajování algoritmů pro segmentaci obrazu máme možnost se domnívat, že tyto algoritmy mohou pracovat na naprosto odlišném principu. Nejenže existuje více druhů klasifikace, jako je například per-pixel nebo řízená klasifikace s trénovacími plochami, ale i v rámci metody SEaTH by se dalo zvolit více metod pro výpočet prahů a vzdáleností mezi třídami. Již v průběhu práce byla naznačena nutnost automatizovat metodu SEaTH ve formě aplikace. Po zpracování klasifikace na nízké úrovni bylo přistoupeno ke korekci hrubých chyb, které ovlivňovaly klasifikaci na střední úrovni. Počet manuálně pozměněných objektů nepřesáhl číslo pět v rámci jednoho snímku. Celkem šlo asi o deset případů v celé datové sadě.

Práce v programu Definiens Developer ve verzi staré 8 let nebyla ideální pro tuto práci. Novější verze tohoto softwaru je mnohem lépe uzpůsobena moderním počítačům a obsahuje také některé nové funkce a přehlednější uživatelské rozhraní. Tomuto ještě více uškodil obrovský objem zpracovaných dat. Zpracování některých metod, především segmentace, trvalo hodiny u každého snímku a znemožňovalo tak opakování postupu několikrát s různým nastavením. Rozhodně by práci pomohla analýza ještě menšího území, například po vymezení centra města. S menším územím a menším rozptylem typů objektů v dané třídě se i zvyšuje přesnost klasifikace. Práci by rozhodně také pomohlo vymezení hranic měst, další pomocná data, především LIDARová nebo i správní data.

K práci není přiložen accuracy assesement (hodnocení přesnosti) klasifikace. Jeho nutnost v tomto případě je ovšem možné zpochybnit. Výsledky metody SEaTH nejsou v této případové studii zcela přesné. Při bližším ohledání lze zjistit nedostatky způsobené již v segmentační části. Cílem této práce ale není zhodnotit metodu SEaTH proti jiným klasifikačním metodám, to již bylo provedeno v rámci rešeršní části jiným autorem. V případě menšího území a snahy o přesnější klasifikaci, nebo pokud by cílem práce byla pouze klasifikace, by hodnocení přesnosti bylo součástí práce, ale v tomto případě z něj bylo z časových důvodů upuštěno.

Dalším souvisejícím bodem jsou časové komplikace. Během práce bylo objeveno množství nefunkčních metod nebo postupů hlavně v programu Definiens Developer. Vzhledem k velmi staré verzi programu nešel zjistit postup řešení a bylo často nutné hledat alternativy. Dalším časovým zdržením byla komplikace s VPN přístupem na VŠB-TUO, přes který byl software Definiens Developer poskytován autorovi práce. Kvůli vypršení přiděleného období a komplikacím se studentským účtem ztratil autor přibližně dva měsíce času v období, kdy bylo možné na tématu nejvíce pracovat.

Výsledky práce jsou vhodné pro srovnání struktury města. V tomto případě by mohla být užitečná i analýza kruhových výsečí ze středu města. I základní statistika ploch naznačuje hlavní trendy v rámci jednoho města a i mezi městy navzájem. Pro další výzkum by autor, mimo výše zmíněných technických poznámek, doporučil buď se detailněji se zaměřit na těchto pět měst a zapojit do analýzy i pomocná data, nebo, po odstranění některých problémů, srovnávat více měst na této úrovni podrobnosti.

Velkým přínosem práce je praktické nasazení metody SEaTH a velký objem času strávený analýzou velkých datových sad. Autor práce by se rád i v budoucnu zabýval tímto tématem a především zlepšováním a lepším zapojováním matematických metod do analýzy obrazu.

## 8 ZÁVĚR

Tato práce se snaží nastínit postup při zpracování několika družicových snímků městských oblastí z různých senzorů. V práci je nastíněn postup od zakoupení snímků po atmosférické korekci až po interpretaci výsledků.

V první fázi, takzvaném předzpracování, bylo využito obrazové fúze ke zlepšení informací, které je možné získat ze snímku. Dále bylo přistoupeno k mozaikování rozdělených snímků jednoho města. V dalším kroku se přistoupeno ke dvouúrovňové segmentaci snímku, při které nižší úroveň byla na úrovni objektu, vyšší z úrovní byla na úrovni přibližných městských bloků.

Ve druhé fázi práce proběhla klasifikace obrazu s pomocí metody SEaTH. Byla vytvořena hierarchická klasifikace, do které byly dosazeny parametry na základě matematických metod určujících separabilitu a prahy. Aplikací této metody na všech měst vznikla dvouúrovňová klasifikace.

Třetím a posledním bodem práce byla interpretace výsledků. Bylo použito základních statistických analýz a slovního popisu vizualizované klasifikace. Ve výsledcích práce autor popisuje základní charakteristiky jednotlivých měst včetně významných prvků viditelných na snímcích i v klasifikaci. Některá města vykazují větší známky průmyslového rozvoje než jiná, stejně jako vykazují odlišný podíl a rozmístění vegetace.

V diskuzi poté autor shrnul základní problémy při zpracování tématu a vyjádřil potřebu tyto postupy dále jednotlivě zkoumat a zdokonalovat.

## POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

ALEKSANDROWICZ, Sebastian, Konrad TURLEJ, Stanisław LEWIŃSKI a Zbigniew BOCHENEK. 2014. Change Detection Algorithm for the Production of Land Cover Change Maps over the European Union Countries. *Remote Sensing*. **6**(7): 5976-5994. DOI: 10.3390/rs6075976. ISSN 2072-4292. Dostupné také z: <http://www.mdpi.com/2072-4292/6/7/5976/>

ANAS, Alex, Richard ARNOTT a Kenneth A. SMALL. 1997. *Urban Spatial Structure* [online]. [cit. 2015-05-11].

BANZHAF, Ellen, Volker GRESCHO, Maik NETZBAND, Katrine HANNEMANN a Mike MARTINI. 2007. *Monitoring the urban development with integrated system from RS observation and GIS information* [online]. [cit. 2015-05-11].

BLASCHKE, T. 2010. *Object based image analysis for remote sensing* [online]. [cit. 2015-05-11].

BLASCHKE, Thomas, Geoffrey J. HAY, Maggi KELLY, Stefan LANG, Peter HOFMANN, Elisabeth ADDINK, Raul QUEIROZ FEITOSA, Freek VAN DER MEER, Harald VAN DER WERFF, et al. 2014. Geographic Object-Based Image Analysis – Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*. **87**: 180-191. DOI: 10.1016/j.isprsjprs.2013.09.014. ISSN 09242716. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0924271613002220>

DU, Peijun, Pei LIU, Junshi XIA, Li FENG, Sicong LIU, Kun TAN a Liang CHENG. 2014. Remote Sensing Image Interpretation for Urban Environment Analysis: Methods, System and Examples. *Remote Sensing*. **6**(10): 9458-9474. DOI: 10.3390/rs6109458. ISSN 2072-4292. Dostupné také z: <http://www.mdpi.com/2072-4292/6/10/9458/>

FREIRE, S., T. SANTOS, N. GOMES, A. FONSECA a J. A. TENEDÓRIO. 2010. *Extraction Of Buildings From Quickbird Imagery – What Is The Relevance Of Urban Context And Heterogeneity?* [online]. [cit. 2015-05-11].

GAO, Y., J. F. MAS, I. NIEMEYER, P. R. MARPU a J. L. PALACIO. 2006. *Object-Based Image Analysis For Mapping Land-Cover In A Forest Area* [online]. [cit. 2015-05-11].

GEIß, Christian, Hannes TAUBENBÖCK, Michael WURM, Thomas ESCH, Michael NAST, Christoph SCHILLINGS a Thomas BLASCHKE. 2011. Remote Sensing-Based Characterization of Settlement Structures for Assessing Local Potential of District Heat. *Remote Sensing*. **3**(12): 1447-1471. DOI: 10.3390/rs3071447. ISSN 2072-4292. Dostupné také z: <http://www.mdpi.com/2072-4292/3/7/1447/>

GIANINETTO, Marco. 2014. Hierarchical classification of complex landscape with VHR pan-sharpened satellite data and OBIA techniques. *European Journal of Remote Sensing*. : 229-250. DOI: 10.5721/EuJRS20144715. ISSN 22797254. Dostupné také z: <http://www.aitjournal.com/articleView.aspx?ID=886>

HERMOSILLA, Txomin a Luis RUIZ. 2013. *Multi-level Object-based Urban Mapping from Remote Sensing and GIS Data* [online]. [cit. 2015-05-11].

HÖFER, René, Ellen BANZHAF a Annemarie EBERT. 2009. *Delineating urban structure types (UST) in a heterogeneous urban agglomeration with VHR and TerraSAR-X data* [online]. [cit. 2015-05-11].

CHAKRABORTY, Mousumi a Annemarie EBERT. 2009. *An approach towards urban form analysis and landuse classification: A case of Ahmedabad, India* [online]. [cit. 2015-05-11].

JOHANSEN, Kasper, Stuart PHINN, Christian WITTE, Seonaid PHILIP a Lisa NEWTON. 2009. *Mapping Banana Plantations from Object-oriented Classification of SPOT-5 Imagery* [online]. [cit. 2015-05-11].

JUERGENS, Carsten, Alexander SIEGMUND a Deryan MAKTAV. 2011. *Potential Open Space Detection and Decision Support for Urban Planning by Means of Optical VHR Satellite Imagery* [online]. [cit. 2015-05-11].

KULKARNI, Amit. 1997. *An Object-Based Image Analysis Approach For Detecting Urban Impervious Surfaces* [online]. [cit. 2015-05-11].

MOON, Kiduk, Nigel DOWNES a Hendrik RUJNER. 2009. *Adaptation of the Urban Structure Typ Approach for Vulnerability Assessment of Climate Change Risks in Ho Chi Minh City* [online]. [cit. 2015-05-11].

NOVACK, Tessio, Thomas ESCH, Hermann KUX a Uwe STILLA. 2011. Machine Learning Comparison between WorldView-2 and QuickBird-2-Simulated Imagery Regarding Object-Based Urban Land Cover Classification. *Remote Sensing*. **3**(12): 2263-2282. DOI: 10.3390/rs3102263. ISSN 2072-4292. Dostupné také z: <http://www.mdpi.com/2072-4292/3/10/2263/>

NOVACK, Thomas a U. STILLA. 2014. *Classification Of Urban Settlements Types Based On Space-Borne Sar Datasets* [online]. [cit. 2015-05-11].

NUSSBAUM, S., I. NIEMEYER a M. J. CANTY. 2006. *Seath - A New Tool For Automated Feature Extraction In The Context Of Object-Based Image Analysis* [online]. [cit. 2015-05-11].

PELLEGRINO, Cristina. 2007. *Decision Support System for Brownfield Site Sustainable Regeneration* [online]. [cit. 2015-05-11].

POUR, Tomáš. 2013. *Detekce volných ploch na území města Olomouc pomocí metod dálkového průzkumu Země* [online]. [cit. 2015-05-11].

TARANTINO, Eufemia a Benedetto FIGORITO. 2011. Extracting Buildings from True Color Stereo Aerial Images Using a Decision Making Strategy. *Remote Sensing*. **3**(12): 1553-1567. DOI: 10.3390/rs3081553. ISSN 2072-4292. Dostupné také z: <http://www.mdpi.com/2072-4292/3/8/1553/>

VANHUYSSSE, Sabine, Carla IPPOLITI a Annamaria CONTE. 2009. *Object-Based Classification Of Spot And Aster Data Complemented With Data Derived From Modis Vegetation Indices Time Series In A Mediterranean Test-Site* [online]. [cit. 2015-05-11].

WALKER, Wayne a Ned HORNING. 2010. *An Introduction to Image Segmentation and Object-oriented Analysis* [online]. [cit. 2015-05-11].

WAQAR, Mirza, Johum MIRZA, Rafia MUMTAZ a Ejaz HUSSAIN. 2010. *Development of New Indices for Extraction of Built-Up Area & Bare Soil from Landsat Data* [online]. [cit. 2015-05-11].

WURM, Michael, Hannes TAUBENBÖCK a Stefan DECH. 2010. *Quantification of urban structure on building block level utilizing multisensoral remote sensing data* [online]. [cit. 2015-05-11].

YU, Xiaomin, Feibing ZHAN, Mingsheng LIAO a Jinxing HU. 2012. *Object-oriented Feature Selection Algorithms Based on Improved SEaTH Algorithms* [online]. [cit. 2015-05-11].

ZHAN, Qingming, MOLENAAR a Klaus TEMPFLI. 2002. *Hierarchical Image Object-based Structural Analysis Toward Urban Land Use Classification Using High-Resolution Imagery nad Airborne LIDAR Data* [online]. [cit. 2015-05-11].

## **PŘÍLOHY**



# SEZNAM PŘÍLOH

## **Volné přílohy**

Příloha 1 DVD

## **Vázané přílohy:**

Příloha 2 Tabulka srovnání měst, nízká úroveň

Příloha 3 Tabulka srovnání měst, střední úroveň

Příloha 4 Testování čtyř tříd pomocí SEaTH

## Příloha číslo 2 – Tabulka srovnání měst, nízká úroveň

Szekesfehervar - nízká úroveň	Rozloha (px)	Rozloha (% z celku)
Tmavé plochy	340006	0,23
Vysoká vegetace	18910599	12,89
Nízká vegetace	46559054	31,74
Ostatní/volné plochy	22381431	15,26
Červené střechy	903997	0,62
Asfaltové plochy	57575273	39,25
<b>Celkem</b>	<b>146670360</b>	<b>100</b>

Katowice - nízká úroveň	Rozloha (px)	Rozloha (% z celku)
Tmavé plochy	8132081	5,37
Vysoká vegetace	60195221	39,77
Nízká vegetace	63284	0,04
Ostatní/volné plochy	20954604	13,84
Červené střechy	5605427	3,70
Asfaltové plochy	56414663	37,27
<b>Celkem</b>	<b>151365280</b>	<b>100</b>

Košice - nízká úroveň	Rozloha (px)	Rozloha (% z celku)
Tmavé plochy	14882354	11,84
Vysoká vegetace	46480402	36,96
Nízká vegetace	19702766	15,67
Ostatní/volné plochy	9096079	7,23
Červené střechy	4431308	3,52
Asfaltové plochy	31148790	24,77
<b>Celkem</b>	<b>125741699</b>	<b>100</b>

Ostrava - nízká úroveň	Rozloha (px)	Rozloha (% z celku)
Tmavé plochy	21930678	12,26
Vysoká vegetace	47671821	26,64
Nízká vegetace	11010220	6,15
Ostatní/volné plochy	14504429	8,11
Červené střechy	4857638	2,71
Asfaltové plochy	78963418	44,13
<b>Celkem</b>	<b>178938204</b>	<b>100</b>

Leipzig - nízká úroveň	Rozloha (px)	Rozloha (% z celku)
Tmavé plochy	5599944	5,41
Vysoká vegetace	23320308	22,54
Nízká vegetace	583705	0,56
Ostatní/volné plochy	18929898	18,30
Červené střechy	2431946	2,35
Asfaltové plochy	52600192	50,84
<b>Celkem</b>	<b>103465993</b>	<b>100</b>

### Příloha číslo 3 – Tabulka srovnání měst, střední úroveň

Szekesfehervar - střední úroveň	Rozloha (px)	Rozloha (% z celku)
Zastavěné	27577084	18,80
Ostatní/smíšené	84003800	57,27
Vegetace	35107575	23,93
Červené střechy	0	0,00
<b>Celkem</b>	<b>146688459</b>	<b>100</b>

Katowice - střední úroveň	Rozloha (px)	Rozloha (% z celku)
Zastavěné	33331685	22,03
Ostatní/smíšené	78717002	52,03
Vegetace	39249192	25,94
Červené střechy	0	0,00
<b>Celkem</b>	<b>151297879</b>	<b>100</b>

Košice - střední úroveň	Rozloha (px)	Rozloha (% z celku)
Zastavěné	2216221	1,76
Ostatní/smíšené	63181491	50,26
Vegetace	52461445	41,74
Červené střechy	7839598	6,24
<b>Celkem</b>	<b>125698755</b>	<b>100</b>

Ostrava - střední úroveň	Rozloha (px)	Rozloha (% z celku)
Zastavěné	75753911	42,40
Ostatní/smíšené	60367657	33,79
Vegetace	42523439	23,80
Červené střechy	0	0,00
<b>Celkem</b>	<b>178645007</b>	<b>100</b>

Leipzig - střední úroveň	Rozloha (px)	Rozloha (% z celku)
Zastavěné	68376545	66,13
Ostatní/smíšené	24007912	23,22
Vegetace	11006140	10,65
Červené střechy	0	0,00
<b>Celkem</b>	<b>103390597</b>	<b>100</b>

## Příloha číslo 4 – Testování čtyř tříd pomocí SEaTH

bs/br	JM	Bha	T1	T2
round	0,05663866	0,02872806	1,348837	2,233008
bright	0,4009454	0,2237346	-3206,151	3933,698
compact	0,1137786	0,05857161	1,671629	4,009733
blue	0,00676572	0,003388595	NA	NA
green	0,003224	0,0016133	NA	NA
red	0,6108315	0,3644418	-6583,547	7177,514
nir	0,6988576	0,4299045	-4975,853	5872,025
rect	0,007591189	0,003802816	0,5943725	0,6883805
diff	0,1363772	0,07062486	1,628472	0,6133325
eclipse	0,05623448	0,0285201	0,9215491	1,223637
density	0,3218068	0,1754295	1,373926	0,9743049
texture	0,7808078	0,4949587	0,022972	0,06341438
<b>ndvi</b>	<b>0,7967619</b>	<b>0,5081308</b>	<b>0,1152787</b>	<b>0,1083235</b>

bs/bi	JM	Bha	T1	T2
round	0,2311673	0,1228274	1,329917	8,119452
bright	0,6871216	0,4209252	-4328,924	5067,229
compact	0,2203514	0,1167313	2,086718	9,636345
blue	0,7326726	0,4562369	-1960,049	2534,266
green	0,6200019	0,371065	-9539,449	10384,22
red	0,5420824	0,3161381	-8341,187	8971,088
nir	0,6585748	0,3994146	-5609,636	6509,876
rect	0,2181811	0,1155125	1,022984	0,7455198
diff	0,01204708	0,006041757	0,5303338	0,4877019
eclipse	0,2343546	0,1246309	0,8541804	-0,5285502
density	0,01776292	0,008921134	-0,2738122	1,671295
texture	0,1849287	0,09702244	0,03278155	0,0570969
<b>ndvi</b>	<b>0,8019605</b>	<b>0,5124607</b>	<b>0,03155387</b>	<b>-0,1213502</b>

bs/ro	JM	Bha	T1	T2
round	0,09452251	0,04841455	1,119975	2,061046
bright	1,287701	1,032405	846,6502	-349,2606
compact	0,262073	0,1404542	1,356503	4,165017
blue	0,3708072	0,2050625	556,8772	-31,20176
green	0,7478107	0,4682537	1349,567	-682,7607
red	1,028177	0,7217287	875,6	-452,4555
<b>nir</b>	<b>1,883454</b>	<b>2,842617</b>	<b>992,8016</b>	<b>-665,6277</b>
rect	0,05147856	0,02607633	0,6024666	0,7899351
diff	0,4824369	0,2760413	0,5227309	0,5128055
eclipse	0,09734698	0,04989794	0,8705284	1,04009
density	0,9208167	0,6169427	1,19165	13,65721
texture	0,08725672	0,0446087	0,07889011	0,05647803
<b>ndvi</b>	<b>0,9466006</b>	<b>0,6411247</b>	<b>0,02082646</b>	<b>-0,03256924</b>

ro/br	JM	Bha	T1	T2
round	0,08854117	0,04528045	1,84	-0,5128633
bright	1,385978	1,180871	-764,3217	1274,388
compact	0,08408074	0,04294964	4,846481	-0,6911699
blue	0,4309084	0,2426503	-73,41252	597,779
green	0,6909208	0,4238232	-782,6878	1449,264
red	1,567568	1,531478	-681,4102	1105,858
nir	1,597269	1,602633	-2115,084	2535,962
rect	0,03103982	0,0156416	0,9908926	0,6058022
diff	0,6930073	0,4254184	0,4965543	0,5350875
eclipse	0,1096243	0,05637161	0,9633654	0,5029748
density	0,5757816	0,339524	1,65293	1,108605
texture	0,6557101	0,3972812	0,04646004	0,06690116
ndvi	1,326214	1,08799	0,1683261	0,08359846

ro/bi	JM	Bha	T1	T2
round	0,3415536	0,1872659	1,476484	-0,002554821
bright	1,208922	0,9275062	-1020,226	1531,721
compact	0,3880044	0,2156743	3,162132	0,1794941
blue	1,173367	0,883542	-322,5204	850,7161
green	1,222804	0,9452101	-1421,731	2092,26
red	1,286222	1,03033	-820,7871	1245,671
nir	1,086969	0,7841324	-2368,599	2790,858
rect	0,3856141	0,2141925	0,9429686	0,7380332
diff	0,388613	0,2160519	0,5131856	0,5224973
eclipse	0,3594914	0,1981409	0,8474474	0,5491705
density	1,057714	0,7525938	66,23761	1,233925
texture	0,1323642	0,06847382	0,05533564	0,06166215
ndvi	0,105818	0,05436008	-0,007374388	0,0105143

br/bi	JM	Bha	T1	T2
round	0,09420138	0,04824604	1,309341	0,2072009
bright	0,2264902	0,1201866	-12253,04	13151,98
compact	0,1446197	0,07505748	2,769208	0,4382369
blue	0,7385213	0,4608626	-1663,167	2248,945
green	0,6531472	0,3953765	-8359,299	9188,46
red	0,156074	0,08125017	-17954,05	18929,31
nir	0,2130742	0,1126505	-28388,31	29738,54
rect	0,2219536	0,1176319	0,9354451	0,7530132
diff	0,1879383	0,09868191	0,5956976	-0,3521546
eclipse	0,08993165	0,04600816	0,8032732	0,5721071
density	0,4689139	0,2671699	0,9204554	1,402571
texture	0,2748567	0,147837	0,07677215	-0,007472244
ndvi	1,16279	0,8708271	0,09590779	0,1331797