

**UNIVERZITA KARLOVA V PRAZE**

**Přírodovědecká fakulta**

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Markéta HORŇÁKOVÁ

**AUTOMATICKÁ EXTRAKCE BUDOV  
A ZPEVNĚNÝCH PLOCH Z DAT VELMI VYSOKÉHO  
ROZLIŠENÍ V SUBURBÁNNÍ ZÓNĚ PRAHY**

**AUTOMATIC EXTRACTION OF BUILDINGS AND  
IMPREVIOUS AREAS FROM VERY HIGH RESOLUTION  
DATA IN SUBURBAN AREA OF PRAGUE**

Diplomová práce

Vedoucí diplomové práce: RNDr. Lucie Kupková, Ph.D

Praha 2011

# Zadání diplomové práce

**pro** Markétu Horňákovou

**obor** Kartografie a geoinformatika

**Název tématu:** Automatická extrakce budov a zpevněných ploch z dat velmi vysokého rozlišení v suburbánní zóně Prahy

## Zásady pro vypracování

Předmětem práce je vypracování vhodné metodiky pro automatickou extrakci budov a zpevněných ploch z dat velmi vysokého rozlišení pro účely hodnocení vývoje zástavby v suburbánní zóně Prahy, především v oblastech komerční suburbanizace.

Práce se zaměří na:

Rešerši literatury s cílem podat přehled stávajících využitelných metod klasifikace a extrakce budov a zpevněných ploch z dat velmi vysokého rozlišení.

Navržení vlastního postupu pro extrakci budov a zpevněných ploch ve vybraných oblastech komerční suburbanizace v zázemí Prahy s využitím objektově orientované klasifikace.

Nalezení metod (pravidel) pro rozlišení různých typů střech a zpevněných ploch v závislosti na materiálu (spektrálních charakteristikách), tvarových charakteristikách a případně také s využitím dat o relativní výšce objektů.

Zhodnocení přesnosti navrženého postupu s využitím dat zpracovaných ruční vektorizací budov a zpevněných ploch.

Diskusi využitelnosti navrženého postupu v praktických aplikacích - například monitorování rozšiřování suburbánních zón pro účely územního plánování a správu území.

Výstupem práce bude mapa extrahovaných budov a zpevněných ploch, soubor klasifikačních pravidel (popis tříd, klasifikačních příznaků, prahových hodnot a funkcí příslušnosti) a výsledky hodnocení přesnosti navrženého postupu.

Práce bude vycházet z projektu MŽP ČR Suburbánní rozvoj, suburbanizace a urban sprawl v České republice: omezení negativních důsledků na životní prostředí a z projektu GAČR Regionální diferenciaci a potenciální rizika využití ploch jako odraz funkčních změn krajiny Česka 1990–2010.

**Rozsah grafických prací:** podle potřeby

**Rozsah průvodní zprávy:** 60 – 80 stran

**Seznam odborné literatury:**

KOLÁŘ, J., HALOUNOVÁ, L. PAVELKA, K. (1997): Dálkový průzkum Země 10. Praha: ČVUT, 164 s.

RIDD, M. K., HIPPLE J. D.(2006): Manual of Remote Sensing, Vol. 5, Remote Sensing of Human Settlements, ASPRS

SCHOWENGERDT, R. A.(2007): Remote sensing : models, and methods for image processing. Burlington : Academic Press, 515 s.

HEROLD, M., GARDNER, M. et al. (2002): The spectral dimension in urban land cover mapping from high-resolution optical remote sensing data. Proceedings of the 3rd Symposium on Remote Sensing of Urban Areas, June 2002, Istanbul

SMALL, Ch. (2002): High spatial resolution spectral mixture analysis of urban reflectance. Remote Sensing of Environment 88, s. 170–186

GAO, Y., MAS, J. F. (2008). A comparison of the performance of pixel-based and object-based classifications over images with various spatial resolutions. Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVIII-4/C1

Vedoucí diplomové práce: RNDr. Lucie Kupková, Ph.D.

Konzultant diplomové práce:

Datum zadání diplomové práce: prosinec 2010

Termín odevzdání diplomové práce: srpen 2011

*Platnost tohoto zadání je po dobu jednoho akademického roku.*

.....  
Vedoucí diplomové práce

.....  
Vedoucí katedry

V Praze dne

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně a že jsem všechny použité prameny řádně citovala.

Jsem si vědoma toho, že případné použití výsledků, získaných v této práci, mimo Univerzitu Karlovu v Praze je možné pouze po písemném souhlasu této univerzity.

Svoluji k zapůjčení této práce pro studijní účely a souhlasím s tím, aby byla řádně vedena v evidenci vypůjčovatelů.

V Praze dne 21.8. 2011

Markéta Hornáková

## **Poděkování**

Na tomto místě bych ráda poděkovala vedoucí mé diplomové práce RNDr. Lucii Kupkové, Ph.D. za trpělivost, cennou pomoc a poskytnuté rady. Dále RNDr. Jakobovi Lysákovi za konzultaci při zpracování dat leteckého laserového skenování. V neposlední řadě také své rodině za neustálou podporu.

# Automatická extrakce budov a zpevněných ploch z dat velmi vysokého rozlišení v suburbánní zóně Prahy

## Abstrakt

V současné době, kdy jsou družicová data velmi vysokého rozlišení a data leteckého laserového skenování dostupnější, roste také možnost jejich využívání v různých typech aplikací. S rychlým rozvojem zázemí měst vzrůstá potřeba monitorovat tyto suburbánní oblasti, aby nedocházelo k nekoordinované výstavbě. Tato práce se proto zaměřuje na objektově orientovanou klasifikaci s cílem navržení vlastního metodického postupu pro extrakci budov a zpevněných ploch ve vybraných oblastech komerční suburbanizace v okolí Prahy. Cílem bylo mimo jiné nalezení pravidel pro rozlišení různých typů střech a zpevněných ploch v závislosti na materiálu, tvarových charakteristikách atd. Literární rešerše podává v úvodu přehled metod klasifikace a extrakce budov a zpevněných ploch s využitím optických dat velmi vysokého rozlišení a výškových dat.

Pro analýzu modelových území zón komerční suburbanizace v zázemí Prahy byly využity snímky velmi vysokého rozlišení ze senzoru Quickbird a výšková data leteckého laserového skenování LIDAR a metody objektově orientované klasifikace. Navržený metodický postup využívá v procesu klasifikace informace o výšce vycházející z nDSM (normalized digital surface model) a dále soubor navržených klasifikačních pravidel pro extrakci různých typů zpevněných ploch. Pro klasifikaci byl využit software eCognition 8.0. Výsledky klasifikace byly exportovány do formátu shp. a přesnost klasifikace byla hodnocena na základě porovnání klasifikačního výstupu s referenčními vektorovými vrstvami, které byly výstupem manuální vektorizace dat.

Přesnost výstupů klasifikace, zejména v případě klasifikace budov, je dostatečná k tomu, aby navržený postup s využitím elevačních dat mohl být využíván pro aktualizaci informací o území a k monitoringu rozvoje suburbanizace.

**Klíčová slova:** OBIA, nDSM, QuickBird, budovy a zpevněné povrchy, komerční suburbanizace, eCognition

# **Automatic extraction of buildings and impervious areas from very high resolution data in suburban area of Prague**

## **Abstract**

Nowdays, when the very high resolution satellite imagery and airborne laser scanning data have become more accessible, the possibility of their use for different types of applications increased also. With a rapid development of urban hinterlands the demand to monitor these areas increases also with the goal to avoid uncoordinated construction. This work therefore focuses on an object oriented based classification in order to design its own methodological approach for the extraction of buildings and impervious areas in selected areas of commercial suburbanization in the Prague hinterland. The aim is among others to find the classification rules for distinguishing different types of roofs and impervious areas depending on the material, shape characteristic etc. The literature overview summarizes methods of buildings and impervious areas classification and extraction using very high resolution optical data and elevation data.

Very high resolution QuickBird imagery and airborne laser scanning LIDAR elevation data and object oriented classification methods were used for and analysis of selected commercial suburbanization model areas in Prague hinterland. The proposed methodology uses elevation information from nDSM layer (normalized digital surface model) and also set of proposed classification rules for the extraction of various types of roofs and other impervious areas. Software eCognition 8.0 was used for the classification. Results of the classification were exported to a shp. format and classification accuracy was evaluated comparing the classification output with reference vector layers, which were an output of manual vectorisation of the same image data.

The accuracy of results is satisfying. The proposed approach with using elevation data is suitable for monitoring commercial suburbanization and impervious areas. The technique can be used to update the information about area and for monitoring of suburbanization development.

**Keywords:** OBIA, nDSM, QuickBird, building and impervious surfaces, commercial suburbanization, eCognition

# OBSAH

<b>Přehled použitých zkratků.....</b>	<b>10</b>
<b>Seznam obrázků a tabulek .....</b>	<b>11</b>
<b>1. Úvod .....</b>	<b>13</b>
<b>2. Vstup do problematiky a literární rešerše.....</b>	<b>15</b>
2.1 Družicová data .....	16
2.2 Využití VHR dat pro mapování suburbanizace .....	18
2.3 Přístupy ke klasifikaci VHR dat.....	20
2.3.1 <i>Pixelová klasifikace</i> .....	20
2.3.2 <i>Objektově orientovaná klasifikace</i> .....	22
2.3.2.1 Segmentace .....	22
2.3.2.2 Klasifikace .....	26
2.3.3 <i>Objektově orientovaná klasifikace s využitím DEM</i> .....	29
2.4 Land cover .....	33
<b>3. Metodika .....</b>	<b>34</b>
3.1 Modelové území Jirny.....	35
3.2 Data a software .....	36
3.3 Předzpracování družicových snímků .....	37
3.4 Transformace družicových snímků .....	38
3.5 Tvorba nDSM .....	39
3.6 Objektově orientovaná klasifikace.....	43
3.6.1 <i>Multiměřítková segmentace</i> .....	44
3.6.2 <i>Tvorba klasifikační báze s využitím nDSM</i> .....	45
<b>4. Výsledky.....</b>	<b>53</b>
4.1 Vizualní interpretace výstupu klasifikace .....	53
4.2 Zhodnocení přesnosti klasifikace s využitím vektorové vrstvy .....	55
4.3 Ověření přenositelnosti klasifikační báze .....	59
<b>5. Diskuze .....</b>	<b>67</b>
<b>6. Závěr .....</b>	<b>71</b>



<b>Seznam zdrojů informací .....</b>	<b>73</b>
<b>Seznam příloh .....</b>	<b>79</b>

## **PŘEHLED POUŽITÝCH ZKRATEK**

**DEM** – *Digital Elevation Model*

**DMT** – *Digitální Model Terénu*

**DMR** – *Digitální Model Reliéfu*

**DN** – *Digital Number*

**DPZ** – *Dálkový Průzkum Země*

**GIS** – *Geographic Information System*

**IDW** – *Inverse Distance Weighted*

**LIDAR** – *Light Detection And Ranging*

**nDSM** – *Normalized Digital Surface Model*

**NDVI** – *Normalized Different Vegetation Index*

**NIR** – *Near InfraRed*

**NOAA** – *National Oceanic and Atmospheric Administration*

**OBIA** – *Object Based Image Analysis*

**RMSE** – *Root Mean Squared Error*

**VHR** – *Very High Resolution*

## SEZNAM OBRÁZKŮ A TABULEK

Tab. 1	Spektrální charakteristika senzoru Quickbird.....	18
Obr. 1	Chessboard segmentace .....	23
Obr. 2	Quadtree segmentace .....	24
Obr. 3	Multiměřítková segmentace.....	25
Obr. 4	Technologie LIDAR.....	30
Obr. 5	Modelové území Modletice.....	34
Obr. 6	Modelové území Jirny .....	35
Obr. 7	Vektorová vrstva Modletice.....	36
Obr. 8	Vektorová vrstva Jirny .....	37
Obr. 9	Pansharpening družicového snímku .....	38
Obr. 10	Chybová zpráva při načítání vrstev do software eCognition .....	39
Obr. 11	Tvorba pravidelné mřížky („Create fishnet“).....	40
Obr. 12	Nástroj „Spatial join“ .....	40
Obr. 13	Nástroj „Feature to point“ .....	41
Obr. 14	Nástroj „Topo to raster“ .....	41
Obr. 15	Výpočet nDSM .....	42
Obr. 16	Nástroj „Point to raster“.....	42
Obr. 17	Komerční zóna v modelovém území Modletice.....	43
Obr. 18	Komerční zóna v modelovém území Jirny .....	44
Obr. 19	Ukázka nastavení měřítkového parametru s hodnotami 25, 28, 35 .....	45
Obr. 20	Přehled klasifikovaných tříd.....	45
Obr. 21	Nastavení prahové hodnoty pro průměrnou hodnotu nDSM.....	46
Obr. 22	Nastavení prahové hodnoty NDVI .....	47
Obr. 23	Přiřazení neklasifikovaných segmentů do třídy povrch.....	48

Obr. 24	Rozsah hodnot příznaku Brightness .....	48
Obr. 25	Nastavení prahové hodnoty příznaku Ratio Green pro třídu „holá pole“ .....	49
Obr. 26	Rozsah hodnot příznaku Mean Blue.....	50
Obr. 27	Rozsah hodnot příznaku Cut Ratio Green .....	51
Obr. 28	Příznak Ratio Green s prahovou hodnotou $0,37 \leq \text{Ratio Green} \leq 0,4089$ .....	52
Obr. 29	Výsledek objektově orientované klasifikace v modelovém území Modletice .....	53
Obr. 30	Klasifikace heterogenní plochy.....	54
Obr. 31	Klasifikace budovy pouze na základě výšky .....	55
Obr. 32	Družicový snímek modelového území Modletice .....	57
Obr. 33	Hodnocení přesnosti klasifikace budov v modelovém území Modletice .....	57
Obr. 34	Hodnocení přesnosti klasifikace zpevněných povrchů v modelovém území Modletice.....	58
Obr. 35	Výsledek objektově orientované klasifikace v modelovém území Jirny .....	59-60
Obr. 36	Hodnocení přesnosti klasifikace budov v modelovém území Jirny.....	61
Obr. 37	Chybně klasifikované budovy v kontrolní vektorové vrstvě modelového území Jirny.....	61
Obr. 38	Hodnocení přesnosti klasifikace zpevněných povrchů v modelovém území Jirny ....	62
Obr. 39	Výsledek klasifikace s upravenou klasifikační bází pro modelové území Jirny .....	63
Obr. 40	Hodnocení přesnosti klasifikace zpevněných povrchů s upravenou klasifikační bází v modelovém území Jirny.....	64
Obr. 41	Chybějící mračno bodů ve výřezu Jirny.....	66

# 1. Úvod

S rozvojem a dostupností družicových snímků velmi vysokého rozlišení roste také jejich využití pro monitorování jevů souvisejících s městským a příměstským prostředím včetně zón komerční suburbanizace. Tradiční pixelové klasifikační algoritmy nedosahují v případě mapování komerční suburbanizace příliš dobré přesnosti. Tento problém vyplývá z prostorové a spektrální heterogenity suburbánních oblastí, které jsou směsicí většinou poměrně velkých pravoúhlých budov s různými materiály využitými na pokrytí střech, materiálově různorodými typy zpevněných povrchů (parkoviště, logistické areály apod.) a komunikací ať již místního významu, ale často také dálnic, které zajišťují rychlé napojení a snadnou dopravní dostupnost. V těchto zónách se samozřejmě také vyskytují různé typy vegetačního pokryvu (lesy, křoviny, louky a zemědělské oblasti), vodní plochy a holé půdy (různá stadia výstavby). Tradiční klasifikační přístupy jsou proto nahrazovány novými metodami klasifikace. Velký potenciál při mapování a klasifikaci komerční suburbanizace s využitím družicových snímků velmi vysokého prostorového rozlišení má objektivě orientovaný přístup, který kromě spektrálních příznaků využívá také prostorové, tvarové a další charakteristiky. Potenciál tohoto přístupu je ještě zvýšen v případě využití výškových dat pro extrakci budov.

Práce vychází z projektu Ministerstva životního prostředí ČR Suburbánní rozvoj, suburbanizace a urban sprawl v České republice: Omezení negativních důsledků na životní prostředí 2007 – 2011. Diplomová práce se zaměřuje na objektivě orientovanou klasifikaci komerční suburbanizace a navazuje na již zpracované studie v rámci projektu, které se věnovaly klasifikaci liniových prvků a rezidenční zástavby. Komerční suburbanizace patří mezi stěžejní procesy suburbánního rozvoje. Postupně se často nekontrolovaně rozšiřuje do venkovského osídlení a především do volné krajiny na úkor často velmi kvalitní zemědělské půdy. Tento nekoordinovaný rozvoj výstavby nákupních a komerčních areálů, průmyslových a dopravních staveb a jejich rozšiřování do okolní krajiny nazývaný urban sprawl představuje značnou hrozbu pro životní prostředí. (Oučedníček, 2007)

Hlavním cílem diplomové práce je vytvoření a použití metodického postupu pro extrakci budov a zpevněných ploch nacházejících se ve vybraných komerčních oblastech suburbánní zóny Prahy. Extrakce je provedena s využitím objektivě orientované klasifikace se zaměřením na rozlišení různých typů střech a zpevněných povrchů v závislosti na materiálních, tvarových či výškových vlastnostech. Přesnost navrženého postupu a získaných výsledků je porovnána s daty zpracovanými ruční vektorizací budov a zpevněných ploch. Ke zpracování jsou využity panchromatické a multispektrální družicové snímky velmi vysokého rozlišení ze senzoru Quickbird a dále data z leteckého laserového skenování. Pro tvorbu klasifikační báze byla zvolena komerční zóna lokality Modletice.

V práci je také hodnocena použitelnost navržené klasifikační báze a celého postupu pro extrakci budov a zpevněných ploch pro jiný snímek z družice QuickBird zachycující

komerční zónu v oblasti obce Jirny. Hypotézou bylo, že bez určitých úprav nebude klasifikační báze se stejnými výsledky použitelná pro jiný snímek. Dalším předpokladem bylo, že některé zpevněné povrchy mají velmi podobné spektrální chování jako holé/odkryté povrchy (např. holá zemědělská půda nebo staveniště) a nepodaří se je zcela rozlišit. Pro zpřesnění klasifikace byla využita výšková data z leteckého laserového skenování a z nich vytvořený nDSM (Normalized Digital Surface Model).

První část diplomové práce se věnuje vstupu do dané problematiky, literární rešerši a teoretickému popisu leteckého laserového skenování včetně popisu družicových systémů. Druhá část popisuje vytváření metodického postupu objektově orientované klasifikace včetně předzpracování dat (transformace, pansharpening a tvorba nDSM). V závěru je potom zhodnocena přesnost vytvořeného metodického postupu pro extrakci budov a zpevněných ploch v oblastech komerční suburbanizace.

## 2. Vstup do problematiky a literární rešerše

Využití družicových dat s velmi vysokým rozlišením v posledních letech značně vzrůstá a nacházejí uplatnění v mnoha oborech lidské činnosti. Jedním z těchto oborů jsou i urbanistické studie, zahrnující sledování urbanizačního a suburbanizačního procesu, plánování rezidenční či komerční výstavby, ale i monitorování zpevněných ploch a silnic, které souvisí s výše uvedenými pojmy. Existuje tedy mnoho odborných článků a studií zabývajících se využitím družicových dat velmi vysokého rozlišení pro extrakci budov a zpevněných ploch. Kromě toho se věnují i různým metodickým postupům s cílem najít ten nevhodnější dle požadavků uživatele na výsledek.

Slovo suburbanizace pochází z anglického slova suburb, které v překladu znamená předměstí. Pod tímto pojmem si můžeme představit přesun obyvatel či jejich aktivit, z centra města do zázemí. Tímto procesem dochází k rozšiřování území města. Kromě suburbanizace se v obcích v blízkosti větších měst odehrává i další suburbánní rozvoj – tedy procesy, aktivity a jejich změny, které se odehrávají v zázemí měst, nejsou ovšem primárně způsobeny a nesouvisí s odlivem lidí, kapitálu, daní nebo funkcí z jádrových měst. K nejviditelnějším projevům suburbánního rozvoje patří stavební aktivita či oživení ekonomických funkcí a společenských aktivit v příměstských obcích. Suburbanizace představuje jeden z procesů suburbánního rozvoje, jehož zdrojovou oblastí je jádrové město (Ouředníček, M.).

Suburbanizace souvisí s výstavbou nových domů a bytů, které lze poté označit jako satelitní městečka tzv. suburbia, dále nákupní a průmyslové zóny. Z výše uvedeného můžeme suburbia rozdělit do dvou skupin dle převládající funkce, a to na rezidenční (obytnou) suburbanizaci a komerční (pracovní a obslužnou) suburbanizaci.

První uvedená suburbanizace, rezidenční, je charakterizována především výstavbou nového bydlení v zázemí města a s tím je spojený postupný odliv obyvatel z centrální části města do nových rodinných a bytových domů do suburbia. Rezidenční suburbanizace má mnoho forem, které se liší podle rozsahu nové výstavby, charakteru bydlení, lokalizace zástavby, architektury a ceny domů.

Pro druhou suburbanizaci, komerční, jsou také typické a zřetelné projevy, zejména lokalizací ve výhodných místech podél hlavních dopravních tahů. Dochází k přesunu některých funkcí z centrálních částí měst do perifernějších oblastí nebo zcela mimo území města. Většina nových areálů komerční výstavby je budována na místech původních polí, na tzv. zelené louce (greenfield). Typickými funkcemi, které se od počátku 90. let stěhují z měst do jejich zázemí, jsou logistické areály, hypermarkety a další obchody, částečně i výroba a zábava (Ouředníček, M.).

Se suburbanizací je spojen i pojem Urban Sprawl, který je vlastně jistou formou suburbanizace. Urban Sprawl je však nežádoucí z ekonomického, sociálního a environmentálního pohledu. Lze si jej představit jako rozšiřování zástavby do volné krajiny, přičemž je tento proces neřízený a nepromyšlený při umisťování rezidenčních či komerčních objektů do krajiny. Výsledkem je většinou mozaiková struktura nově rozvíjených oblastí v zázemí města. Zdrojem rozvoje je především cíl investorů či vlastníků pozemků dosáhnout maximálního zisku. Dopady pro společnost, ale i krajinu jsou však natolik rozsáhlé a nákladné, že je nutné urban sprawl účinně potlačovat (Ouředníček, M.).

## **2.1. Družicová data**

V posledních desítkách let vzrostl význam dálkového průzkumu Země s využitím družicových systémů pro monitorování v oblasti hospodářství, přírodních katastrof mapování území v mnohých dalších oborech využívajících geografické informace. To vše hlavně díky rychlému technologickému vývoji v oblasti DPZ, což dokazuje vzrůstající počet komerčních družic, který se v dnešní době pohybuje v řádu desítek a neustále se zvyšuje. Družicové snímky umožňují zmapovat aktuálně a přesně rozsáhlé území během krátké doby. A zároveň se družicová data dostanou ke svým uživatelům řádově v hodinách, maximálně během pár dní. S postupem času došlo k velkému posunu u prostorového rozlišení družicových dat, která je dnes možné získat s prostorovým rozlišením menším než 1 m. Kromě klasických družicových snímků lze získat i specifická data, kterými jsou například hyperspektrální či radarové snímky. Archivace probíhá pro veškerá data a je možné je kombinovat i s aktuálními daty pro různé vývojové studie či sledování změn.

### ***Družicová data malého a středního prostorového rozlišení***

Prostorové rozlišení u družicových senzorů s malým rozlišením se pohybuje v řádu 1 km a pro senzory se středním rozlišením v řádu 100 m. Data jsou pořizována v intervalu jednoho až několik dní, a to pouze v multispektrálním režimu (3 spektrální pásma ve viditelném záření a jedno pásmo v oblasti infračerveného záření). Takovéto snímky jsou vhodné pro mapování v měřítku 1:1 000 000. Využití nacházejí i pro globální a kontinentální mapování, sledování stavu a vývoje vegetace, sněhové pokrývky, atmosféry a oceánů či monitorování rozsáhlých přírodních katastrof. Do této kategorie patří například Meteosat, Goes, NOAA, OrbView 2, Modis, Meris atd.



### ***Družicová data vysokého prostorového rozlišení***

Mezi družicové systémy pořizující data vysokého rozlišení patří Landsat 5, Landsat 7, SPOT, Terra, Aqua a další. Prostorové rozlišení takovýchto dat se pohybuje mezi 5 až 30 m. Velmi často jsou data pořizována jak v panchromatickém, tak multispektrálním režimu v intervalu zhruba několika dní. Uplatnění nacházejí pro mapování v měřítku 1:100 000 až 1:25 000, dále pro regionální mapování, geologické mapy, sledování lesní těžby, sledování stavu a vývoje vegetace, tvorbu DMT, monitorování rozvoje měst.

### ***Družicová data velmi vysokého prostorového rozlišení***

Charakteristickou vlastností těchto dat je prostorové rozlišení v řádu jednotek metrů. Družicové senzory pořizují data v panchromatickém a multispektrálním režimu. Je možné využít metody tzv. pan – sharpeningu a provést kombinaci panchromatického a multispektrálního režimu. Výsledkem je poté multispektrální snímek s vysokým rozlišením, které je převzato ze snímků panchromatických. VHR družice snímají zpravidla ve čtyřech spektrálních pásmech, tři ve viditelné části spektra (modré, zelené a červené) a jedno pásmo v oblasti infračerveného záření. Kromě běžné barevné syntézy (červená – zelená – modrá), je možné díky blízkému infračervenému pásmu (NIR) provést syntézu v nepravých barvách (NIR – červená – zelená). Syntéza v nepravých barvách nachází značné uplatnění v ekologii, kde umožňuje snadnější vymezení vegetace od povrchů bez vegetace, ale i odlišení různých druhů vegetace a monitorování aktuálního stavu.

Družice pořizující data velmi vysokého rozlišení mají tu výhodu, že se vrací na stejné místo zemského povrchu v intervalu 1 – 3 dní a lze je získat z prakticky jakéhokoliv území. Využití nachází v podrobném mapování, při tvorbě 3D modelů, urbanistických studií, precizním zemědělství, mapování dopravních sítí atd. Díky vysokému prostorovému rozlišení je možné mapovat i detaily, jako osobní automobily, lodě, budovy a umožňují rozlišit i různé druhy zástavby. Data lze využít pro plánování výstavby či různé urbanistické studie. Do této kategorie patří následující družice – Ikonos, OrbView, Formosat, GeoEye, QuickBird a další.

### ***Družice QuickBird***

Z vojenské základny Vanderberg Air Force Base v Kalifornii odstartovala dne 18.10. 2001 raketa Delta II, která vynesla na oběžnou dráhu do výšky 450 km senzor velmi vysokého rozlišení s názvem QuickBird. Tento družicový senzor postavily společně firmy Ball Aerospace and Technologies Corp., Kodak a Folker Space. Družice je provozována společností DigitalGlobe (dříve EarthWatch, sídlící v Coloradu v USA). Družice QuickBird se pohybuje rychlostí 25 560 km/h a doba oběhu je 94 minut. Charakteristickým znakem je schopnost

družice natáčet se jak v rovině letu, tak i napříč dráhy o úhel až 25°. Na zemském povrchu lze tedy snímat pás o šířce až 544 km a pořizovat stereoskopické scény ve směru letu. Překryv základní stereodvojice je 90%. Družice disponuje dvěma senzory, panchromatickým a multispektrálním. První z nich poskytuje černobílé snímky s prostorovým rozlišením 61 cm v nadiru až 72 cm (v závislosti na míře vychýlení senzoru). Senzor pořizující multispektrální snímky snímá zemský povrch s menším prostorovým rozlišením 244 cm, v nadiru až 288 cm, ale ve čtyřech spektrálních pásmech (modré, zelené, červené a blízké infračervené). Jako u ostatních dat velmi vysokého rozlišení je možné snímky kombinovat pomocí pansharpeningu. Velikost scény je zhruba 16,5 x 16,5 km a polohová přesnost dat je 14 m RMSE.

	spektrální pásmo	spektrální rozsah (nm)	prostorové rozlišení (m)
<i>panchromatický senzor</i>	černobílé	445 – 900	0,6
<i>multispektrální senzor</i>	modré	450 – 520	2,4
<i>multispektrální senzor</i>	zelené	520 – 600	2,4
<i>multispektrální senzor</i>	červené	630 – 690	2,4
<i>multispektrální senzor</i>	blízké infračervené	760 - 900	2,4

*Tabulka 1: Spektrální charakteristika senzoru Quickbird*

*Zdroj: šetření autora*

## 2.2. Využití VHR dat pro mapování suburbanizace

Jak již bylo uvedeno výše, VHR data slouží v tomto konkrétním případě k monitorování stavu, změn a vývoje urbanizace na zvoleném území. Berková (2009) ve své práci využívá VHR dat a objektivě orientované klasifikace pro sledování změn ve využití území, konkrétně změnám týkajících se urbanizace území, kde výsledky mají sloužit k dalšímu studiu širších vztahů mezi konstrukcí a jejím okolím z hlediska udržitelného rozvoje. Frauman, Wolf (2005) vyzdvihují velký potenciál VHR dat pro extrakci informací z městských oblastí. Binard a kol. (2005) ve své studii uvádějí, že VHR data jsou bohatým zdrojem užitečných informací pro urbanisty či managery v daném oboru. Možných aplikací je mnoho a patří mezi ně například inventarizace zastavěných parcel v regionálním měřítku, mapování zpevněných povrchů, mapování a hodnocení městské zeleně, identifikaci městských morfologických komplexů, stanovení hustoty zástavby a množství otevřených prostor ve městě pro srovnávací městské studie.

Využití družicových dat velmi vysokého rozlišení z družice QuickBird pro městské a zastavěné oblasti se věnují ve svém článku autoři Volpe, Ross (2003), kde popisují, že vzhledem k vysokému rozlišení a široké oblasti, která může být zachycena v rámci jedné scény, se zdají být družicová data pořizovaná satelitem QuickBird vhodným zdrojem informací pro celou škálu aplikací souvisejících s městskou zástavbou. Na základě toho bylo provedeno několik

pilotních projektů se zaměřením na městské oblasti. Mezi hlavní témata těchto projektů patří vytváření a aktualizace map, kdy prostředí města a zejména jeho okolí se rychle rozvíjí a roste, a proto je vyžadována častá aktualizace map. Velká geometrická přesnost, získaná ortorektifikací dat, umožňuje aktualizaci především se silnicemi a budovami a tematických map v měřítku 1:10 000 a 1:5 000. Další projekt se věnuje extrakci a aktualizaci silniční sítě. Byla analyzována možnost extrakce silniční sítě a některých souvisejících atributů. Bylo dosaženo vysokého procenta při detekci, společně s velmi dobrými výsledky při extrakci objektů jako šířka cesty, silniční značky, stromy podél cest a další. Dále lze využít multispektrální pásma v pravých i nepravých barvách pro generaci přesných map pro land use s podrobnou legendou při velkém měřítku. V jiném projektu se podařilo ze snímků pořízených v dopoledních hodinách analyzovat plynulost silničního provozu z hlediska hustoty a hlavních směrů.

Dalšími autory, kteří se dané problematice věnují, jsou Aldred, Wang (2007). Uvádějí, že rozsáhlé mapování městské zástavby poskytuje potřebné informace pro městské plánování, monitoring a management životního prostředí a pro studie mikroměřítkového klimatu. Nicméně použití těchto map na výše uvedené problémy bylo omezeno nedostatkem rutinních a automatických či polo – automatických metod, aby poskytly dostatečně přesný a detailní popis složitého a heterogenního městského prostředí z dostupných snímků velmi vysokého rozlišení jako je Ikonos a Quickbird.

Dle autorů Hermosillat, Ruiz, Reico, Estornell (2011) jsou vývoj a dynamika krajiny a land use patrně zejména v městském a příměstském prostředí vzhledem k budování nových infrastruktur, domů a budov. Údržba městských kartografických databází vyžaduje spolehlivou a systematickou metodologii pro detekci staveb. Tradičně byl tento konkrétní úkol řešen s pomocí fotointerpretace, což je drahé a časově náročné. Velké množství multispektrálních snímků s vysokým rozlišením a zvyšující se dostupnost dat Lidar ovlivnil kombinaci těchto dvou zdrojů dat a vývoj metod digitálního zpracování obrazu pro automatickou detekci a vymezení budov. Techniky detekce budov mohou být zařazeny do tří skupin v závislosti na zdroji dat: (i) s použitím leteckých nebo satelitních snímků, (ii) s použitím trojrozměrných informací, (iii) s kombinací obou zdrojů dat. Jejich cílem je vymezení městských, průmyslových a suburbánních staveb. Klíčovým faktorem při detekci budov je jejich typ. Městské a průmyslové oblasti vykazují lepší přesnost při detekci budov než suburbánní oblasti, a to vzhledem k malé velikosti předměstských staveb v kombinaci s výraznější přítomností stromů v předměstských oblastech, což způsobuje obtížnější detekci budov. Od té doby, co jsou budovy seskupené ve vysoce hustých městských nebo průmyslových oblastech, mají obvykle pravidelné vzory a směry. Automatická detekce budov s využitím snímků vysokého rozlišení sebou přináší problémy z hlediska geometrie. Budovy představují složité struktury, které vytváří náhlé výškové diskontinuity, stíny atd. Z hlediska radiometrie mohou různé kombinace materiálů vytvořit různé hodnoty intenzity spektrálních pásem.

Zeng, Zhang, Wang a Lin (2002) popisují město jako důležité místo nejen pro život lidí, ale také jako centrum ekonomického a sociálního rozvoje. Klasifikace land use v městském prostředí s využitím multispektrálních satelitních snímků vysokého rozlišení hraje klíčovou roli při mapování městských oblastí, územním plánování a řízení, založení a revizi GIS databáze, monitorování životního prostředí a přírodních katastrof a při založení telekomunikačních sítí.

### **2.3. Přístupy ke klasifikace VHR dat**

Pro extrakci budov či zpevněných ploch z VHR dat je možné využít více přístupů. Některé články se zabývají pouze jednou z metod, jiné naopak porovnávají metody mezi sebou. První přístup je založen na pixelové klasifikaci (per - pixel classification, pixel – based analysis, pixel by pixel classification), kde je klasifikace realizována na základě spektrálních příznaků. V tomto případě klasifikace probíhá pouze na základě hodnot jednotlivých pixelů, nikoliv však jejich okolí. Například Frauman, Wolf (2005) uvádějí, že tato metoda s sebou nese jisté nevýhody. Hlavní nevýhodou při aplikaci pro urbanizované území je to, že často produkuje tematické mapy postrádající prostorovou spojitost, a to v důsledku spektrální heterogenity a prostorovému rozptylu ve snímku.

Studie Yuan a Bauer (2006) zkoumá digitální extrakci land use, zejména klasifikační techniky pro zpevněné městské povrchy s využitím dat Quickbird. Studují a porovnávají dvě metody a to objektově orientovaný přístup a klasifikaci per – pixel. Zatímco tradiční metody klasifikace per – pixel jsou založeny na spektrální – radiometrické informaci jednotlivých pixelů, objektově orientovaný přístup poskytuje v procesu klasifikace jedinečné možnosti začlenění texturálních a kontextových informací ve velkém měřítku stejně jako četné objektově založené rysy. Nicméně, některé studie ukazují značně rozporuplné výsledky. Určité studie zjistily významně vyšší přesnosti u objektově – orientovaného přístupu (Benz et. al., 2003; Schwarz et. al., 2000, Wang et. al., 2004), zatímco jiné studie uvádějí pro oba přístupy podobné výsledky se srovnatelnou přesností.

#### **2.3.1. Pixelová klasifikace**

Jednou z metod klasifikace obrazových dat je přístup per – pixel, představující jednu z historicky dřívějších metod. Mezi zástupce algoritmů řízené klasifikace patří Maximum Likelihood (klasifikátor maximální pravděpodobnosti), Parallelepiped (Rovnoběžnostěnový klasifikátor) nebo Nearest Neighbour. U těchto metod má uživatel možnost ovlivnit výsledek pomocí výběru vhodných vzorků tréninkových množin. Na základě těchto tréninkových množin dochází k zařazení jednotlivých pixelů do předem definovaných tříd. Klasifikátor

Maximum Likelihood je založen na předpokladu, že rozdělení bodů tvořících třídu tréninkových dat má Gaussovo normální rozložení. V rozptylogramu jsou vytvářeny elipsy pro stejné pravděpodobnosti. Pro klasifikátor Parallelepiped je charakteristická citlivost na rozsahy změn. Přičemž rozsahy jsou dány rovnoběžnostěny. Pixel je zařazen dle své hodnoty do odpovídajícího rovnoběžnostěny. Tento klasifikátor je rychlý a početně velmi účinný. Problémy však mohou nastat v případě, že se rovnoběžnostěny překrývají. (Repaka et. al. 2004)

Do kategorie algoritmů neřízené klasifikace patří ISODATA, K – means clustering či Fuzzy K – means clustering. Princip neřízené klasifikace spočívá ve shlukové analýze, kdy jsou pixely příznakového prostoru statisticky rozděleny do shluků. Předpokladem je, že pixely odpovídající stejnému povrchu jsou ve vícerozměrném prostoru blízko sebe a naopak pixely patřící k odlišným kategoriím povrchu jsou od sebe vzdáleny. Dochází ke spojování pixelů v obrazu do skupin s podobnými spektrálními vlastnostmi v jednotlivých pásmech. Uživatel na základě podkladů (mapy, znalost terénu, letecké foto) nakonec interpretuje výsledek získaných shluků do klasifikačních tříd, které sám definoval. Výhodou je rychlost vyhodnocení. Nejjednodušším klasifikátorem je algoritmus K – means. Při jeho aplikaci jsou jako vstupní parametry zadány počty shluků a parametr shlukování jako je počet iterací atd. Jsou vypočteny středy shluků a jednotlivé pixely jsou přiřazeny ke shlukům, ke kterým mají nejkratší (minimální) vzdálenost. Využití tohoto algoritmu je výpočetně náročné, a proto je vhodná aplikace na části obrazu. Dalším výše zmíněným klasifikátorem je ISODATA. Jedná se o rozšířený algoritmus K – means, který umožňuje měnit clustry v průběhu iterací a to následovně: clustry, které se stanou heterogenní se rozpadnou; clustry, které jsou blízko sebe se sloučí; clustry s malým počtem pixelů se rozpustí do ostatních. (Repaka et. al. 2004)

Výše uvedené klasifikační metody pracují pouze s příznakovým prostorem a nezahrnují do procesu klasifikace kontextuální či jiné informace.

Dle Aldred, Wang (2007) podrobné mapování střech v městském prostředí vyžaduje data velmi vysokého rozlišení. Nicméně tradiční pixelové klasifikátory založené na spektrálních třídách jsou neúčinné pro multispektrální snímky s velmi vysokým rozlišením, a to v důsledku velkých spektrálních rozdílů uvnitř třídy a spektrálními změnami mezi třídami, které charakterizují člověkem vytvořené objekty.

Seyds, Dare, Jones (2005) se ve své studii věnují automatické klasifikaci land coveru s využitím snímků vysokého rozlišení a dat z Lidaru a porovnávají objektivě orientovaný přístup s pixelovou klasifikací maximum likelihood. Uvádějí, že použití tradičních automatických klasifikačních systémů založených na spektrálních hodnotách pixelů vykazuje velmi neuspokojivé výsledky při aplikaci na snímky s vysokým rozlišením. V závěru proto upřednostňují objektivě orientovanou klasifikaci před pixelovou klasifikací.

Další autoři, kteří se danému tématu věnují jsou Marangoz a kol. (2010) a uvádějí, že klasifikace spoléhající na pixelově založené přístupy přináší v současnosti omezené výsledky. Typicky mají potíže týkající se značného informačního obsahu dat velmi vysokého rozlišení, kterými jsou například snímky z družice Ikonos. Produkují nekonzistentní výsledky klasifikace a jsou daleko za očekáváním při extrakci objektů zájmu.

### **2.3.2. Objektově orientovaná klasifikace**

Celkově lze říci, že objektově založené klasifikační techniky jsou novým a inovačním přístupem, zvláště pak pro aplikace pracující s prvky vytvořenými člověkem. V oblasti dálkového průzkumu městských oblastí existuje několik aplikací, které prokazují, že objektově orientované přístupy jsou lepší než pixelové analýzy, zejména pro oddělení silnic, letišť či městské zástavby. V porovnání s přírodním prostředím je městské prostředí charakterizováno ostrými a diskrétními hranicemi a vysokou frekvenční změnou různých povrchů s podobnými odrazivými vlastnostmi. Antropogenní prvky lze lépe reprodukovat na základě objektově orientovaného přístupu a to přes opakovaný proces segmentace. Například stíny mohou být charakterizovány speciálním vztahem se sousedními objekty a tvar objektu může pomoci při rozlišení mezi střechou a cestou, které mají stejné odrazivé vlastnosti. V souhrnu, objektově orientovaná analýza obrazu kombinuje funkčnost GIS a technik dálkového průzkumu země tím, že pracuje s polygony, homogenními shluky místo s jednotlivými pixely.

Objektově orientovaná analýza obrazu (OBIA) umožňuje zahrnout do postupu zpracování i například kontextuální a další informace. Snahou této metody je imitace vizuální interpretace snímků člověkem. Principem je, že člověk při vizuální interpretaci snímku nevyhodnocuje jednotlivé pixely, ale postupně zaostřuje oko na homogenní celky snímku a podle spektrálních, tvarových, velikostních, kontextuálních, texturálních a dalších informací rozpoznává jednotlivé objekty. Aby bylo možné dosáhnout tohoto cíle pomocí softwarového řešení, je zapotřebí snímek rozdělit do homogenních oblastí reprezentujících objekty reality a pak aplikovat klasifikační model ([www.gisat.cz](http://www.gisat.cz))

#### **2.3.2.1. Segmentace**

Jak bylo uvedeno výše, prvním a klíčovým krokem objektově orientované klasifikace snímku je segmentace, jejímž cílem je získat smysluplné objekty ze snímku založeném na jejich spektrálních a texturálních charakteristikách (např. ulice, domy, vegetace atd.). Sousední pixely s podobnými hodnotami odrazivosti jsou seskupeny do segmentů omezených velikostí a tvarem. Jakýkoliv druh segmentace zahrnuje určitou úroveň zobecnění. Segmentace může být provedena pro více vložených úrovní např. nižší úroveň obrazových objektů je seskupena znovu a znovu, což pomáhá reprezentovat informace o obraze na různých úrovních homogenity a také váhy. Existuje několik druhů segmentace a to v závislosti na přístupu

k segmentaci homogenity. Jako příklad lze uvést Local Contrast Segmentation, Watershed Segmentation či Texture Segmentation. (eCognition User Guide, 2009)

Software eCognition 8.0 nabízí celou řadu segmentací, které dělí do dvou skupin podle přístupu ke klasifikaci snímku. První skupina algoritmů „Top – down“ tak zvaně dělí něco velkého na malé části. Naopak druhá skupina algoritmů „Bottom – up“ spojuje malé části, aby vzniklo něco velkého (eCognition User Guide 2009)

Mezi segmentační algoritmy skupiny „Top – down“ patří následující:

- Chessboard segmentation
- Quadtree – Based segmentation
- Contrast filter segmentation
- Contrast split segmentation


Mezi segmentační algoritmy skupiny „Bottom – up“ patří následující:

- Multiresolution segmentation
- Multi - threshold segmentation
- Spectral difference segmentation

V následujících podkapitolách byly detailněji popsány nejdůležitější segmentační algoritmy.

### ***Chessboard segmentation***

Chessboard segmentation představuje jeden z nejjednodušších segmentačních algoritmů, který dělí scénu do komplikovanější sady pravidel – přiřazení obrazových objektů do stejných čtverců s danou velikostí. Jelikož tento algoritmus produkuje jednoduché čtvercové objekty, je často využíván pro rozdělení obrazu a obrazových objektů, například pro očištění malých obrazových objektů, kdy relativně malé obrazové objekty již byly identifikovány, mohou být dále segmentovány s použitím malého čtvercového parametru (square – size parameter) pro získání podrobnější analýzy.




***Obrázek 1: Chessboard segmentace***

***Zdroj: Definiens (2009)***

## ***Quadtree segmentation***

Quadtree segmentation je podobná předchozímu klasifikačnímu přístupu a opět dělí obraz do čtverců, ale v tomto případě mají různou velikost. Je možné definovat horní hranici barevných rozdílů v rámci každého čtverce pomocí „Scale parametr“. Po vytvoření čtvercové sítě pokračuje algoritmus následujícím způsobem. V případě, že není splněno kritérium homogenity, dochází k dalšímu rozdělení čtverce na další 4 menší čtverce. Například pokud maximální barevný rozdíl uvnitř čtverce je větší než definovaná váhová hodnota. Tento proces se opakuje do té doby, dokud není splněno kritérium homogenity pro každý čtverec.

U Quadtree segmentace obvykle velmi homogenní oblasti produkují větší čtverce než heterogenní oblasti. V porovnání s multiresolution segmentation je tento segmentační algoritmus méně náročný na zdroje.



***Obrázek 2: Quadtree segmentace***

***Zdroj: Definiens (2009)***

## ***Multiresolution segmentation***

Proto jednou z nejčastěji aplikovaných segmentací je Multiresolution Segmentation – Region Growing Segmentation. Multiresolution segmentation patří do přístupů, které postupují zespodu – nahoru (Bottom – up). Jedná se o semi-automatický proces, kdy uživatel definuje specifické parametry, které ovlivňují velikost a tvar výsledných segmentů v obraze. Výsledné objekty jsou přiřazeny nejen podle spektrálních charakteristik, ale i podle tvaru, texturálních parametrů, kontextuálních informací či vztahu k sousedním objektům. Pomocí tohoto algoritmu je možné získat homogenní objekty v několika segmentačních úrovních vycházející z pixelové úrovně, přičemž jednotlivé úrovně jsou charakterizovány velikostí segmentu. Segmentační technika u „*Region growing algorithm*“ začíná v každém bodě obrazu s jedním pixelovým objektem a slučuje tyto objekty v obraze do větších.

Významným kritériem segmentace je velikost objektů („scale parameter“ – průměrná velikost objektů) a jeho výběr závisí na účelu klasifikace. Kromě toho musí být nastaveny hodnoty pro barvu („color“ – průměrná spektrální hodnota), tvar („shape“ – geometrická forma objektů), kompaktnost („compactness“) a hladkost („smoothness“). Zatímco „scale parameter“ určuje průměrnou velikost generovaných objektů, „color“ a „shape“ vyjadřují příslušná kritéria



homogenity, která jsou aplikována. Je vytvořena hierarchická síť objektů, která umožňuje současnou reprezentaci obrazových informací v různých rozlišeních.

Tato kritéria jsou spojena do jednoho parametru definovaného jako heterogenita segmentů. Rovnováha, ve které jsou tato kritéria použita, závisí na požadovaném výstupu. Následující rovnice obsahuje tyto proměnné: kde  $f$  je kritérium heterogenity, jinak také nazývané „scale factor“. Dále  $w$  je uživatelem definovaná váha pro barvu, zde platí že  $0 = w = 1$ . Kritérium barvy odpovídá  $h_{colour}$  a kritérium tvaru je označeno  $h_{shape}$ .


$$f = w * h_{color} + (1 - w) * h_{shape}$$

Další rovnice se vztahuje ke kritériu tvaru, které se skládá ze dvou parametrů a to kompaktnost a hladkost. Musejí být spojeny s použitím uživatelem definované váhy pro kompaktnost, kde platí  $0 = w_{cmt} = 1$ .

$$h_{Smooth} = n_{Merge} * \frac{l_{Merge}}{b_{Merge}} - \left( n_{Obj1} * \frac{l_{Obj1}}{b_{Obj1}} + n_{Obj2} * \frac{l_{Obj2}}{b_{Obj2}} \right)$$

$$h_{Cmpt} = n_{Merge} * \frac{l_{Merge}}{\sqrt{n_{Merge}}} - \left( n_{Obj1} * \frac{l_{Obj1}}{\sqrt{n_{Obj1}}} + n_{Obj2} * \frac{l_{Obj2}}{\sqrt{n_{Obj2}}} \right)$$

Ve výše uvedených rovnicích pro výpočet kritérií kompaktnosti a hladkosti jsou uvedeny následující proměnné, kde  $n$  je velikost objektu,  $l$  představuje obvod objektu a  $b$  je bounding box. Pokud nejmenší nárůst přesáhne toleranci heterogenity definovanou uživatelem, proces se zastaví.



**Obrázek 3: Multiměřítková segmentace**

*Zdroj: Definiens (2009)*

### 2.3.2.2. Klasifikace

Klasifikace je postup, který sdružuje obrazové objekty do odpovídajících tříd. Třídy popisují sémantický význam objektů. Třídy mohou být seskupeny hierarchicky, takže může být popis třídy z rodičovské třídy na dceřinou třídu. Třídy tvoří strukturovanou sub – síť nazývanou hierarchie tříd (Class Hierarchy). Třídy mohou být spojeny pomocí dědičnosti, aby zdědily popis třídy nebo odkazy na skupiny, které spojují různé třídy dohromady do skupin tříd. Popisy tříd jsou vytvořeny pomocí systému založeném na fuzzy logice.

Program eCognition nabízí několik různých možností klasifikace obrazových objektů. Je možné klasifikovat každou třídu zvlášť s využitím postupů, nebo je případně možné klasifikovat všechny třídy současně podle hierarchie tříd. Kromě toho Definiens nabízí snadný klasifikační nástroj zvaný „Nearest Neighbour Classification“.

Při klasifikaci každé třídy samostatně pomocí procesů je možné využít podmínky v případě, že lze zařadit objekt v obraze do třídy na základě jednoho příznaku. Klasifikační algoritmy jsou mnohem složitější klasifikátory, které řeší některé klasifikační úlohy, jako je třeba hledání lokálních extrémů. Popisy tříd (Class Description) jsou používány, pokud jsou k přiřazení obrazových objektů do třídy nutné různé podmínky (multiple conditions) nebo funkce příslušnosti (membership function). Funkce členství mohou být použity v popisu tříd, aby charakterizovaly fuzzy přechody mezi třídami. Je doporučeno využívat popisy tříd pro definování typických charakteristik obrazových objektů.

Pokud využíváme Nearest Neighbour Classification, je vhodné si nasbírat vzorky (samples) pro jednotlivé třídy. V procesním stromu (process tree) lze volně kombinovat různé přístupy, což umožňuje maximální flexibilitu při klasifikaci. Aby bylo možné definovat přístup nebo kombinaci přístupů vhodných ke klasifikaci, nabízí program několik nástrojů. (eCognition User Guide, 2009)

Darwish, Leukert, Reinhardt (2003) se ve své studii zabývají hledáním optimálních parametrů pro extrakci různých tříd krajinného pokryvu s využitím segmentačního přístupu (multimeřítková segmentace), testováním možnosti využití jedné segmentace pro úspěšné extrahování všech sledovaných tříd krajinného pokryvu a dále testováním použitelnosti segmentačního přístupu pro různé datové typy. Uvádějí, že základním principem koncepce klasifikace je využití důležitých informací (tvar, textura, kontextové informace), které jsou prezentovány prostřednictvím obrazových objektů se stejným významem. K získání těchto obrazových objektů je využita objektově orientovaná klasifikace, která začíná segmentací celého obrazu. V softwaru eCognition znají výsledné obrazové objekty jejich sousedy a jsou později klasifikovány. Proces klasifikace je řízen klasifikační bází, která popisuje vlastnosti výsledných tříd objektů ( ve formě fuzzy funkcí příslušnosti ke třídě).

Jiná studie autorů Harayama, Jaquet (2004) uvádí, že na základě toho, že tradiční pixelově založené klasifikační přístupy nejsou vhodné pro snímky velmi vysokého rozlišení, se

rozhodli využít objektově orientovaný přístup pro klasifikaci land cover včetně využití digitálního výškového modelu. Podrobně popisují dva hlavní kroky objektově orientované klasifikace. Nejprve se věnují segmentaci, v jejímž procesu dochází k rozdělení celého snímku a jsou generovány obrazové objekty na základě nastavených kritérií homogenity a nehomogenity pro barvu a tvar. Uvádějí, že je důležité během segmentace experimentovat se změnou hodnot váhy pro barvu a tvar, dokud nejsou nalezeny parametry, které se nejlépe hodí pro daný snímek. Například při použití vah 0,9 pro barvu a 0,1 pro tvar dojde k „pře“ – segmentování obrazu, což znamená, že vznikne příliš mnoho malých segmentů. A to z důvodu, že je algoritmus příliš citlivý na malé rozdíly v barvě. Naopak, pokud je dána maximální váha pro tvar a minimální váha pro barvu získáme „pod“ – segmentované kompaktní ale nesmyslné segmenty. Optimální výsledek lze získat v případě, že jsou použity podobné váhy pro tvar a barvu. Dále se věnují klasifikaci obrazu, která je založena na fuzzy logice. Ta využívá nejen atributy obrazových objektů, ale také vztahy mezi sítí obrazových objektů, což má za následek sofistikovanou klasifikaci zohledňující lokální souvislosti. Při zpracování využívají také digitální výškový model pro odlišení objektů dle jejich výšky. Například, i přestože spektrální informace stromů a travního porostu je podobná, mohou být od sebe snadno rozlišeny pomocí hodnot z digitálního výškového modelu (ten autoři získali jako rozdíl digitálního modelu povrchu a digitálního modelu terénu). Stejný přístup může být použit pro klasifikaci budov vs. silnic.

Xiaoxia, Jixian, Zhengjunil (2004) se ve svém článku věnují metodě objektově orientované klasifikace družicových dat velmi vysokého prostorového rozlišení. Popisují, že s rozvojem satelitních technologií vznikají družicová data velmi vysokého rozlišení, jejichž metrické vlastnosti jsou přijatelné pro mapování land use ve velkém měřítku. Tradiční řízené a neřízené klasifikace jsou založeny na hodnotách šedi pixelů samotných, tedy pro klasifikaci jsou použity pouze spektrální údaje. Takový výsledek je nepříjemný při klasifikaci VHR snímků. Pro vyřešení tohoto problému byla navržena objektově orientovaná klasifikace s využitím metody segmentace obrazu a fuzzy klasifikace na základě výsledků segmentace. V této metodě již nejsou jednotkami zpracování jednotlivé pixely, ale obrazové objekty. Nejprve je potřeba segmentovat celý snímek do skupin pixelů dle významu, tedy do segmentů. Dále by měla být definována sada klasifikačních pravidel. Tato pravidla zahrnují spektrální, prostorové, kontextové a textové informace. Poté je vybrán klasifikátor, který přiřadí každý segment ke správné třídě podle klasifikačních pravidel. V porovnání s běžnými pixelově založenými klasifikačními přístupy využívající spektrální odezvy, obsahují obrazové objekty další informace jako texturu objektu, tvar, vztahy k sousedním objektům. Tento přístup může oprávněně uspokojit široké spektrum mapování a šetření land use. Dle autorů obecně platí, že proces objektově orientované klasifikace může být rozdělen do dvou hlavních kroků: multiměřítková segmentace a fuzzy klasifikace výsledných obrazových objektů. Segmentace představuje seskupení sousedních pixelů do regionů nebo segmentů založeném na podobných kritériích jako jsou měřítko, barva a forma. Multiměřítková segmentace je první a důležitý postup v softwaru eCognition, který umožňuje extrahovat homogenní obrazové objekty

v libovolném rozlišení, zejména s ohledem na lokální kontrasty. Výsledkem segmentace jsou obrazové objekty, které mohou být v dalším kroku klasifikovány. Pro klasifikaci zvolili autoři metodu členských funkcí, které jsou založené na fuzzy logice. Uvádějí, že fuzzy logika je matematický přístup ke kvantifikaci znalostí a výroků. Členské funkce umožňují formulaci znalostí a konceptů a jsou snadno přizpůsobitelné.

Článek autorů Marangoz, Oruc, Buyuksalih (2010) se také věnuje objektově orientované analýze snímku pro extrakci silnic a budov ze zaostřených snímků IKONOS. Vzhledem k možnostem klasických klasifikačních metod (klasifikace per pixel) se autoři rozhodli pro objektově orientovanou analýzu obrazu. Takový algoritmus vyžaduje jednu nebo více segmentací obrazu, které by měly být navíc podporovány kontextovými informacemi pro zlepšení procesu klasifikace. Objektově orientovaný přístup bere v potaz spektrální informace, formu a texturu. Jeho klasifikační fáze začíná rozhodujícím prvním krokem, a to seskupením sousedních pixelů do objektů se stejným významem, které jsou řešeny v pozdější fázi klasifikace. Touto metodou nejsou klasifikovány jednotlivé pixely, ale homogenní obrazové objekty, které byly extrahovány během předchozího kroku segmentace. Některými uživateli (Hofmann, 2001) bylo s určitým stupněm úspěchu studováno automatické rozpoznání a segmentace běžných objektů jako jsou budovy a domy ze snímků velmi vysokého prostorového rozlišení, např. Ikonos, QuickBird.

V poslední době se stala častěji využívaným přístupem objektově orientovaná klasifikace (tzv. OBIA – Object Based Image Analysis). Kupková, Potůčková, Kopalová, Kolář (2010) využívají klasifikační metodu OBIA pro detekci urbanizovaného území ze satelitních snímků QuickBird. Jejich cílem bylo vytvoření klasifikačního algoritmu, který umožní extrahovat budovy z VHR dat a zároveň bude možné tento klasifikační algoritmus použít i pro jinou lokalitu stejného snímku. Výsledek ukázal, že je možné využít stejné klasifikační pravidlo pro jinou lokalitu stejného snímku s podobnou geografickou charakteristikou jakou má lokalita, pro kterou bylo klasifikační pravidlo vytvořeno. Nelze ho však se stejnou úspěšností využít pro jiný snímek, kde je velký podíl suburbánních oblastí s velkým podílem komerční suburbanizace.

Studie autorů Herold, Guenther, Clarke (2003) zabývající se mapováním městské oblasti jižního pobřeží Santa Barbary s využitím dat z družice Ikonos a programu eCognition, označují přístup objektově orientované analýzy obrazu jako jednu z možností pro analýzu dat ze senzorů velmi vysokého prostorového rozlišení, které zobrazují městské oblasti zahrnující objekty jako jsou domy, silnice atd. Ve své práci dále upozorňují na to, že družicové senzory Ikonos nebo QuickBird jsou limitovány ve spektrálním rozlišení, zvláště evidentní při dálkovém průzkumu městských oblastí. Široce známá spektrální komplexnost materiálů městské zástavby má za následek omezení při rozlišení a oddělení zastavěných území, různých druhů střech či cest. Z toho důvodu by měla klasifikace obrazu obsahovat další doplňující prostorové a kontextuální charakteristiky jako je další úroveň informací.

Objektově orientovaná klasifikace zpevněných povrchů (budov, silnic, různých druhů střech) je tématem článku Aldred, Wang (2007). Střechy jsou význačným rysem budov, jak je patrné ze senzorů dálkového průzkumu Země a mohou být považovány jako takové náhrady za stopy (obrysy) domů, které jsou nedílnou součástí urbanistických studií. Velká variabilita ve složení materiálu, barev, tvaru, velikosti a orientace budov v typicky smíšeném použití městské scény znamená, že střechy jsou rozlišovány od jiných zpevněných povrchů více pomocí sémantických vlastností složitějších k pochopení, než jakéhokoliv konzistentní fyzicky definované atributy.

Zpevněné povrchy, obsahující střechy budov, silnice, dálnice, parkoviště a jejich mapování, poskytuje základní ukazatel kvality životního prostředí a dále hodnotné informace pro plánování a řízení činností. Přesto i v dnešní době je automatické extrahování prvků městské zástavby z dat velmi vysokého rozlišení dálkového průzkumu Země stále těžký úkol. Zvláště stíny budov a stromů ve snímcích s vysokým rozlišením představují vážný problém pro digitální klasifikaci dle Yuan a Bauer (2006).

### ***2.3.3. Objektově orientovaná klasifikace s využitím DEM***


Digitální výškový model, často také označovaný jako digitální elevační model (DEM – Digital Elevation model), představuje zvláštní případ DTM (Digital Terrain Model), kde hodnotami jsou nadmořské výšky. Mezi základní zdroje o nadmořských výškách patří terénní měření, letecká a družicová fotogrammetrie, radarová interferometrie, laserová altimetrie (laser scanning) či digitalizace vrstevnic.

S využitím jedné z výše uvedených metod je možné ze získaných výškových dat, která mají zpravidla tvar nepravidelné bodové sítě, vytvořit pravidelnou síť bodů rastrových DEM, a to pomocí různých interpolačních metod. Existuje několik způsobů jak pracovat s pravidelnou sítí bodů a pro výpočet elevace může být použit vážený průměr okolních bodů (např. metoda IDW) či geostatický průměr na autokorelaci okolních bodů (např. metoda Kriging) a nebo optimalizace parametrů nějaké matematické funkce, kterou je aproximován terén (splajn, polynommické intervaly atd.). (Barták, 2008)

Laserová altimetrie neboli laser scanning je velice progresivní metodou a předpokládá pečlivé a kvalitní zpracování naměřených dat. Terén je snímán laserovými paprsky zpravidla z letadla. Využitím této metody je docíleno vysoké přesnosti, a to v řádu 0,2 – až 1 m. Laserové skenování bylo vyvinuto pro rychlé a operativní mapování. I přesto, že se jedná o velmi mladou metodu, nachází své uplatnění při tvorbě 3D modelů měst, analýzách vegetačního pokryvu.

Pod zkratkou LIDAR se ukrývá slovní spojení Light Detection and Ranging, kde hlavní částí je pulsní laser, který vysílá krátké záblesky infračerveného záření a vysílá je k zemi. Tento paprsek je odražen zpět do sensoru, který zaznamenává i dobu letu. Infračervené pulsy jsou vysílány s velmi vysokou frekvencí až 80 000 Hz. Jeden řádek je vytvořen vychylováním

paprsku v příčném směru vzhledem ke směru letadla v rozsahu  $\pm 20^\circ$ . Samotný paprsek dokáže proniknout některými materiály a zpět na senzor poté dopadá několik dílčích odrazů tak, jak paprsek procházel například vegetací. Z těchto dílčích odrazů jsou nejdůležitější právě první a poslední, kde první odraz dává informaci o vegetačním pokryvu a ten poslední je potom odrazem od fyzického terénu.



**Obrázek 4: Technologie LIDAR**

**Zdroj:** <http://www.southernmapping.com/methodology.php>

Jak uvádí Kopalová (2007) při vytvoření vlastního klasifikačního algoritmu pro extrakci budov a zpevněných ploch je možné další zpřesnění s využitím DEM (Digital Elevation Model). Hofmann (2008) se zabývá využitím DEM pro zlepšení výsledků při objektově orientované analýze obrazu. Uvádí, že i přes vysoké prostorové rozlišení dat z družice Ikonos může být automatická či semi-automatická detekce budov či silnic založená pouze na spektrálních charakteristikách značně složitá, zvláště pak v heterogenních oblastech, jako jsou hustě osídlená území. Použití DEM a dalších sémantických informací pomáhá detekovat tyto objekty mnohem adekvátněji. Při kombinaci spektrálních a výškových dat je významná výšková informace objektů a jejich spektrální vlastnosti, jelikož mohou být použity pro nástin tvaru objektů a pro odpovídající klasifikaci s programem Definiens eCognition.

Aldred, Wang (2007) popisují, že předchozí studie objektově orientované klasifikace budov v městské scéně pomocí dat Ikonos používají ještě dva přístupy. První z nich obsahuje doplňující informaci jako například DEM s vysokým rozlišením z dat laserového skenování nebo digitální katastrální mapy. Druhý přístup se zaměřuje na scéně s limitovanou variabilitou a relativní jednotností spektrálního složení střechy nebo dále stavební morfologií. Tento druhý přístup minimalizuje spektrální, prostorové a kontextové heterogenity střech ve scéně a

zjednodušuje identifikaci a hodnocení parametrů potřebných pro jejich klasifikaci.

Teo, Chen (2004) ve své studii nejprve uvádějí, že extrakce informací o krajinném pokryvu z dat dálkového průzkumu je důležitou součástí geografických informačních systémů. A právě budovy jsou jedním z významných typů při klasifikaci krajinného pokryvu. Získané obrysy budov jsou užitečné pro monitorování katastrof, při rozhodování či rekonstrukci budov, stejně jako pro další aplikace. Podle autorů se stal LIDAR v dnešní době osvědčeným způsobem pro odvození 3D informací v mapování a v GIS úlohách. Data z LIDARu poskytují velmi přesné 3D body, u kterých ale chybí informace o zlomové linii (breaklines). Naopak družicové snímky velmi vysokého prostorového rozlišení poskytují informace o zlomových liniích oproti datům z LIDARu. Kromě toho jsou multispektrální snímky užitečné pro identifikaci a klasifikaci objektů, jako jsou budovy a vegetace. Proto autoři ve své práci kombinují data LIDARu a družicové snímky velmi vysokého prostorového rozlišení pro detekci budov. Další studie (Halla a Walter, 1999; Zeng et al., 2002; Walter, 2004; Hofmann et al., 2002) ukazují, že doplňující informace o výšce jsou prospěšné pro klasifikaci budov a jiných objektů. Jak již bylo zmíněno výše, autoři se zaměřují na extrakci budov s využitím objektově založené klasifikace. Navrhovaný postup se skládá ze dvou hlavních částí a to segmentace a klasifikace. V segmentaci jsou body z LIDARu převzorkovány do rastrové podoby. Potom jsou v segmentaci kombinovány výškové atributy dat LIDARu a radiometrické atributy snímku. Data s podobnou výškou a spektrálními hodnotami jsou sloučeny do segmentu. V klasifikaci využívají objektově orientovaný přístup pro separaci budov a ostatních ploch. Atributy uvažované při klasifikaci obsahují: výškové informace z dat LIDAR; spektrální informace z multispektrálních snímků; drsnost povrchu; tvar regionů. Výsledky jejich práce ukázaly potenciál automatické metody pro extrakci budov. Pomocí jejich přístupu bylo rozpoznáno více než 89% budov. Většina z nezjištěných budov jsou budovy malých rozměrů. Tyto chyby vznikly převážně ve fázi segmentace. Proto uvádějí, že je potřeba další zpracování pro extrakci budov menších rozměrů, kterému se již ale nevěnují.

Autoři Hermosillat, Ruiz, Reico, Estornell (2011) se ve své studii věnují jedné z technik detekce a umístění budov založené na kombinaci snímků a trojrozměrných dat z leteckého laserového skenování. Dle autorů použití dvou vzájemně se doplňujících zdrojů dat obvykle zlepšuje výsledky detekce budov. Uvažují dva hlavní přístupy: objektově orientovanou klasifikaci a detekci na základě prahování. U prvního přístupu jsou obrazové objekty vytvořeny pomocí automatické segmentační techniky. Poté jsou objekty charakterizovány pomocí spektrálních, tvarových a výškových parametrů. Přístupy založené na prahování nejprve uplatňují prahové hodnoty pro nDSM (normalized digital surface model) k rozlišení budov a vegetace a dále kombinují s prahovými hodnotami použitými na NDVI (Normalized difference vegetation index), aby byla odmaskována vegetace. Poté mohou být budovy prohlášeny za budovy, nebo zamítnuty v závislosti na různých podmínkách, jako jsou velikost a tvar, spektrální hodnoty nebo textura. Dle autorů výsledky ukazují, že přístup detekce budov založený na prahování vytváří lepší výsledky v různých analyzovaných scénářích, zvláště

v příměstských oblastech. Tato metoda umožňuje přesnější vymezení budov a detekci objektů než objektově založené klasifikační metody. Navíc objektově orientované klasifikační metody představují složitější postup, vzhledem k většímu počtu parametrů potřebných pro definice a opatření, které mají být prováděny.

Zeng, Zhang, Wang a Lin (2002) popisují, že jedním z nejslibnějších přístupů k řešení náročných úkolů v rámci klasifikaci městského land use je integrace multispektrálních satelitních snímků. V jejich práci jsou výšková data z leteckého laserového skenování začleněna do klasifikace městského prostředí. Data z laserového skenování využívají k získání informace o poloze každého pixelu výšku nad povrchem terénu. Tato informace může být použita k oddělení městské zástavby, která je vyšší než zemský povrch, od objektů přímo na zemském povrchu, např. stromy, vodní plochy, ulice atd.

Syed, Dare, Jones (2005) ve své práci navrhli objektově orientované klasifikační schéma, které využívá DSM odvozené z dat leteckého laserového skenování a multispektrální obrazová data pro prvotní segmentaci a následnou klasifikaci objektů. Z dat Lidaru vytvořili normalizovaný digitální model povrchu (nDSM). V procesu multiměřítkové segmentace byl vliv u nDSM a multispektrálních pásem kontrolován při generování objektů vahou pásem, měřítkovým parametrem, množstvím barevného a tvarového faktoru. Lidar poskytuje velmi přesné informace o poloze a výšce, ale méně přesné informace o geometrickém tvaru objektů. Kdežto snímky vysokého rozlišení poskytují velmi detailní informace o objektech jako spektrální signatury, textura, tvar atd. Kombinace těchto dvou typů, navzájem se doplňujících se datasetů, je slibná pro extrakci budov či 3D modelování měst. Přesnost výsledků s využitím tohoto přístupu je slibná v porovnání s pixelově založenou klasifikací maximum likelihood. Výsledky ukazují, že objektově orientovaný přístup má velký potenciál pro integraci dat Lidar a snímků s vysokým rozlišením pro multisenzorovou klasifikaci.

Hofman (2008) také uvádí, že v porovnání s pixelově založenými metodami je objektově orientovaná analýza obrazu v programu Definiens eCognition nejvhodnější pro zpracování složitých scén, jako jsou snímky s vysokým rozlišením městských oblastí. Především se jedná o techniku segmentace a dále o objektově orientovanou klasifikaci, které dávají nové možnosti čelit typickým problémům v městské oblasti DPZ. Například se stíny se lze jednoduše vypořádat pomocí sousedních vztahů, zpevněné plochy mohou být lépe rozlišeny pomocí jejich tvaru a v neposlední řadě domy lze lehce identifikovat pomocí jejich relativní výšky oproti okolním objektům.



## 2.4. Land cover

Krajinný pokryv lze popsat jako přírodní nebo pěstovanou vegetaci nebo člověkem vytvořené konstrukce (budovy, apod.), které se vyskytují na povrchu země. Voda, led, holé skály, písek a podobné povrchy představují rovněž land cover (FAO). Jedna kategorie land cover může sloužit k různým způsobům využití (land use).


Bylo zjištěno, že spektrální rozlišení obsažené ve 4 spektrálních kanálech z dat velmi vysokého rozlišení, je dostačující pro rozlišení mezi široce diferencioványi třídami land coveru v městském prostředí jako je voda, holé půdy, vegetace, stíny a zpevněné povrchy. Ale jemná klasifikace do více užitečných sémantických kategorií, jako jsou silnice, parkoviště a budovy, je navíc komplikována tím, že vysoké spektrální změny mezi třídami jsou nalezeny mezi těmito druhy rysů, dle Aldred, Wang (2007).

Syed, Dare, Jones (2005) ve své studii využívají automatickou klasifikaci s využitím objektově orientovaného přístupu pro vyčlenění land coveru ze snímků vysokého rozlišení a dat z Lidaru. Tento přístup hodnotí jako efektivní a předpovídají mu slibnou budoucnost.

Dle Griffith (2005) rozvoj satelitních snímků vysokého rozlišení a leteckých snímků ve spojení s objektově orientovanou analýzou obrazu pomocí software eCognition může sloužit k analýze land use a land cover určité oblasti. Land use odkazuje na to, co lidé dělají na zemském povrchu. Příkladem je zemědělství, komerční a rezidenční rozvoj či doprava. Land cover představuje typ materiálu vyskytující se v krajině. Materiály jako voda, různé typy vegetace, půdy a člověkem vytvořené materiály jako např. asfalt.

### 3. Metodika

Obec se nachází v okrese Praha východ zhruba 20 km jihovýchodně od centra Prahy mezi městy Říčany a Jesenice u Prahy. První zmínka o obci se v historických pramenech objevuje kolem roku 1336. Obec vznikla v roce 1991 oddělením od obce Dobřejovice. Svou strategickou polohou u dálnice D1 se staly Modletice synonymem pro komerční suburbanizaci. Nadmořská výška je zhruba 357 m.n.m. Katastrální rozloha obce je 344 ha, z čehož činí orná půda 70%. Kromě toho jsou z kategorií zemědělské půdy v katastru obce také i ovocné sady. Pro Modletice je charakteristická rezidenční zástavba a komerční suburbanizace zahrnující sklady, logistické parky atd. Například od roku 1997 zde má své sídlo a centrální sklad maloobchodní firma Billa. V plánu je také výstavba mimoúrovňového křížení dálnice a pražského okruhu na 11. kilometru dálnice D1, čímž se upevní postavení Modletic jako strategického místa poblíž významných dopravních tahů. Podle aktuálního ortofota již začala výstavba mimoúrovňového křížení. (Bromová, 2010)




*Obrázek 5: Modelové území Modletice*

*Zdroj: šetření autora*

### 3.1. Modelové území Jirny

Obec se nachází v okrese Praha východ zhruba 22 km východně od centra Prahy v těsné blízkosti dálnice D11 mezi Úvaly a Brandýsem nad Labem. V historických záznamech jsou zmínky o obci z roku 1352. Skládá se ze dvou fyzicky oddělených částí (Jirny a Nové Jirny). Vzdálenost mezi těmito dvěma částmi je zhruba 1,5 km. Tvar půdorysu obce připomíná hvězdicí, ze které vycházejí komunikační směry paprscitě na všechny strany. Průměrná nadmořská výška je 250 m.n.m. Katastrální plocha obce zaujímá 824 ha, z čehož zaujímá orná půda 56% a 1/5 je osázena lesním porostem. Z jižní strany obklopuje obec přírodně rekreační Klánovický les. Zemědělské plochy vyplňují prostor mezi oběma částmi obce. Výstavba rodinných domů v Jirnech probíhá v omezené míře. Oproti tomu dominantní část území byla využita ke komerčním aktivitám zaměřeným na logistiku a pro stavbu velkokapacitních skladišť. Své sklady zde mají například obchodní řetězec Penny Market, Globus, dále překladště firmy DHL a nebo středoevropské distribuční centrum hraček Lego. (Kupková L.; Novák, J.)



Obrázek 6: Modelové území Jirny

Zdroj: šetření autora

## 3.2. Data a software

### Družicová data

Družicové snímky velmi vysokého rozlišení pořízené družicovým systémem QuickBird byly nasnímány pro oblast Modletice 13. dubna 2007 v 10:35:03 hod. a pro oblast Jirny 21. dubna 2007 v 10:25:10 hod. K dispozici byly snímky jak multispektrální s prostorovým rozlišením 2,4 m, tak i snímek panchromatický s prostorovým rozlišením 0,6 m. Po provedení pansharpeningu byly k dispozici pro obě sledované oblasti zaostřené multispektrální snímky s prostorovým rozlišením 0,6 m.

### Lidar data

Data z leteckého laserového skenování byla pořízena v roce 2010 a k dispozici byla v podobě mračna bodů, ze kterých bylo potřeba zpracovat výřez pouze pro modelové oblasti. Data byla poskytnuta ve formátu XYZ.

### Vektorová data

Vektorová data použitá pro zhodnocení přesnosti klasifikace vznikla ruční vektorizací stejných snímků QuickBird, které byly použity pro klasifikaci. Jedná se o polygonové vrstvy, které byly zpracovány v rámci bakalářské práce (Bromová 2010), jejímž cílem bylo pořízení vektorové databáze krajinného pokryvu v různých časových horizontech. Pro tvorbu vektorových vrstev modelového území Modletice využila autorka vrstvu sloučených dat ZABAGED. Vektorová vrstva pro modelové území Jirny byla vytvořena jiným autorem v rámci projektu MŽP Suburbánní rozvoj, suburbanizace a urban sprawl v České republice: Omezení negativních důsledků na životní prostředí 2007 – 2011.



*Obrázek 7: Vektorová vrstva Modletice*

*Zdroj: <http://web.natur.cuni.cz/ksgrrsek/urrlab/>*



*Obrázek 8: Vektorová vrstva Jirny*

*Zdroj: <http://web.natur.cuni.cz/ksgrsek/urrlab/>*

## **Software**


Pro zpracování dat byl využit následující software: PCI Geomatica 9.1; ArcGIS 10.0; eCognition Developer Trial 8.0, eCognition Developer 8.0. Zaostření multispektrálního snímku panchromatickým bylo provedeno v software PCI Geomatica v modulu Focus. U software ArcGIS bylo využito modulu ArcMap pro tvorbu NDSM a pro transformaci družicových snímků a ArcCatalog pro import souřadnicového systému. Posledním využitým softwarem byl eCognition Developer, který sloužil ke zpracování objektivě orientované klasifikace, multiměřítkové segmentace a následné klasifikace.

### **3.3. Předzpracování družicových snímků**

Družicové snímky velmi vysokého rozlišení pořízené družicovým senzorem QuickBird byly před samotnou objektivě orientovanou klasifikací předzpracovány. Jak již bylo uvedeno výše, snímky jsou pořizovány ve dvou režimech, a to multispektrálním a panchromatickým. Přičemž panchromatické snímky (u snímku QuickBird je prostorové rozlišení 0,6 m) mají zhruba 4x vyšší prostorové rozlišení než snímky multispektrální (u snímku QuickBird je 2,4 m). Při „pansharpeningu“ (digitální spojení obrazových dat – image fusion) je multispektrální snímek zaostřen panchromatickým snímek s vyšším prostorovým rozlišením. Výsledkem je poté multispektrální snímek s prostorovým rozlišením, které odpovídá původnímu rozlišení snímku panchromatického (v případě dat z QuickBirdu to je 0,6 m).

Pansharpening byl aplikován na snímky zachycující oblasti Modletice a Jirny s využitím softwaru PCI Geomatica a modulu Focus. Zde je k dispozici funkce „pansharp“

(automatic image fusion), která spojuje panchromatické snímky velmi vysokého rozlišení s multispektrálními snímky a vytváří multispektrální snímky velmi vysokého rozlišení.“ Na obrázku č. 6 je ukázka multispektrálního (vlevo) a zaostřeného snímku (vpravo).

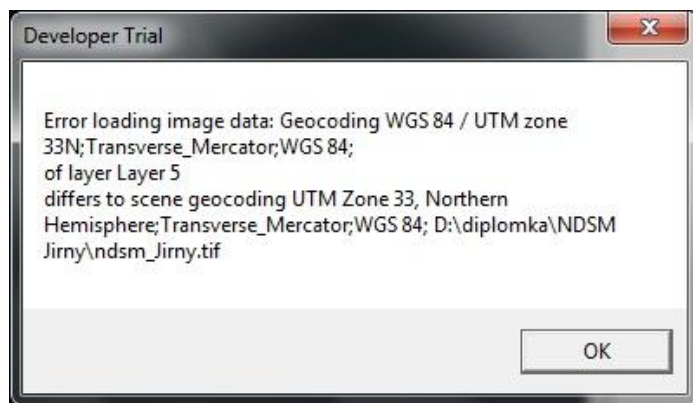


*Obrázek 9: Pansharpening družicového snímku*

*Zdroj: šetření autora*

### **3.4. Transformace družicových snímků**

Souřadnicový systém zaostřených družicových snímků velmi vysokého prostorového rozlišení zachycující oblast Modletice a Jirny odpovídá WGS 84, UTM 33 Northern Hemisphere, Transverse Mercator. Bodové vrstvy z leteckého laserového skenování LIDAR, ze kterých je v další fázi vytvořen nDSM, byly v souřadnicovém systému S- JTSK Krovak, East North. Prvním předpokladem bylo, že postačí v modulu ArcCatalog importovat bodovým vrstvám z leteckého laserového skenování souřadnicový systém ze zaostřených družicových snímků. Ke změně souřadnicového systému opravdu došlo, ale problém nastal při společném otevření snímku a vrstvy nDSM v software eCognition. Při pokusu o otevření došlo k vyslání chybové zprávy, že souřadnicové systémy si neodpovídají viz. obr. 7.



**Obrázek 10: Chybová zpráva při načítání vrstev do software eCognition**

*Zdroj: šetření autora*


Z tohoto důvodu byly transformovány zaostřené družicové snímky podle vektorových vrstev odpovídajících oblastí. Nejprve bylo cílem přiřadit družicovým snímkům stejný souřadnicový systém, který mají vektorové vrstvy, tedy S-JTSK Krovak, East North. Zaostřené družicové snímky jsou ve formátu pix. Pro import souřadnicového systému byl opět zvolen ArcCatalog. V tomto případě však nešlo importovat souřadnicový systém souboru pix. Tento problém byl vyřešen převodem formátu pix družicových snímků na formát tiff s využitím modulu Focus. Po tomto kroku již bylo možné importovat koordinační systém S-JTSK Krovak s využitím ArcCatalogu. Samotná transformace byla realizována v ArcMapu s využitím nástroje Georeferencing, který slouží ke georeferenci a transformaci rastru. Celkem bylo nasbíráno 12 vlíčovacích bodů, jejichž přesnost (residual) by neměla přesáhnout 1m, což se při zpracování podařilo. Typ transformace je v software ArcMap vždy prvního řádu, v tomto případě tedy afinní. Pro převzorkování byla využita funkce Nearest Neighbour. Výsledky georeference pro Modletice a Jirny jsou v příloze č. 1.1. a 1.2.

### **3.5. Tvorba nDSM**

Pro zpracování byly k dispozici data jak z laserového skenování, tak i DMR 4.generace. Digitální model reliéfu zobrazuje terén bez budov, sloupů, stromů atd. DMR 4.generace zobrazuje přirozený nebo člověkem upravený zemský povrch v digitálním tvaru ve formě výšek v pravidelné síti (5x5 m) bodů o souřadnicích X,Y,Z. Zde Z představuje nadmořskou výšku ve výškovém referenčním systému Balt po vyrovnání s úplnou střední chybou výšky 0,3 m v odkrytém terénu a 1 m v zalesněném terénu. (ČÚZK, 2011)

Ke zpracování byl využit software ArcGIS s aplikacemi ArcMap a ArcCatalog. Bodové vrstvy byly načteny s využitím funkce ASCII to raster. Obě bodové vrstvy jsou načítány po částech a je potřeba je spojit v jednu jedinou vrstvu pomocí nástroje „merge“. Poté byla bodová vrstva obsahující výšky budov oříznuta podle bodové vrstvy zobrazující terén. V dalším

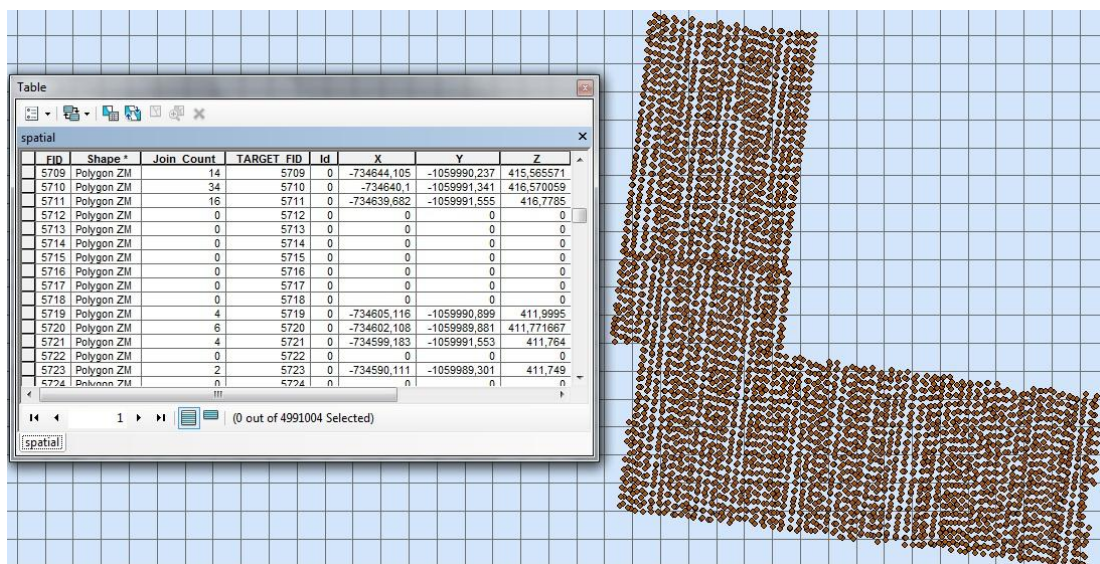
kroku byly bodové vrstvy převedeny z multipointu na singlepoint s využitím funkce „Feature to Point“. Pomocí nástroje „Create fishnet“ (tvorba pravidelné mřížky) byla vytvořena síť polygonů o velikosti 4x4 m.



**Obrázek 11: Tvorba pravidelné mřížky („Create fishnet“)**

*Zdroj: šetření autora*

Nástroj „Spatial join“ slouží pro převod atributů z jedné feature class (třídy prvků) do druhé feature class na základě prostorových vztahů dvou tříd. V tomto případě přiřadí k vytvořeným polygonům atributy z bodové vrstvy obsahující výšku budov.

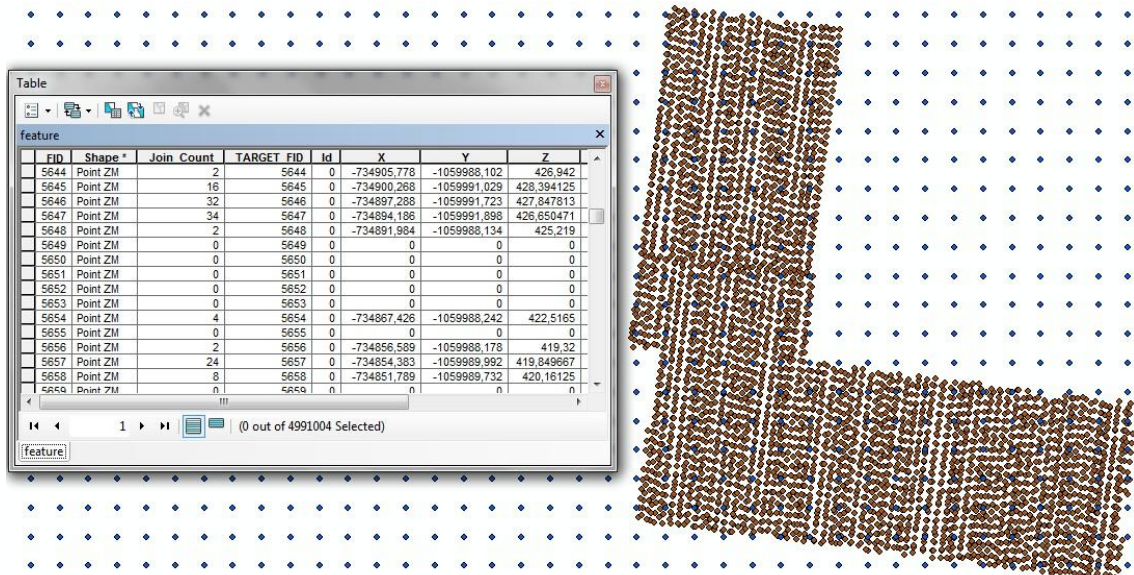


**Obrázek 12: Nástroj „Spatial join“**

*Zdroj: šetření autora*




Dále byla využita funkce „Feature to point“, aby polygony přebraly výšku z bodu. Tento nástroj vytvořil třídu prvků (feature class) obsahující body generované z reprezentativního umístění vstupní třídy (input features).



**Obrázek 13: Nástroj „Feature to point“**

*Zdroj: šetření autora*

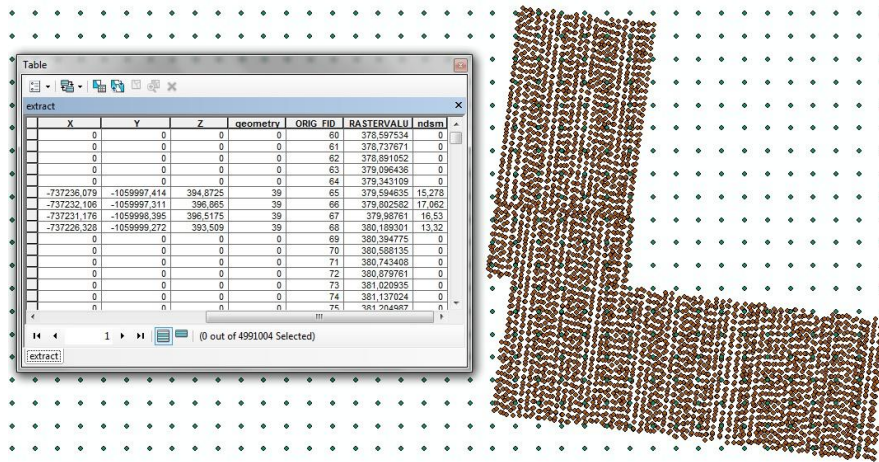
Poté byl aplikován na bodovou vrstvu DMR nástroj „Topo to raster“, který interpoluje hydrologicky korektní raster z bodů, linií a polygonů. Takto vzniklý raster byl dále spolu s vrstvou, která vznikla v jednom z předchozích kroků (Feature to point), vstupním parametrem pro nástroj „Extract values to points“. Tato funkce extrahuje hodnoty buněk rasteru a zaznamenává hodnoty v atributové tabulce výstupní feature class (třídy prvků).



**Obrázek 14: Nástroj „Topo to raster“**

*Zdroj: šetření autora*

V nově vzniklé vrstvě, která byla nazvána pracovní „extract.shp“ byl v atributové tabulce přidán sloupec s využitím add field (název: ndsm, typ: double). Pomocí funkce Field Calculator byly od sebe odečteny dva sloupce [Z] – [RASTERVALUE], od výšky budov byla tak odečtena výška terénu. V dalším kroku byly s využitím Select by Attributes vybrány všechny atributy s hodnotou ndsm menší než 0. Vybrané atributy byly přepsány tak, že do Field Calculator byla vepsána hodnota 0. Tímto bylo docíleno toho, že zůstaly pouze výšky pro budovy (případně jiné výškové objekty jako mohou být nevyfiltrované stromy či sloupy).




X	Y	Z	geometry	ORIG_FID	RASTERVALU	ndsm
0	0	0	0	60	376,59754	0
0	0	0	0	61	376,737671	0
0	0	0	0	62	376,881052	0
0	0	0	0	63	376,996436	0
0	0	0	0	64	376,943109	0
-737236,079	-1059997,414	394,8725	39	65	376,594635	15,278
-737232,106	-1059997,311	396,865	39	66	376,802582	17,062
-737231,176	-1059998,395	396,5175	39	67	376,80761	16,53
-737229,326	-1059999,272	393,509	39	68	380,185901	13,32
0	0	0	0	69	380,394775	0
0	0	0	0	70	380,598135	0
0	0	0	0	71	380,743408	0
0	0	0	0	72	380,879761	0
0	0	0	0	73	381,020935	0
0	0	0	0	74	381,137624	0
0	0	0	0	75	381,094997	0

**Obrázek 15: Výpočet nDSM**

*Zdroj: šetření autora*

V posledním kroku je převedena bodová vrstva „extract.shp“ na raster s použitím nástroje „Point to raster“.



**Obrázek 16: Nástroj „Point to raster“**

*Zdroj: šetření autora*

V přílohách jsou uvedeny vstupní, výstupní vrstvy a parametry nastavení jednotlivých funkcí. V případě, že je nutné zadat hodnotu cell size, je zadávána vždy stejná hodnota. Při zpracování byla jako první hodnota cell size u nástroje „create fishnet“ hodnota 4 m. Stejná hodnota cell size byla poté nastavena pro funkci „Topo to raster“ a také pro „Point to raster“. Během celého zpracování byly nově vzniklé vrstvy vždy nazývány podle použitého nástroje např. fishnet.shp, spatial.shp, topo\_teren atd.

Stejný postup byl aplikován pro tvorbu NDSM pro oblast Jirny, která slouží pro závěrečnou validaci vytvořené klasifikační báze.

### 3.6. Objektově orientovaná klasifikace

Před samotnou klasifikací obrazu bylo potřeba vymezit komerční zóny modelového území Modletice a Jirny. Tyto oblasti jsou charakterizovány sklady, logistickými, výrobními a prodejními areály. Zpevněné povrchy zahrnují silnice a dálnice, parkoviště atd. Ze snímků Quickbird a z nDSM byly v software eCognition (nástroj „subset selection“) vytvořeny výřezy zachycující požadované komerční zóny (viz. obr. 17 a 18). Poté bylo možné přistoupit k segmentaci a tvorbě klasifikační báze.



*Obrázek 17: Komerční zóna v modelovém území Modletice*

*Zdroj: šetření autora*




*Obrázek 18: Komerční zóna v modelovém území Jirny*

*Zdroj: šetření autora*

### **3.6.1. Multiměřítková segmentace**

Prvním krokem objektově orientovaného přístupu ke klasifikaci obrazu je segmentace, která obraz rozdělí do relativně homogenních objektů. Z druhů segmentace uvedených výše byla aplikována multiměřítková segmentace. Důležitou součástí je nastavení parametrů segmentace, kterými jsou měřítkový parametr, tvar a kompaktnost. Autoři eCognition 8.0 User Guide (2010) zvolili pro multiměřítkovou segmentaci hodnotu měřítkového parametru 25. Dle těchto autorů je lepší provést segmentaci tak, aby byly vytvořeny poměrně malé objekty a získány tak přesné obrysy budov. Pro měřítkový parametr není definováno žádné pravidlo, proto je potřeba zkoušet nastavení tak dlouho, dokud měřítkový parametr nepovede k objektům, které jsou vhodné pro další klasifikaci. Na obr. 19 jsou v pořadí zleva doprava znázorněny ukázky výstupů segmentace s měřítkovými parametry s hodnotou 25, 28 a 35. Pro samotné zpracování byl zvolen jako nejvhodnější měřítkový parametr s hodnotou 28. Nastavení parametrů tvar a kompaktnost vycházelo z doporučení autorů eCognition 8.0 User Guide – Simple building extraction, kteří nastavili hodnoty pro tvar 0,1 a pro kompaktnost 0,5. Multiměřítková segmentace byla provedena pouze na jedné úrovni, a to z toho důvodu, že cílem bylo v další fázi klasifikovat budovy komerční suburbanizace a zpevněných ploch. Diplomové práce Kopalová (2007), Kolankiewiczová (2009) pracují se dvěma segmentačními úrovněmi, aby v jedné úrovni vyklasifikovaly budovy a v druhé segmentační úrovni klasifikovaly land cover atd. Avšak v postupu aplikovaném v předkládané práci jsou již na počátku využita výšková data a jak se ukázalo v tomto případě, je dostačující segmentace pouze na jedné úrovni.

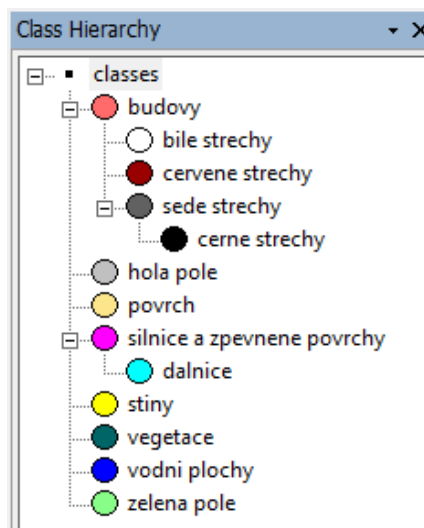


*Obrázek 19: Ukázka nastavení měřítkového parametru s hodnotami 25, 28, 35 (zleva doprava)*

*Zdroj: šetření autora, software eCognition 8.0*

### **3.6.2. Tvorba klasifikační báze s využitím nDSM**

Během klasifikačního procesu byla vytvářena klasifikační báze. Tento iterativní proces začíná základní strategií a pokračuje implementací vlastních pravidel. Po aplikování vlastních pravidel je potřeba zkontrolovat výsledky. V případě, že výsledky nejsou uspokojivé, je nutné se vrátit o krok zpět a zpřesnit či rozšířit strategii. Na základě zpřesněné strategie je upravena i klasifikační báze a opět zkontrolovány výsledky. Takto se postupuje, dokud není dosaženo uspokojivých výsledků. (eCognition 8.0 User Guide – Simple building extraction) Tímto přístupem se řídí následující klasifikační postup. Kompletní klasifikační báze včetně prahových hodnot pro jednotlivé třídy a postup klasifikace je uveden v příloze č. 3. Přehled klasifikovaných tříd je uveden na obr. 20.

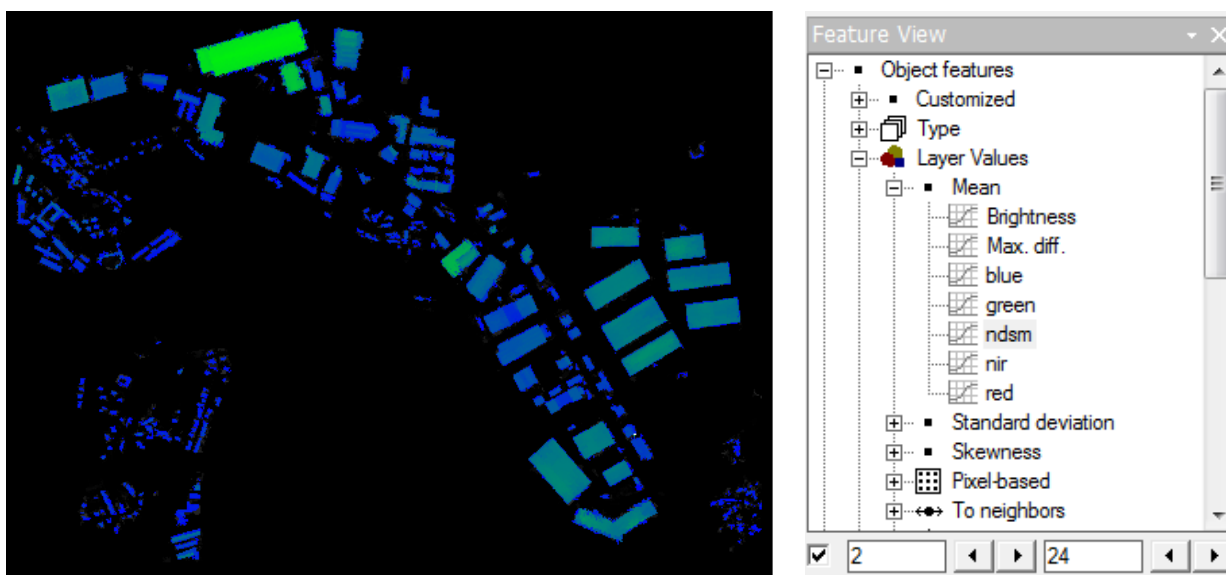


*Obrázek 20: Přehled klasifikovaných tříd*

*Zdroj: šetření autora, software eCognition 8.0*

Základní předpoklad, z něhož klasifikace s využitím nDSM vychází, je ten, že budovy mají větší výšku než okolní povrch. Tato skutečnost byla využita pro prvotní klasifikaci. Jedním z cílů této diplomové práce bylo ukázat, že informace o výšce z dat LIDAR poskytuje klíčovou informaci pro extrakci budov. Vzhledem k tomu, že nejen budovy, ale například také stromy mají určitou výšku, pouze využití doplňujících informací o různém chování ve vrstvách LIDAR a RGB umožňuje oddělení budov od všech ostatních objektů s výškou. (eCognition 8.0 User Guide – Simple building extraction)

S využitím nástroje pro zobrazení příznaků (Feature view) je možné posunovat práh příznaku průměrné hodnoty nDSM, dokud není dosaženo požadovaného stavu (viz. obr. 20). Na základě vhodné prahové hodnoty je nastavena podmínka, aby se všechny segmenty s požadovanou výškou přiřadily do třídy budovy pomocí nástroje „assign class“ (viz. příloha č. 3, klasifikační báze).



**Obrázek 21: Nastavení prahové hodnoty pro průměrnou hodnotu nDSM**


**Zdroj: šetření autora, software eCognition 8.0**

Při kontrole výsledků klasifikace bylo zjištěno, že jsou kromě budov vyklasifikovány také některé stromy. Dalším krokem byla tedy úprava strategie, a tím i klasifikační báze tak, aby byly chybně vyklasifikované stromy odděleny od budov. Stromy, které mají stejnou výšku jako budovy, nesou heterogenní informace o výšce a spektrální charakteristiky pro vegetaci. Pro klasifikaci stromů a vegetace, které jsou ve třídě budovy, bylo využito příznaku NDVI. Normalizovaný diferenční vegetační index patří do skupiny poměrových indexů, které využívají normalizovaný poměr odrazivosti povrchů v červené viditelné a blízké infračervené části spektra. Vyšší hodnoty vegetačního indexu jsou charakteristické pro světlejší plochy a reprezentují oblasti s nejbohatší vegetací. Vodní plochy či větší zastavěná území se jeví téměř

černě. Hodnoty NDVI se nacházejí v rozmezí  $\langle -1, 1 \rangle$ , přičemž se hodnoty pohybují v závislosti na množství zelené hmoty v pixelu. V průběhu roku a v rámci změny ročních období může docházet ke změně hodnot NDVI pro určité druhy povrchu, zejména pro zemědělské či lesní plochy.

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

Z výše uvedených informací vychází hledání a nastavení prahové hodnoty pro klasifikaci stromů a další vegetace z již vyklasifikované vrstvy budov. Do třídy vegetace byly zařazeny všechny segmenty z třídy budovy s hodnotou  $0,3 \leq NDVI \leq 0,579$  (viz. obr. 22).

 budovy with NDVI  $\geq 0.3$  and NDVI  $\leq 0.579$  at level 1: vegetation

**Obrázek 22: Nastavení prahové hodnoty NDVI**

**Zdroj: šetření autora, software eCognition 8.0**

Následovalo opětovné zhodnocení výsledků klasifikace, ze kterého vyplynulo, že tvary některých budov nejsou ideální, a proto bylo potřeba dále upravit klasifikační bázi. Vycházela jsem z předpokladu, že některé z neklasifikovaných segmentů jsou značně obklopeny segmenty z třídy budovy. V případě, že mají neklasifikované objekty vysoce podobnou hranici se segmenty z třídy budovy, měly by také patřit do třídy budovy. Tento poznatek byl převeden do klasifikační báze. V software eCognition je možné vyjádřit sousední vztahy objektů s využitím funkcí „Class related feature“. Vytvořené pravidlo musí popisovat situaci tak, že v případě, že neklasifikované objekty mající vysoce podobnou hranici se segmenty budov budou patřit také do třídy budovy. Ze souboru funkcí „Class related feature“ byl vybrán nástroj relativní hranice k („Relative border to“). Tento nástroj popisuje délku celkové hranice objektu v porovnání s hranicí konkrétní třídy a konkrétní příklad je uveden na třídě budovy:

- objekty, které nehraničí se segmenty třídy budovy mají hodnotu 0
- objekty, které jsou kompletně ohraničeny budovami mají hodnotu 1
- objekty s vysoce podobnou hranicí se segmenty z třídy budovy mají vysoké hodnoty blíží se 1
- objekty s nízkou hranicí podobnosti se segmenty z třídy budovy mají nízké hodnoty blíží se 0

Na základě této strategie se řídilo i nastavení prahové hodnoty tak, že všechny neklasifikované objekty s hodnotou relativní hranice s budovami  $\geq 0,5$  byly přiřazeny do třídy budovy.


V dalším kroku bylo možné přistoupit ke klasifikaci zpevněných ploch. Všechny neklasifikované objekty byly pomocí funkce „assign class“ přiřazeny do třídy povrch (viz. obr. 22), ze které se byly v další fázi klasifikovány hlavní třídy land cover, ale především silnice, dálnice, parkoviště a další zpevněné povrchy.

- klasifikace land cover
- unclassified at level 1: povrch

**Obrázek 23: Přřazení neklasifikovaných segmentů do třídy povrch**

*Zdroj: šetření autora, software eCognition 8.0*

Příznak brightness představuje podíl součtu všech kladných středních spektrálních hodnot objektu a počtu spektrálních pásem. (Goder, 2007) Vodní plochy byly klasifikovány z třídy „povrch“ nejprve na základě příznaku brightness. Při hledání prahových hodnot v příznaku brightness se vodní plochy jeví téměř jako černé či velmi tmavé viz. obr 24.



**Obrázek 24: Rozsah hodnot příznaku Brightness**

*Zdroj: šetření autora, software eCognition 8.0*

Při kontrole výsledku klasifikace třídy „vodní plochy“ došlo k chybné klasifikaci „stínů“, které mají stejné prahové hodnoty jako vodní plochy. Proto bylo potřeba upravit klasifikační bázi a na základě dalších příznaků z třídy „vodní plochy“ odklasifikovat stíny. Některé vodní plochy nebyly stále vyklasifikovány. Dalším spektrálním příznakem vhodným pro klasifikaci vodních ploch je průměrná hodnota NIR. V NIR mají vodní plochy vysokou pohltivost a malou odrazivost. Podobné vlastnosti mají právě i některé silnice, převážně dálnice. Aby nedošlo k chybnému zařazení „silnic a zpevněných povrchů“ do třídy „vodní plochy“ byly v následujícím kroku z třídy „povrch“ vyklasifikovány hlavní obrysy silnic na základě spektrálního poměrového příznaku Ratio Green. Tento příznak vyjadřuje podíl zeleného pásma na celkovém jasu objektu. Poté bylo možné doklasifikovat zbytek vodních ploch pomocí



zmíněného spektrálního příznaku NIR.

V pořadí další klasifikovanou třídou byla třída pracovní nazvaná „zelená pole“. Do této třídy byly zahrnuty plochy se stromy, trávou, vegetací atd. Ze třídy „povrch“ byly na základě funkce „assign class“ přiřazeny všechny segmenty s prahovou hodnotou  $0,31 \leq NDVI \leq 0,71$  do třídy „zelená pole“. Klasifikace byla zpřesněna s využitím dalšího pravidla. Segmenty z třídy „povrch“ s prahovou hodnotou  $0,44 \leq \text{Cut Ratio Green} \leq 0,47$  byly také přiřazeny do třídy „zelená pole“. Příznak Cut Ratio Green vychází z předpokladu, že zelené pásmo obsahuje důležité informace o vegetaci, ale pouze ve srovnání se dvěma dalšími pásmy. Jedním ze způsobů porovnání pásem je vytvoření poměru. Relevantní poměr je vyjádřen následující rovnicí:

$$\text{Cut Ration Green} = \frac{\text{green}}{\text{red} + \text{green} + \text{blue}}$$

*Zdroj: eCognition User Guide – Simple building extraction (2010)*

Tento poznatek bylo potřeba převést do klasifikační báze s využitím funkce „Create new arithmetic feature“, která umožňuje výpočet vlastních indexů, poměrů atd.

Třída „holá pole“ je charakterizována přírodními povrchy bez vegetace. Tato třída byla klasifikována na základě spektrálního příznaku Ratio Green. Oproti povrchům s vegetací je hodnota Ratio green pro třídu „holá pole“ vyšší. Prahová hodnota byla zvolena tak, aby všechny segmenty ze třídy „povrch“ splňující  $0,3222999 \leq \text{Ratio Green} \leq 0,37$  byly zařazeny do třídy „holá pole“ viz. obr. 25.




**Obrázek 25: Nastavení prahové hodnoty příznaku Ratio Green pro třídu „holá pole“**

*Zdroj: šetření autora, software eCognition 8.0*

V dalším kroku bylo potřeba doklasifikovat třídu „silnice a zpevněné povrchy“. Doposud byl vyklasifikován pouze základní obrys silniční sítě a zpevněných povrchů. Silnice a zpevněné povrchy mají charakter některých holých ploch. Z tohoto důvodu byla jako první klasifikována třída „holá pole“. Pravidlo bylo nastaveno tak, aby se všechny doposud neklasifikované segmenty z třídy „povrch“ s prahovou hodnotou  $0,11 \leq NDVI \leq 0,2$  přiřadily do třídy „silnice a zpevněné povrchy“. Pravidlo bylo ještě doplněno o podmínku, kdy opět všechny doposud neklasifikované segmenty z třídy „povrch“ s relativní hranicí  $0,5 \leq s$  třídou „silnice a zpevněné povrchy“ patřily do této třídy také. Pomocí příznaku Brightness bylo možné vyklasifikovat z třídy „silnice a zpevněné povrchy“ samostatnou třídu „dálnice“.

V poslední části objektově orientované klasifikace bylo snahou rozlišit různé typy střech komerční zástavby. Pro klasifikaci byly využity spektrální a kontextové příznaky. První třídou byly střechy, které se na družicovém snímku jeví jako bílé. Pro třídu „bílých střech“ byl zvolen spektrální příznak průměrná hodnota modrého pásma, vycházející z předpokladu, že světlé plechové střechy jsou charakterizovány velkým jasnem. Na obr. 26 mají bílé střechy v rozsahu prahových hodnot příznaku Mean Blue světle zelenou barvu. Klasifikační pravidlo je zvoleno tak, že všechny segmenty ze třídy „budovy“ s prahovou hodnotou  $580 \leq \text{Mean Blue} \leq 1049,1$  jsou začleněny do třídy „bílých střech“ a dále všechny segmenty z třídy „budovy“ s relativní hranicí  $0,5 \leq s$  třídou „bílých střech“ patří do této třídy také.



**Obrázek 26: Rozsah hodnot příznaku Mean Blue**

**Zdroj: šetření autora, software eCognition 8.0**


Další klasifikovanou třídou byly „červené střechy“, které se však na družicovém snímku v kombinaci pásem RGB jeví jako modré. Pro tvorbu klasifikační strategie byl využit příznak Cut Ratio Green, jehož rozsah hodnot je na obr. 27. Při pohledu na tento obrázek jsou jasně patrné tmavě modré budovy, které odpovídají právě „červeným střechám“. Na základě tohoto poznatku byly s využitím funkce „assing class“ přiřazeny segmenty z třídy „budovy“ s prahovou hodnotou  $0,3042 \leq \text{Cut Ratio Green} \leq 0,36$  do třídy „červené střechy“. Opět byla pro zpřesnění klasifikace využita kontextová informace o relativní hranici s třídou „červené střechy“.



**Obrázek 27: Rozsah hodnot příznaku Cut Ratio Green**

**Zdroj: šetření autora, software eCognition 8.0**

„Šedé střechy“ byly předposledním klasifikovaným typem střech. Zde byl předpoklad využití stejného příznaku jako pro třídu „holá pole“ pouze s jinou prahovou hodnotou. Proto bylo klasifikační pravidlo nastaveno tak, že segmenty z třídy „budovy“ s prahovou hodnotou  $0,37 \leq \text{Ratio Green} \leq 0,4089$  byly zařazeny do třídy „šedé střechy“ (viz. obr. 28). Stejně jako u předchozích typů střech byla využita kontextová informace o relativní hranici s třídou „šedé střechy“. Jako poslední byly klasifikovány černé střechy. Tento typ se nacházel na snímku pouze v jednom případě, i přesto bylo snahou daný typ klasifikovat. Z třídy „šedé střechy“ byly vybrány segmenty s prahovou hodnotou  $147 \leq \text{Mean NIR} \leq 162$  a byly přiřazeny do třídy „černé střechy“.



**Obrázek 28: Příznak Ratio Green s prahovou hodnotou  $0,37 \leq \text{Ratio Green} \leq 0,4089$**

*Zdroj: šetření autora, software eCognition 8.0*

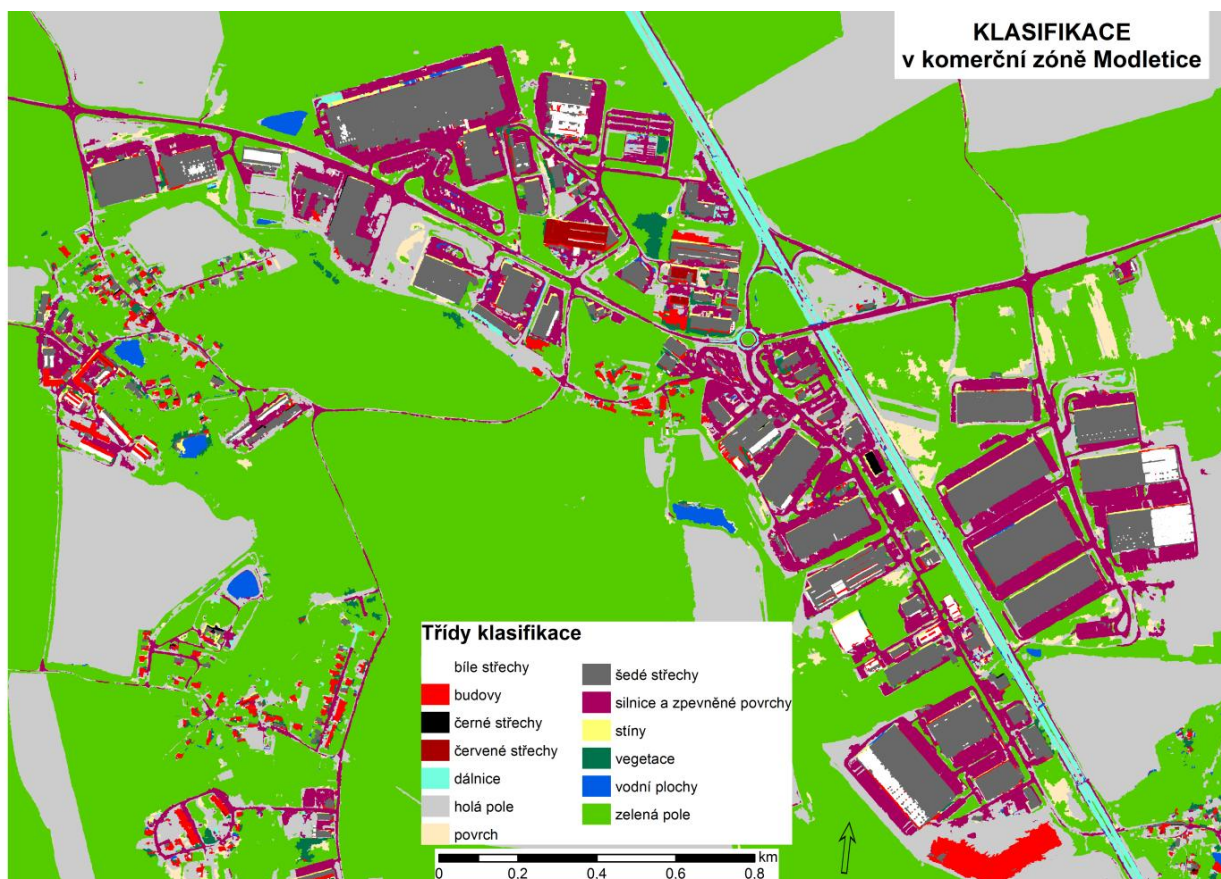
Jak již bylo zmíněno výše, při klasifikaci třídy „vodní plochy“ došlo k chybnému zařazení třídy „stíny“. Stíny se však nacházely i ve třídách „budovy“, „šedé střechy“, „bílé střechy“ a „červené střechy“, proto bylo nutné klasifikační bázi upravit. Stíny jsou klasifikovány z třídy „budovy“ a „šedé střechy“ na základě spektrálního příznaku Mean NIR. Z třídy „vodní plochy“, „šedé střechy“, „bílé střechy“ a „červené střechy“ byly odklasifikovány na základě kontextové informace „Distance to“ (vzdálenost ke konkrétní třídě).

Jelikož bylo cílem klasifikace získat mapu extrahovaných budov a zpevněných povrchů, byly v konečné fázi třídy sloučeny následovně:

- třída „budovy“ vznikla sloučením této třídy a tříd „bílé střechy“, „červené střechy“, „šedé střechy“ a „černé střechy“
- třída „silnice a zpevněné povrchy“ vznikla sloučením této třídy a třídy „dálnice“
- třída „povrch“ vznikla sloučením této třídy a tříd „zelená pole“, „holá pole“, „vodní plochy“, „stíny“ a „vegetace“

## 4. Výsledky

Následující kapitola se věnuje zhodnocení výsledků objektově orientovaného přístupu pro extrakci komerčních budov a zpevněných povrchů v suburbánní zóně Prahy. Zhodnocení přesnosti navrženého postupu bylo provedeno s využitím dat získaných ruční vektorizací a byla také ověřena přenositelnost navržené klasifikační báze pro jinou modelovou lokalitu. Výsledkem objektově orientované klasifikace jsou polygonové vrstvy ve formátu shp. vyexportované ze software eCognition 8.0. Výsledek podrobné klasifikace je na obr. 29 a v příloze č. 4.1. Upravený tematický výstup zpracovaný na základě podrobné klasifikace bez rozlišení typů střech a ostatních zpevněných ploch je v příloze č. 5.7.




Obrázek 29: Výsledek objektově orientované klasifikace v modelovém území Modletice

Zdroj: šetření autora, software eCognition 8.0

### 4.1. Vizuální interpretace výstupu klasifikace

Z hlediska vizuálního hodnocení klasifikace bylo dosaženo kvalitních výsledků při klasifikaci budov v komerční zóně s využitím dat velmi vysokého rozlišení a nDSM vytvořeného z výškových dat LIDAR. Klasifikace zpevněných povrchů dosahuje také uspokojivých výsledků, i přesto, že místy docházelo k záměně s holými povrchy, které se vyznačují podobnou charakteristikou jako některé silnice, parkoviště či další zpevněné povrchy. Některé


plochy byly příliš heterogenní a nebylo možné je více rozklasifikovat (viz. obr. 30). Klasifikace holých/odkrytých povrchů, ale nebyla stanovena jako cíl této práce.



**Obrázek 30: Družicový snímek heterogenní plochy (vlevo), klasifikace heterogenní plochy (vpravo),**

**Zdroj: šetření autora, software eCognition 8.0**

Vizuálně lze také pozorovat případy, kdy došlo během klasifikačního procesu k extrakci budov na základě výšky, jejíž informace je nesena ve vrstvě nDSM. Na snímku QuickBird však tyto budovy nejsou. Je zřejmé, že družicové snímky velmi vysokého rozlišení byly pořízeny dříve než výšková data LIDAR. Budovy v tomto případě nebylo možné dále klasifikovat na základě spektrálních či kontextových příznaků do odpovídajících tříd podle typu střechy. Na obr. 31 je vždy sledována budova (zvýrazněna červenou elipsou) nejprve na snímku z družice QuickBird, kde je pouze staveniště, dále ve vrstvě nDSM, ve výsledné klasifikaci a na aktuálním ortofotu, kde je již budova postavena (zdroj: ČÚZK). Těchto případů se vyskytuje ve výsledné klasifikaci několik a byly zohledněny při hodnocení přesnosti klasifikace. Jak bylo uvedeno výše, při podrobné klasifikaci typů střech zůstaly tyto objekty ve třídě „budovy“ a nebyly dále klasifikovány.



*Obrázek 31: Klasifikace budovy pouze na základě výšky: staveniště na družicovém snímku (vlevo nahoře), budova ve vrstvě nDSM (vpravo nahoře), vyklasifikovaná budova (vlevo dole), budova na aktuálním ortofotu (vpravo dole)*

*Zdroj: šetření autora, software eCognition 8.0, ČÚZK*

## **4.2. Zhodnocení přesnosti klasifikace s využitím vektorové vrstvy**

Pro zhodnocení přesnosti klasifikace byla k dispozici data získaná ruční vektorizací budov a zpevněných povrchů stejných družicových snímků, které byly využity pro klasifikaci. Na základě prostorového překryvu vyklasifikované vrstvy převedené do vektorové podoby a vektorové vrstvy vzniklé manuální vektorizací byly vytvořeny dva mapové výstupy hodnotící přesnost klasifikace budov a zpevněných povrchů. Každý mapový výstup obsahuje tři třídy – třídu zachycující místa, kde se obě vrstvy překrývají a tudíž se výsledek klasifikace shoduje s výsledkem ruční vektorizace (překryv). Další třídou jsou místa, kde byla daná kategorie vyklasifikována, ale nebyla potvrzena manuální vektorizací (klasifikace) a poslední třída zahrnuje místa, kde byla daná kategorie zachycena ruční vektorizací, ale nebyla vyklasifikována (kontrolní vrstva). Kontrolní vrstva budov vznikla sloučením dvou kategorií zástavby a to budovy rezidenční zástavby (rodinné domy, bytovky, řadové domy) a budovy

komerční zástavby (obchodní domy, sklady, logistické areály, průmyslové a zemědělské komplexy). Kontrolní vrstva zpevněných povrchů vznikla sloučením vrstev umělé účelové plochy (parkoviště, manipulační plochy) a komunikace (silniční a železniční síť s okolím včetně čerpacích stanic a křižovatek, přístavy, letiště s umělým povrchem).

Výsledné mapové výstupy hodnocení přesnosti klasifikace jsou na obr. 33 a 34 a v přílohách č.5.1 a č. 5.2. Při pohledu na obr. 33 vyplývá, že bylo s využitím objektově orientovaného přístupu vyklasifikováno více budov než se nachází v kontrolní vektorové vrstvě. Na mapě jsou tyto budovy znázorněny růžovou barvou. Na základě aktuálního ortofota bylo ověřeno, že všechny takto vyklasifikované objekty jsou budovy. Jedná se především o nově vystavěné komerční areály, či přístavby stávajících areálů. Důvodem, proč byly tyto budovy vyklasifikovány, byla aktuálnější data leteckého laserového skenování, ze kterých byla vytvořena vrstva nDSM a podle výšky klasifikovány budovy. V době, kdy byla na základě podkladu původního družicového snímku vytvořena kontrolní vektorová vrstva, nebyly dané budovy ještě postaveny (viz. obr. 32). V levé dolní části obr. 33 s hodnocením přesnosti klasifikace byly klasifikovány některé budovy rezidenční zástavby, které však nebyly zahrnuty do hodnocení přesnosti, a to z dvou důvodů, jelikož pro toto území již nebyla k dispozici kontrolní vektorová vrstva a zároveň proto, že rezidenční zástavba nepatří do komerční suburbanizace a nebyla tedy hlavním cílem klasifikace.

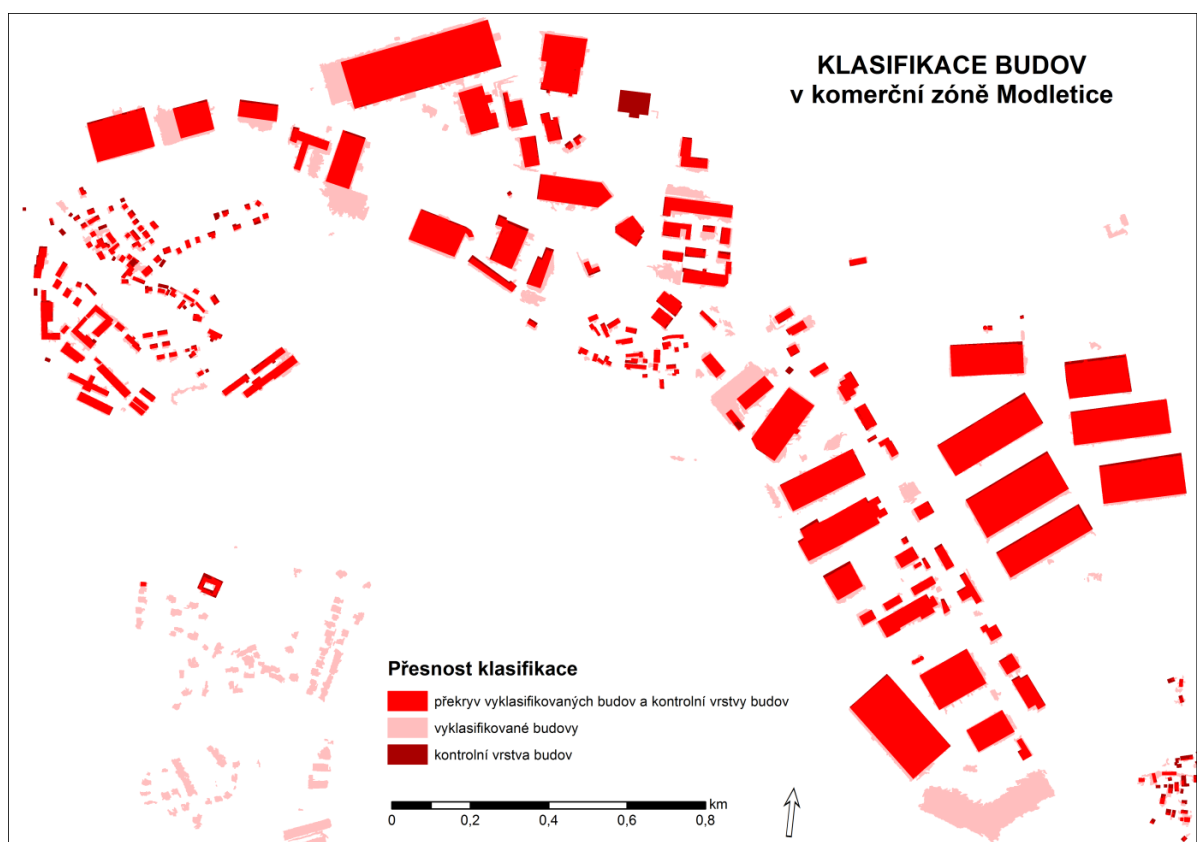
Opačná situace, kdy se budova nacházela v kontrolní vektorové vrstvě, ale nebyla vyklasifikována, nastala v modelovém území Modletice pouze v jednom případě. K tomuto případu došlo proto, že budova chyběla v mračně bodů z leteckého laserového skenování a nemohla být proto klasifikována na základě své výšky. Tomuto problému bylo věnováno více prostoru při hodnocení klasifikační báze v modelovém území Jirny. Na základě vizuálního porovnání družicového snímku a výsledné klasifikace lze říci, že se podařilo vyklasifikovat všechny budovy v modelovém území Modletice.





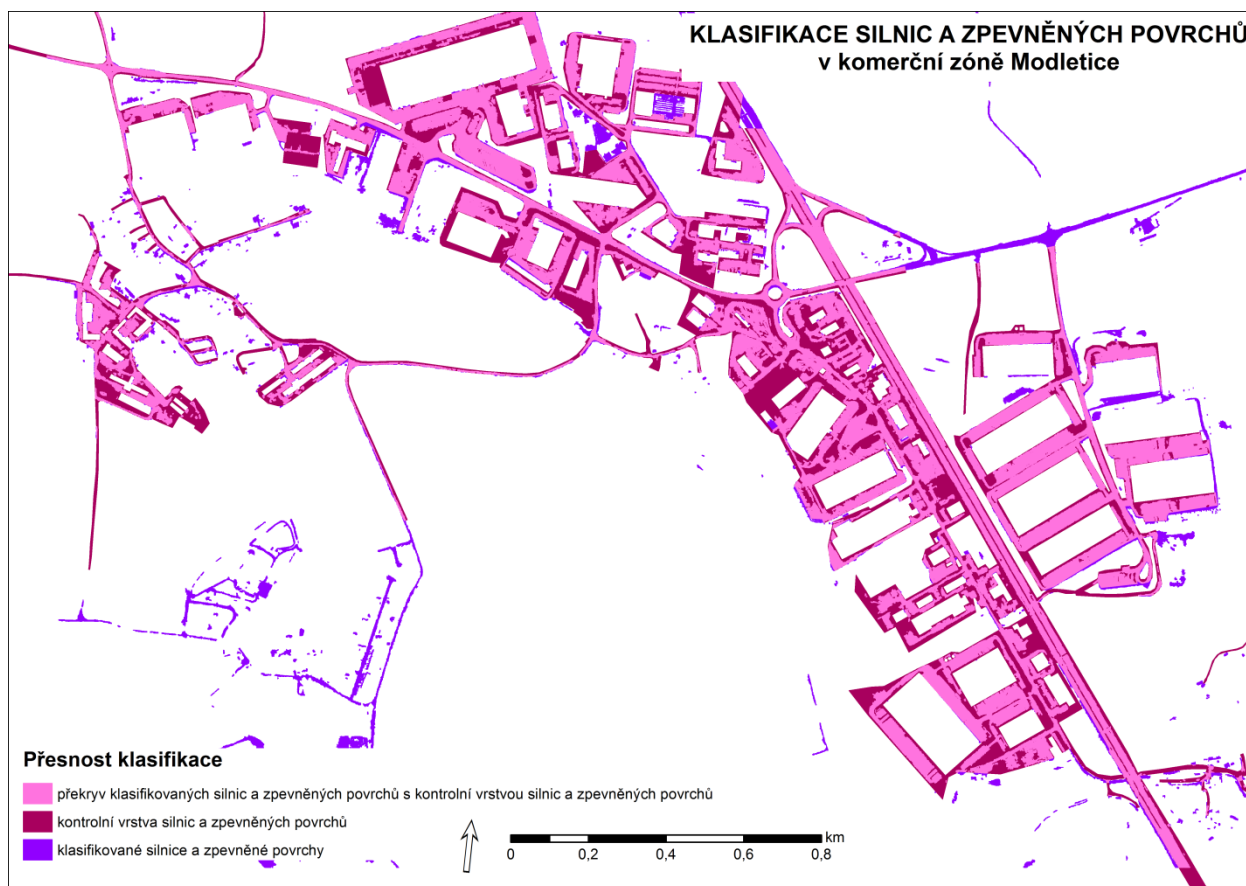
*Obr. 32: Družicový snímek modelového území Modletice*

*Zdroj: šetření autora, software ArcMap*



*Obr. 33: Hodnocení přesnosti klasifikace budov v modelovém území Modletice*

*Zdroj: šetření autora, software ArcMap*




**Obr. 34: Hodnocení přesnosti klasifikace zpevněných povrchů v modelovém území Modletice**

**Zdroj: šetření autora, software ArcMap**

Na dalším mapovém výstupu na obr. 34 byla hodnocena přesnost klasifikace silnic a zpevněných povrchů pro jednotlivé vrstvy. Z mapového výstupu je patrné, že se nepodařilo vyklasifikovat všechny zpevněné povrchy. Nepřesnosti mohly vzniknout z několika důvodů. Jednak proto, že docházelo při klasifikaci k záměnám mezi třídou „zpevněné povrchy“ a „holá půda“, dále proto, že definice kategorie „zpevněné povrchy“ v kontrolní vektorové vrstvě a ve výstupu klasifikace nebyla zcela identická. Jedním z dalších možných důvodů je to, že kontrolní vektorová vrstva zpevněných povrchů vznikla v době, kdy se tam opravdu zpevněné povrchy nacházely, avšak v klasifikované vrstvě již na daném místě byla budova. Proto nebylo možné daný objekt klasifikovat jako zpevněný povrch, protože byl již klasifikován jako budova na základě výšky z časově aktuálnějšího nDSM. Nepřesnosti vznikly jistě i proto, že nebyly vyklasifikovány některé silnice a místní komunikace, zatímco v kontrolní vrstvě byla jejich vektorizace provedena bezezbytku. V tomto případě se ukázalo, že kontrolní vektorová vrstva není pro zhodnocení přesnosti klasifikace úplně použitelná. Z výše uvedených důvodů, a především z důvodu časové rozdílnosti kontrolní vektorové vrstvy a výškových dat, nebylo možné vypočítat procentuální úspěšnost klasifikace zpevněných povrchů. Určení procentuální úspěšnosti by vyžadovalo vzít každou plochu, kterou se nepodařilo vyklasifikovat a určit, který z výše uvedených důvodů zapříčinil to, že plocha nebyla správně klasifikována.

### 4.3. Ověření přenositelnosti klasifikační báze

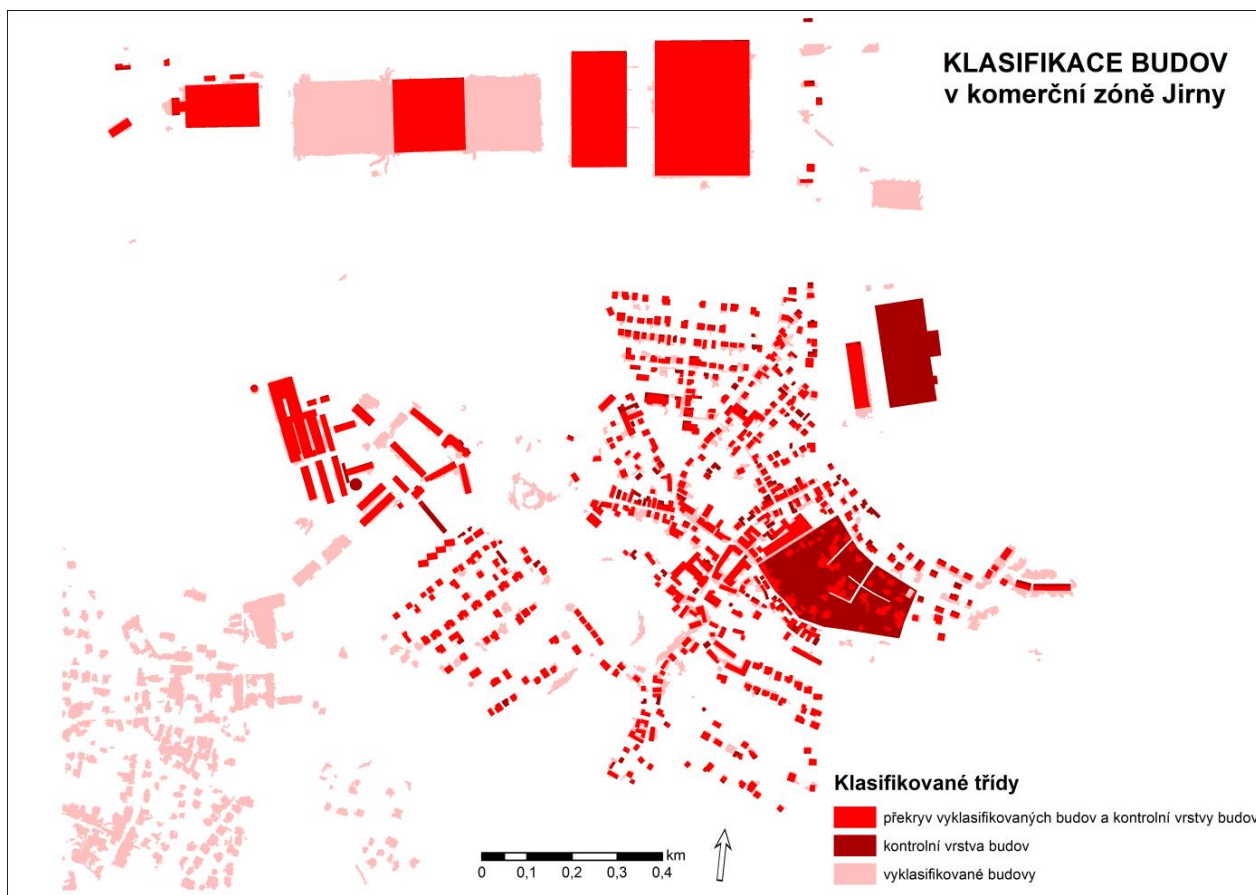
Jedním z cílů práce bylo ověření využitelnosti vytvořené klasifikační báze pro další snímky. Báze byla vytvořena na výřezu snímku zachycující oblast Modletice. Modelovou oblastí, na které byla přenositelnost klasifikační báze testována, byly Jirny. V obou případech byly použity družicové snímky ze senzoru QuickBird. K objektově orientované klasifikaci komerční suburbanizace v oblasti Jirny byl opět využit software eCognition 8.0 a stejná klasifikační báze. Jak je patrné z obr. 35 a z přílohy č. 4.2, výsledek podrobné klasifikace je poměrně uspokojivý. Nepřesnosti se objevily u klasifikace tříd „holá pole“ a „silnice a zpevněné povrchy“, kdy docházelo k záměnám mezi jednotlivými třídami. Také se nepodařilo s dostatečnou přesností vyklasifikovat dálnice. Při aplikaci klasifikační báze se stejnými prahovými hodnotami docházelo u některých tříd k tomu, že pro danou prahovou hodnotu v daném snímku nebyly vyklasifikovány žádné segmenty. K této situaci došlo například v případě použití příznaku Brightness při klasifikace třídy „vodní plochy“. To mohlo být způsobeno několika důvody, které byly tématem diskuze. Upravený tematický výstup zpracovaný na základě podrobné klasifikace bez rozlišení typů střech a ostatních zpevněných ploch je v příloze č. 5.8.






***Obrázek 35: Výsledek objektově orientované klasifikace Jirny s použitím klasifikační báze připravené pro modelové území Modletice (nahore), družicový snímek modelového území Jirny (dole)  
Zdroj: šetření autora, software eCognition 8.0***

Přenositelnost klasifikační báze byla hodnocena na základě mapových výstupů na obr. 36 a obr. 38. Na mapovém výstupu na obr. 36 je hodnocena přesnost klasifikace budov s využitím klasifikační báze vytvořené pro modelové území Modletice. Dle vizuálního hodnocení byly vyklasifikovány všechny budovy v modelovém území Jirny. I v tomto případě byla kontrolní vektorová data starší než výšková data a stejně jako tomu bylo v modelovém území Modletice, byly vyklasifikovány budovy (na mapovém výstupu byly označeny růžovou barvou), které v kontrolní vektorové vrstvě chyběly. Proto i důvody, které danou situaci vysvětlují, jsou totožné s důvody uvedenými výše pro modelové území Modletice. I zde došlo při klasifikaci k případu, kdy se budova nacházela v kontrolní vrstvě, ale nebyla vyklasifikována. Tento případ nastal v modelovém území Jirny v jednom případě. Při pohledu na obr. 37 (modře zakroužkováná oblast) byla objevena zjevná chyba v atributové tabulce kontrolní vektorové vrstvy, kdy byly chybně označeny třídy klasifikace a klasifikované zahrady byly označeny jako budovy. V levé dolní části obr. 36 byla opět vyklasifikována rezidenční zástavba, která nebyla zahrnuta do hodnocení přesnosti ze stejných důvodů jako v modelovém území Jirny. Přenositelnost klasifikační báze pro extrakci budov byla výborná.



*Obr.36: Hodnocení přesnosti klasifikace budov v modelovém území Jirny*

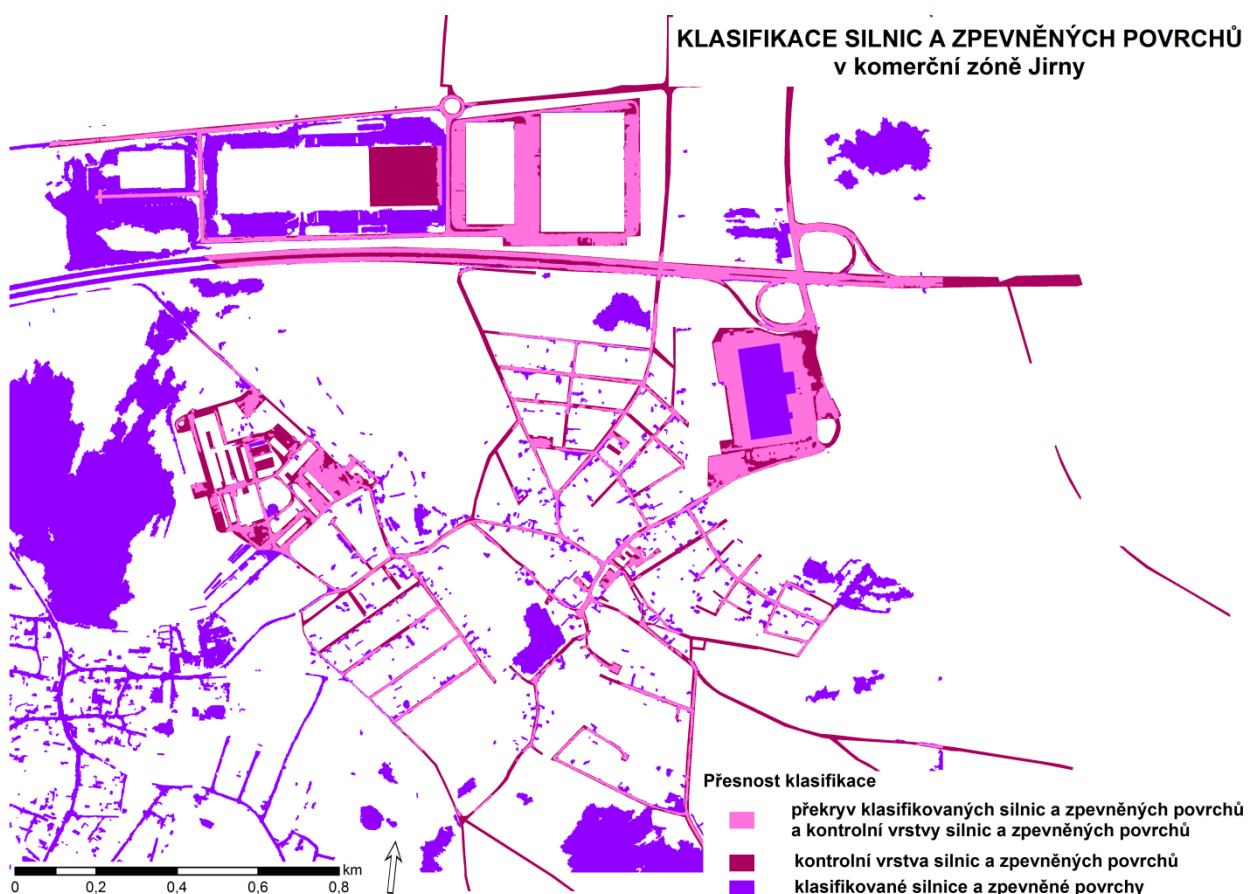
*Zdroj: šetření autora, software ArcMap*



*Obr.37 Chybně klasifikované budovy v kontrolní vektorové vrstvě modelového území Jirny*

*Zdroj: šetření autora, software ArcMap*


Na obr. 38 byla zhodnocena přesnost klasifikace silnic a zpevněných povrchů. Při aplikaci klasifikační báze docházelo k záměnám mezi třídou „holá pole“ a třídou „silnice a zpevněné povrchy“. Holá pole byla místy chybně klasifikována jako silnice a zpevněné povrchy. Při vizuálním hodnocení bylo zjištěno, že v kontrolní vrstvě byly zpevněné povrchy jako jsou parkoviště či nakládací plochy v okolí komerčních budov přiřazeny do třídy obnažené povrchy (sklárky, haldy, oblasti těžby). Právě odlišení obnažených holých povrchů bylo v průběhu klasifikace značný problém. Chyby v klasifikaci byly větší, než při klasifikaci v modelovém území Jirny a došlo k překlasifikování zpevněných povrchů. Přenositelnost klasifikační báze tedy nebyla bez problémů, a to především proto, že se v modelovém území Modletice tyto obnažené povrchy prakticky nevyskytovaly. Avšak v modelovém území Jirny byly odkryté holé povrchy častým jevem. Tento aspekt byl hlavním důvodem zhoršení přesnosti přenositelnosti klasifikační báze pro extrakci zpevněných povrchů. Jelikož byl pro zpracování kontrolních vektorových vrstev pro modelová území vždy jiný autor, může se lišit také zařazení do jednotlivých tříd klasifikace, z toho důvodu bylo možné využít kontrolní vrstvy pouze do určité míry.



**Obr.38: Hodnocení přesnosti klasifikace zpevněných povrchů v modelovém území Jirny**

**Zdroj: šetření autora, software ArcMap**

V následujícím kroku bylo přistoupeno k úpravě klasifikační báze, aby bylo dosaženo lepších výsledků a nedocházelo k záměně mezi jednotlivými třídami. První změnou byla modifikace měřítkového parametru multiměřítkové segmentace z hodnoty 28 na hodnotu 25. Dále se úpravy týkaly především posunutí prahových hodnot a také reorganizaci pořadí aplikace jednotlivých klasifikačních pravidel. Ukázalo se, že roli hraje i to, zda jsou jako první klasifikovány například silnice a zpevněné povrchy a potom holá pole, nebo obráceně. Upravená klasifikační báze je v příloze č. 3.2. Původní klasifikační bázi lze hodnotit jako použitelnou, je možné z ní vycházet při klasifikaci jiných družicových snímků, pouze s mírnou úpravou prahových hodnot některých příznaků. Výsledek podrobné klasifikace s využitím upravené klasifikační báze je na obr. 39 a v příloze č. 4.3. . Upravený tematický výstup zpracovaný na základě podrobné klasifikace bez rozlišení typů střech a ostatních zpevněných ploch je v příloze č. 5.9.

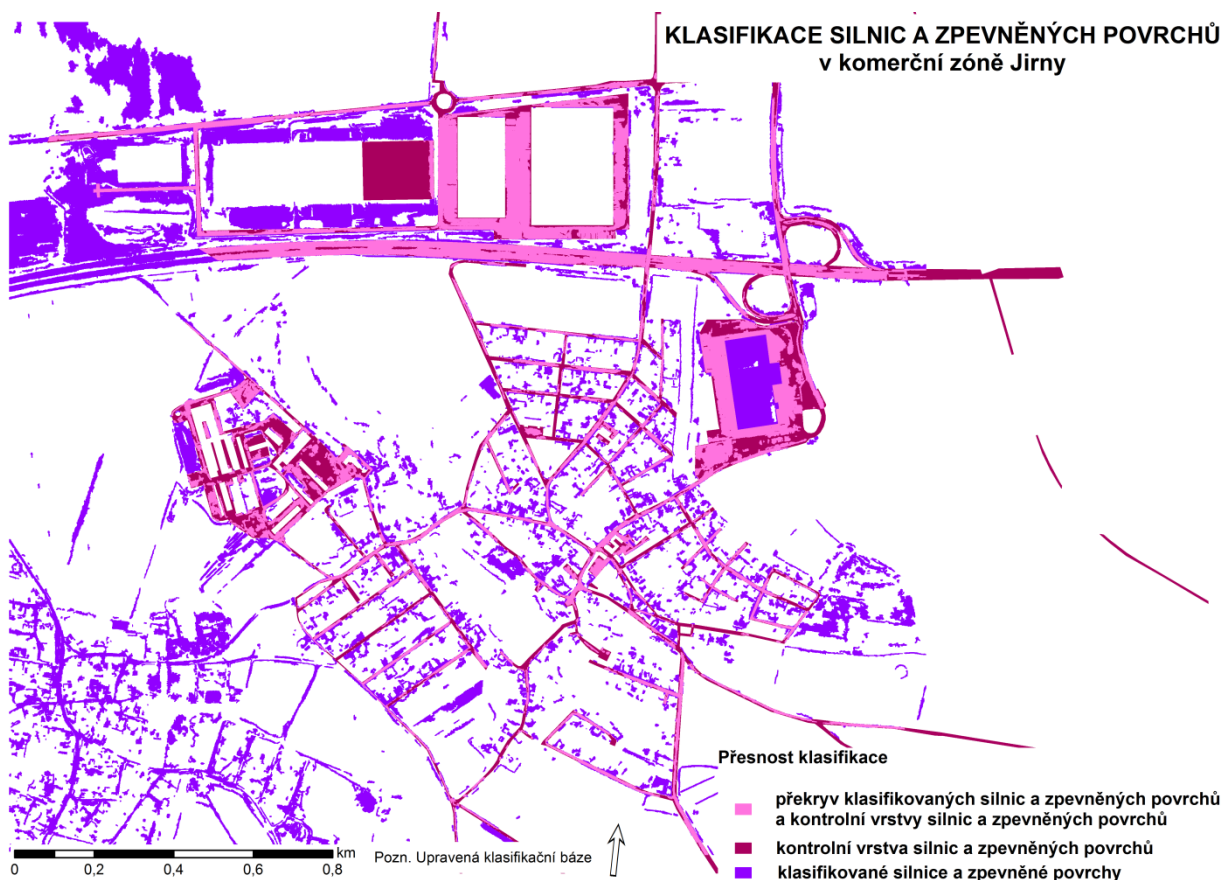


**Obrázek 39: Výsledek klasifikace s upravenou klasifikační bází pro modelové území Jirny**

**Zdroj: šetření autora, software eCognition 8.0**

Hodnocení přesnosti extrakce budov s využitím upravené klasifikační báze bylo prezentováno v mapovém výstupu v příloze č. 5.5 I přestože došlo k úpravě klasifikační báze, pro extrakci budov byl využit stejný přístup jako v původní klasifikační bázi. Jelikož byly výsledky klasifikace budov s využitím původní klasifikační báze výborné, nebylo třeba upravovat klasifikační pravidlo pro extrakci budov. Výsledky klasifikace budov byly tedy prakticky totožné jako při aplikaci původní klasifikační báze. Proto se k příloze 5.5 vztahuje stejný

komentář jako u obr. 36 a obr. 37. Minimální a zanedbatelné změny vznikly pouze z důvodu jiné hodnoty měřítkového parametru multiměřítkové segmentace.



**Obr.40: Hodnocení přesnosti klasifikace zpevněných povrchů s upravenou klasifikační bází v modelovém území Jirny**

**Zdroj: šetření autora, software ArcMap**

Na obr. 40 byla hodnocena přesnost klasifikace silnic a zpevněných povrchů s využitím upravené klasifikační báze. Z výsledků vyplývá, že došlo ke snížení počtu chybně klasifikovaných ploch třídy „holá pole“ do třídy „silnice a zpevněné povrchy“. V modelovém území Jirny byl značně složitý terén s kompaktnější rezidenční zástavbou, takže při klasifikaci zpevněných povrchů s využitím upravené klasifikační báze došlo ke zlepšení přesnosti klasifikace zpevněných povrchů v komerční zóně, ale naopak ke zhoršení v oblastech s rezidenční zástavbou. Přesto i zde byly zřejmé poměrně velké rozdíly mezi klasifikovanou vrstvou a kontrolní vrstvou. Vymezení a odlišení obnažených povrchů se ukázalo jako značný problém.




Jak již bylo zmíněno výše chybí v kontrolní vrstvě některé zpevněné povrchy jako jsou parkoviště atd. Tyto povrchy byly v kontrolní vrstvě chybně zařazeny do třídy obnažené povrchy (skládky, hlady, oblasti těžby). Při vizuálním a statistickém hodnocení byla objevena chyba v klasifikaci u areálu v komerční zóně. U tohoto areálu chybí informace o výšce a nebylo možné ho proto na základě klasifikačního pravidla přiřadit do třídy „budovy“. Tento předpoklad byl ověřen prostudováním mračna bodů z leteckého laserového skenování. Na základě spektrálních příznaků byl tento areál klasifikován jako zpevněný povrch, což ovlivnilo přesnost klasifikace jak budov, tak zpevněných povrchů. Tomuto problému se věnuje následující text včetně obrazové ukázky.

Stejně jako tomu bylo při vizuálním hodnocení klasifikace Modletic, v modelovém území Jirny se vyskytlo několik případů, kdy budovy klasifikované na základě výšky z vrstvy nDSM se však na družicovém snímku nevyskytovaly. Opět bylo provedeno porovnání družicového snímku, vrstvy nDSM a aktuálního ortofota, na kterém je již objekt postaven viz. příloha č. 6.1. (zdroj: ČÚZK).

Zvláštním případem však byla opačná situace, kdy ve vrstvě nDSM chyběla výšková informace k budově, která se však v družicovém snímku nacházela. Byla proto provedena kontrola, zda nedošlo k uživatelské chybě při vytváření nDSM,. Tato domněnka byla vyloučena na základě přezkoumání mračna bodů z leteckého laserového skenování, ze kterého je zřejmé, že pro danou budovu opravdu chybí mračno bodů nesoucí informaci o výšce viz. obr. 41. V tomto případě tedy nedošlo ke klasifikování budovy na základě informace o výšce, ale pouze na základě spektrálního příznaku, který budovu přiřadil do třídy „silnice a zpevněné povrchy“.





*Obrázek 41: Místo, kde chyběla data v mračnu bodů pro modelové území Jirny (nahore), místo, kde chyběla data v mračnu bodů pro modelové území Jirny ve výsledku klasifikace, zařazené do třídy zpevněné povrchy (dole)*

*Zdroj: šetření autora, software ArcMap*

## 5. Diskuze

Využití družicových snímků velmi vysokého rozlišení pro objektově orientovanou klasifikaci budov a zpevněných povrchů nachází v dnešní době čím dál častější uplatnění při monitorování městské zástavby a suburbánních oblastí, pro tvorbu a aktualizaci map městského prostředí (Volpe, Ross 2003), či pro údržbu městských kartografických databází (Hermasillat et. al. 2011). Výsledky diplomové práce dokazují, že použití družicových snímků v kombinaci s výškovými daty pro klasifikaci budov a zpevněných ploch přináší velmi dobré výsledky zejména v případě klasifikace budov a tento postup je možné využít pro monitorování rozšiřování komerční zástavby v suburbánních zónách. Při hodnocení přesnosti klasifikace bylo poukázáno na rozdílnost mezi datem pořízení družicových snímků a daty leteckého laserového skenování, což se projevilo na výsledcích klasifikace. V některých případech byly na základě výškové informace klasifikovány budovy komerční zástavby, ale protože chyběly na družicovém snímku, nebylo je možné zařadit do příslušné třídy na základě jejich spektrálních, texturálních či kontextových příznaků. Jak se ukázalo u výsledku obou klasifikačních bází, došlo k vyklasifikování budov na základě jejich výšky, i přesto, že se tyto budovy na družicovém snímku nenacházely. Je tedy navíc možné sledovat změny, které se v suburbánní zóně udály mezi datem pořízení družicového snímku a výškových dat.

Potvrzení toho, že družicová data velmi vysokého rozlišení v kombinaci s výškovými daty jsou slibným zdrojem dat pro objektově orientovanou klasifikaci a přináší kvalitní výsledky dokládají i další práce. Využití výškových dat pro objektově orientovanou klasifikaci hodnotí pozitivně ve své diplomové práci Kopalová (2007). Ta však využívá DMP (digitální model povrchu) vytvořený v programu SilverEye na základě stínů, které budovy či jiné objekty vrhají. Tento postup nebyl využit z důvodu, že se nejedná o automatickou metodu, a je tedy časově značně náročný. Dalším důvodem je to, že bylo cílem vytvořit nový přístup pro tvorbu nDSM z dat leteckého laserového skenování, který bude možné využít spolu s družicovými snímky pro klasifikaci budov a zpevněných povrchů.

Dinis et. al. (2009) využívá pro klasifikaci hustě osídlených městských oblastí objektově orientovaný přístup s kombinací družicových snímků velmi vysokého prostorového rozlišení a výškových dat Lidar. Autoři upozorňují, že chybné zařazení segmentů s rozdílnou výškou může být způsobeno výškovými nesrovnalostmi mezi DRM a DSM (rozdíl těchto dvou vrstev představuje nDSM) v důsledku velkého časového odstavu mezi pořízením těchto modelů. Aby bylo možné se těmito chybám v klasifikaci vyvarovat, doporučují pořízení pomocných výškových dat ve stejném časovém období. V případě, že to není možné, měl by být časový odstup maximálně 2 roky, zejména pak v městských oblastech, ve kterých dochází k rychlým změnám. Na problémy spojené s využitím DSM při extrakci budov upozorňují Jiang et. al. (2008). Výsledky extrakce budov nejsou přesné v případě, že je území příliš velké nebo terén není rovný. Jako řešení navrhují využití nDSM. Syed et. al. (2005) považují kombinaci družicových snímků vysokého rozlišení a dat LIDAR za velice efektivní. Ke klasifikaci

využívají jako zdroj výškové informace nDSM a spektrální klasifikaci nejbližšího souseda a pro určité třídy využívají fuzzy funkci příslušnosti. Tento přístup nebyl nakonec při zpracování diplomové práce využit, jelikož docházelo k chybnému zařazení segmentů do tříd. Proto byl zvolen přístup prahování, který využívají i autoři software eCognition v jejich klasifikačním návodu eCognition User guide (2010). Objektově orientovaný přístup ke klasifikaci s využitím prahování využívá Hermossilat (2011) a poukazuje na dosažení lepších výsledků zvláště v příměstských oblastech.

Převážná většina autorů Aldred (2007), Harayama (2004), Marangoz (2010), Syed (2005), Binard (2005) atd. volí jako první krok objektově orientované klasifikace multiměřítkovou segmentaci. Někteří autoři považují za klíčový proces objektově orientované klasifikace segmentaci a především nastavení parametrů. Z vytvořených segmentů totiž vychází další klasifikační postup. Například Marangoz et. al. (2010) uvádějí, že při procesu segmentace by měly být parametry nastaveny co nejpřesněji, aby segmenty co nejvíce odpovídaly realitě. A to z toho důvodu, že fáze segmentace je přímo následována klasifikací. Proto autoři vyzkoušeli několik měřítkových parametrů, dokud nenašli ten nejvhodnější pro jejich klasifikaci. I tvůrci software eCognition doporučují experimentovat a otestovat několik variant nastavení měřítkového parametru. Stejný postup navrhuje i Harayama (2004), Uvádí, že je důležité experimentovat s měřítkovým parametrem a s příslušnými vahami barvy a tvaru, dokud nejsou nalezeny parametry, které se nejlépe hodí pro snímek. Dle autorů právě tyto parametry ovlivňují výsledek klasifikace. Na základě těchto poznatků byla pro rozdělení obrazu do relativně homogenních objektů zvolena multiměřítková segmentace s hodnotou měřítkového parametru 28 pro modelové území Modletice. Nastavení měřítkového parametru bylo určeno po několika experimentálních pokusech. Při modifikaci klasifikační báze pro modelové území Jirny bylo nutné hodnotu měřítkového parametru přizpůsobit danému družicovému snímku a byla zvolena hodnota měřítkového parametru 25.

Klasifikační návod tzv. User Guide – Simple building extraction od autorů software eCognition (2010) obsahuje podrobný a přesný návod včetně konkrétních příznaků a prahových hodnot pro objektově orientovanou klasifikaci budov s využitím družicových snímků a elevačních dat. Při zkoušení daného postupu došlo u některých klasifikačních pravidel k chybnému zařazení segmentů do tříd např. budova byla zařazena do třídy vegetace. I přestože laboratorně vytvořený postup obsahuje některé užitečné informace, nelze ho vždy úplně aplikovat pro každou datovou sadu. Pro proces objektově orientované klasifikace a extrakce budov od okolních ploch byla v této práci klíčovým příznakem informace o výšce. Pro odklasifikování stromů, které byly na základě své výšky chybně zařazeny do třídy budovy, byl zvolen poměrový index NDVI. Totožný přístup pro klasifikaci budov s využitím DSM aplikují autoři Jiang et. al. (2008). Pro odklasifikování stromů z třídy „budovy“ však zvolili poměrový index Ratio Green/Ratio Red, i přestože považují poměrový index NDVI za vhodnější. K tomuto postupu je vedla chybějící informace ze spektrálního pásma NIR.

Využití kontextových informací při objektivě orientované klasifikaci vyzdvihují Syed et. al. (2005), konkrétně funkce „vzdálenost k“ (distance to) a „relativní hranice s“ (relative border to). Stejná strategie byla využita i při zpracování této práce pro získání přesnějších tvarů budov a pro zařazení neklasifikovaných segmentů uvnitř plochy určité třídy. Dinis et. al. (2009) patří mezi další autory aplikující během procesu klasifikace kontextové příznaky.

Při klasifikaci docházelo k občasným záměnám mezi třídami „holá pole“ a „silnice a zpevněné povrchy“ obzvláště pak u výřezu snímku Jirny. Zásadní roli přitom hrají nejspíše podobné spektrální charakteristiky. Poměrový index Ratio Geen byl klíčovým příznakem pro klasifikaci třídy „silnice a zpevněné povrchy“. Chybné zařazení do třídy „holá pole“ se podařilo částečně eliminovat na základě tvarových příznaků Length/Width, které charakterizovaly silnice.

Z map a tabulek hodnotících přesnost klasifikace pro modelové území Jirny je patrné, že bylo vyklasifikováno více zpevněných povrchů a silnic, než jich obsahuje kontrolní vrstva. Možným důvodem je to, že tyto plochy byly při vektorizaci zařazeny do kategorie obnažené povrchy obsahující haldy, skládky a oblasti těžby. Právě odlišení obnažených povrchů se ukázalo při klasifikaci jako problematické, jelikož jsou tyto povrchy značně heterogenní. Při vizuální kontrole se jeví jako méně pravděpodobné to, že by při klasifikaci byly do této kategorie řazeny z větší části i plochy, které tam nepatří. Hlavním důvodem toho, proč se na mapě hodnotící přesnost klasifikace budov vyskytuje více vyklasifikovaných budov oproti kontrolní vrstvě, je pozdější termín pořízení výškových dat a tedy přítomnost většího počtu budov v těchto datech. Problém by bylo možné řešit pravděpodobně následným doklasifikováním každé této budovy tím, že se jí manuálně změní atribut a bude přiřazena do správné třídy. Po odečtení rozlohy takto klasifikovaných budov se ukázalo, že přesnost klasifikace byla ve skutečnosti vyšší.

Pro klasifikaci modelového území Jirny byla nejdříve využita klasifikační báze vytvořená pro modelové území Modletice. Poté byla klasifikační báze upravena, aby byly lépe vyklasifikovány některé třídy. Při porovnání klasifikace budov mezi oběma bázemi se ukazuje, že výsledek je prakticky stejný s výbornými výsledky. Drobné změny, které je možné sledovat v přílohách, byly pravděpodobně způsobeny jiným měřítkovým parametrem u multiměřítkové segmentace. Jinak obě báze vycházejí ze stejných výškových dat a stejných pravidel pro klasifikaci budov. Při podrobnější klasifikaci typů střech jednotlivých budov je již zapotřebí úprava prahových hodnot klasifikační báze oproti původní bázi. Při aplikaci klasifikačního pravidla docházelo u několika tříd k situaci, že dané prahové hodnotě neodpovídal žádný segment určený ke klasifikaci. Tento problém se podařilo vyřešit posunutím prahové hodnoty, kdy již segmenty, určené ke klasifikaci, bylo možné přiřadit do požadované třídy. Lepšího výsledku by s největší pravděpodobností bylo dosaženo, kdyby snímky byly vůči sobě normalizovány.

Zásadní při klasifikaci bylo to, že výšková data nejsou ze stejného roku jako družicové snímky. Tato časová disproporce způsobila chyby v klasifikaci (budovy byly klasifikovány

i tam, kde se ve snímku ve skutečnosti nevyskytovaly). Vzhledem k jinému stavu – počtu budov v nDSM a na snímku byla použitelnost kontrolních vektorových vrstev pro hodnocení přesnosti klasifikace omezená (tyto vrstvy na zpracovány na podkladu družicových dat a tudíž také nezachycovaly aktuální stav jako na nDSM). Proto byly tyto vrstvy nakonec použity pouze k orientačnímu zhodnocení přesnosti (mapy překryvů vrstev klasifikace a kontrolních vrstev) a přesnost klasifikace nemohla být vyčíslena procentuálně. Lze ale říci, že úspěšnost klasifikace v případě budov byla alespoň co do počtu velice úspěšná (hodnoceno na základě vizuálně porovnáním vyklasifikované vrstvy a původního snímku. Na základě vizuálního porovnání klasifikace (i map překryvů) a původního snímku lze ale říci, že se podařilo vyklasifikovat prakticky všechny budovy komerční suburbanizace ve sledovaných modelových územích.

Pozorovaný jev, že výsledky klasifikace mohou být zkresleny výškovými daty, potvrzuje například studie Dinis et. al. (2009), která říká, že by výšková data měla být pokud možno ze stejného roku jako družicový snímek. To platí zvláště v místech suburbánních zón, kde se odehrávají změny velmi rychle. Pro tuto diplomovou práci byly k dispozici družicové snímky, které byly pořízeny o 3 roky dříve než výšková data. Během této doby došlo v suburbánních zónách ke značným změnám zejména z hlediska výstavby komerčních areálů. Na základě těchto poznatků lze do budoucna doporučit v případě plánovaného leteckého laserového skenování území současně nasnímat sledovanou lokalitu družicovými senzory.

Navržený postup pro klasifikaci budov a zpevněných povrchů vede k velmi dobrým výsledkům zejména v případě klasifikace budov. Ke zvýšení přesnosti klasifikace by dále mohlo vést vyřazení budov, které se nevyskytují na družicovém snímku a byly klasifikovány na základě výškových dat. V případě, že by se odečetla jejich rozloha, přesnost klasifikace by byla ještě vyšší. Theo, Chen (2004) s využitím objektově orientované klasifikace a výškových dat extrahovali budovy s přesností 85%.

## 6. Závěr

Cílem této diplomové práce bylo navržení metodického postupu pro automatickou extrakci budov a zpevněných povrchů z dat velmi vysokého rozlišení v komerční zóně Prahy. Mezi dílčími úkoly bylo zpracování přehledu stávajících využitelných metodách pro klasifikaci budov a zpevněných povrchů, ověření přenositelnosti vytvořené klasifikační báze na jiné snímky velmi vysokého rozlišení a zhodnocení přesnosti klasifikace s využitím dat získaných ruční vektorizací budov a zpevněných povrchů.

Práce se v úvodu věnuje rešerši literatury a podává přehled a porovnáním používaných metod pro extrakci budov a zpevněných povrchů především se zaměřením na objektově orientovaný přístup ke klasifikaci. Prostor je věnován také problematice objektově orientované klasifikace s využitím výškových dat. Hlavní a stěžejní část diplomové práce se věnuje tvorbě nDSM v software ArcMap 10 a sestavení klasifikační báze pro extrakci budov a zpevněných povrchů s využitím software eCognition 8.0. Klasifikační postup byl postaven na dvou základních krocích. Nejprve byl obraz rozdělen do segmentů s využitím multiměřítkové segmentace na základě nalezení vhodných parametrů a poté byl obraz klasifikován do požadovaných tříd na základě vlastních vytvořených pravidel a určených prahových hodnot jednotlivých příznaků.

Navržená klasifikační báze byla aplikována na družicový snímek velmi vysokého rozlišení jiného modelového území, aby byla ověřena její přenositelnost a využitelnost na jiné družicové snímky a území. Dle výsledků je vytvořená klasifikační báze do značné míry využitelná pro jiné družicové snímky. Významným výsledkem je zjištění, že pro přesnější klasifikaci budov je možné použít původní bázi prakticky bez úprav. Potvrdil se předpoklad, že pro přesnější klasifikaci zpevněných ploch a také rozlišení některých typů střech budou v případě použití klasifikační báze pro jiné území nutné mírné úpravy prahových hodnot některých použitých klasifikačních příznaků. Možnosti přenositelnosti klasifikačníchází by se měly zlepšit v případě, že by byla provedena normalizace spekter použitých snímků, což lze do budoucna doporučit.

Další předpoklad, že některé zpevněné povrchy mají stejný charakter jako holé povrchy a nepodaří se je přesně klasifikovat, byl také potvrzen. Při klasifikaci jak v případě modelového území Modletice, tak v případě modelového území Jirny docházelo k záměnám mezi třídou „holá pole“ a třídou „silnice a zpevněné povrchy“, jelikož tyto třídy mají podobný charakter z hlediska spektrálních charakteristiky. Jako problematické se ukázalo odlišení obnažených povrchů v procesu klasifikace. Navržení klasifikačního postupu pro extrakci těchto odkrytých povrchů by mohlo být námětem pro další studie. V případě modelového území Modletice se podařilo klasifikovat silnice a zpevněné povrchy s uspokojivými výsledky, které jsou dostačující pro aktualizaci informací o rozvoji komerční suburbanizace. Zejména v případě klasifikace budov bylo dosaženo výborných výsledků a to jak v modelovém území Modletice,

tak i v modelovém území Jirny.

Lze tedy shrnout, že v práci se podařilo navrhnout účinný postup klasifikace budov a zpevněných ploch ve vybraných oblastech komerční suburbanizace použitelný v obecné rovině do značné míry i pro jiná území. Přesnost navržené metody objektově orientované klasifikace s využitím informace o výšce z vytvořené nDSM byla zhodnocena s použitím kontrolní vrstvy vzniklé ruční vektorizací budov a zpevněných povrchů a potvrzuje, že vytvořený klasifikační postup přináší výborné výsledky pro klasifikaci budov a uspokojivé výsledky pro extrakci zpevněných povrchů. Potvrdilo se, že využití nDSM v kombinaci s družicovými daty velmi vysokého rozlišení jsou velmi silným nástrojem pro účely klasifikace heterogenního území zón komerční suburbanizace a budou jistě pro tyto účely v budoucnu využívána.



## SEZNAM ZDROJŮ INFORMACÍ

- ALDRED, D.; WANG, J. 2007. *Object – oriented image classification for urban building boundary extraction from Ikonos imagery* [online]. ASPRS The Imaging & Geospatial Information Society [cit. 2011-5-15]. Dostupné z URL:  
< [https://docs.google.com/viewer?url=http://www.asprs.org/conference-archive/ottawa07/ottawa\\_proceedings/1.pdf&pli=1](https://docs.google.com/viewer?url=http://www.asprs.org/conference-archive/ottawa07/ottawa_proceedings/1.pdf&pli=1)>
- BAATZ, M. ... [et al.] 2004. *eCognition Elements 4 User Guide* [online]. Copyright 2000-2005 © Definiens [cit. 2011-1-5]. Dostupné z URL:  
< <http://www.gis.unbc.ca/help/software/ecognition4/ELuserguide.pdf>>
- BAATZ, M.; SCHÄPE, A. 2000. *Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation*[online] [cit. 2011-1-7]. Dostupné z URL:  
< [http://www.ecognition.com/sites/default/files/405\\_baatz\\_fp\\_12.pdf](http://www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf)>
- BARTÁK, V. 2008. *Algoritmy pro zpracování digitálních modelů terénu s aplikacemi v hydrologickém modelování*[rukopis]. Diplomová práce na fakultě životního prostředí České zemědělské univerzity v Praze. Vedoucí diplomové práce Petr Máca
- BAUER, M.E.; YUAN, F. 2006. *Mapping impervious surface area using resolution imagery: A comparison of object-based and per pixel classification* [online]. ASPRS The Imaging & Geospatial Information Society [cit. 2011-6-9]. Dostupné z URL:  
<[https://docs.google.com/viewer?url=http%3A%2F%2Fwww.ecognition.com%2Fsites%2Fdefault%2Ffiles%2F184\\_asprs2006\\_0178.pdf](https://docs.google.com/viewer?url=http%3A%2F%2Fwww.ecognition.com%2Fsites%2Fdefault%2Ffiles%2F184_asprs2006_0178.pdf)>
- BENZ, U.C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. 2004. *Multi-resolution object-oriented fuzzy analysis of remote sensing data for GIS-ready information* [online]. ISPRS J. Photogrammetry and Remote Sensing, 58:239-258. [cit. 2011-6-9]
- BLASCHKE, T. 2010. *Object based image analysis for remote sensing* [online]. ISPRS Journal of Photogrammetry and Remote Sensing [cit. 2011-1-21]. Dostupné z URL:  
< [https://docs.google.com/viewer?url=http%3A%2F%2Fspace.researchstudio.at%2Fdownloads%2F2010%2FObia\\_ISPRS\\_2010\\_Blaschke.pdf](https://docs.google.com/viewer?url=http%3A%2F%2Fspace.researchstudio.at%2Fdownloads%2F2010%2FObia_ISPRS_2010_Blaschke.pdf)>
- BERKOVÁ, V. 2009. *Program eCognition pro klasifikaci urbanizovaného území z družicových snímků SPOT* [online]. Katedra mapování a kartografie, Fakulta stavební, ČVUT [cit. 2011-1-5]. Dostupné z URL:  
< [http://gis.vsb.cz/GIS\\_Ostrava/GIS\\_Ova\\_2009/sbornik/Lists/Papers/043.pdf](http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2009/sbornik/Lists/Papers/043.pdf)>

- BINARD, M. ...[et al.] 2005. *Extraction of Land Use/Land Cover – Related Information from Very High Resolution Data in Urban and Suburban Areas*[online]. Vrije Universiteit Brussel [cit. 2011-1-5]. Dostupné z URL:  
< <http://www.vub.ac.be/spider/publications/paper-earsel-2003.pdf>>
- BROMOVÁ, P. 2010. *Hodnocení suburbanizace v zázemí Prahy vliv na využití krajiny a funkci území*[rukopis]. Bakalářská práce na Přírodovědecké fakultě Univerzity Karlovy na katedře aplikované geoinformatiky a kartografie. Vedoucí diplomové práce Lucie Kupková
- CARLEER, A.; DEBEIR, O.; WOLFF, E. 2004. *Comparison of very high spatial resolution satellite image segmentations*[online]. Image and Signal Processing for Remote Sensing IX. [cit. 2011-1-8]. Dostupné z URL:  
< [http://docs.google.com/viewer?a=v&q=cache:Qjyf5a1KmSMJ:citeseerx.ist.psu.edu/viewdoc/download%3Fdoi%3D10.1.1.91.1163%26rep%3Drep1%26type%3Dpdf+comparison+of+very+high+spatial+resolution+satellite+image+segmentation&hl=cs&gl=cz&pid=bl&srcid=ADGEESgy3UXHojIPJVRtwTN19Y2OArDMegmejog-PeFSQK31yxaKf6lDdnKYvreoNpmimlNgv2EJC0xQ75QmnlL2MHD-P8HODbftSavRkTPQQV1YSPH2r5\\_\\_wXPhrI\\_RYI0gxewtWrGB&sig=AHIEtbRwlsQDP M\\_BPV0wpNu-h1eeWtTadA](http://docs.google.com/viewer?a=v&q=cache:Qjyf5a1KmSMJ:citeseerx.ist.psu.edu/viewdoc/download%3Fdoi%3D10.1.1.91.1163%26rep%3Drep1%26type%3Dpdf+comparison+of+very+high+spatial+resolution+satellite+image+segmentation&hl=cs&gl=cz&pid=bl&srcid=ADGEESgy3UXHojIPJVRtwTN19Y2OArDMegmejog-PeFSQK31yxaKf6lDdnKYvreoNpmimlNgv2EJC0xQ75QmnlL2MHD-P8HODbftSavRkTPQQV1YSPH2r5__wXPhrI_RYI0gxewtWrGB&sig=AHIEtbRwlsQDP M_BPV0wpNu-h1eeWtTadA)>
- DARWISH, A.; LEUKERT, K.; REINHARDT, W. 2003. *Image segmentation for the purpose of object based classification* [online] IEEE International Geoscience and Remote Sensing Symposium Proceedings [cit. 2011-7-5]. ISBN 078037929 Dostupné z URL:  
<[http://www.ecognition.com/sites/default/files/337\\_fr07\\_1420.pdf](http://www.ecognition.com/sites/default/files/337_fr07_1420.pdf)>
- DINIS, J. ...[et al.] 2009. *Hierarchical Object – Based classification of dense urban areas by integrating high spatial resolution satellite images and Lidar elevation data*[online]. The international Archives of the Photogrammetry, Remote Sensing and Spatial Information Science [cit. 2011-8-13]. Dostupné z URL:  
< [http://www.isprs.org/proceedings/XXXVIII/4-C7/papers%20proceedings/Dinis\\_66\\_Hierarchical%20object-based%20classification%20of%20dense%20urban%20areas%20by%20integrating%20high%20spatial%20resolution%20satellite%20images%20and%20lidar%20elevation%20data.pdf](http://www.isprs.org/proceedings/XXXVIII/4-C7/papers%20proceedings/Dinis_66_Hierarchical%20object-based%20classification%20of%20dense%20urban%20areas%20by%20integrating%20high%20spatial%20resolution%20satellite%20images%20and%20lidar%20elevation%20data.pdf)>
- ECOGNITION 8.0 2010. *Getting started – Example: Simple building extraction* [online]. Copyright © 2010 Trimble Navigation limited [cit. 2011-6-15]. Dostupné z URL:  
< [http://community.ecognition.com/home/GuidedTour1\\_eCognition8\\_GettingStarted\\_Example\\_SimpleBuildingExtraction.zip/view](http://community.ecognition.com/home/GuidedTour1_eCognition8_GettingStarted_Example_SimpleBuildingExtraction.zip/view)>

- ECOGNITION 8.0 2010. *Advanced example of building extraction* [online]. Copyright © 2010 Trimble Navigation limited [cit. 2011-6-15]. Dostupné z URL: < [http://community.ecognition.com/home/GuidedTour3\\_eCognition8\\_AdvancedRuleSetWriting\\_ExampleBuildingExtraction.zip/view](http://community.ecognition.com/home/GuidedTour3_eCognition8_AdvancedRuleSetWriting_ExampleBuildingExtraction.zip/view)>
- FRAUMAN, E.; WOLFF, E. 2005. *Segmentation of very high spatial resolution satellite images in urban areas for segments – based classification* [online]. Institut de Gestion de l'Environnement et d'Aménagement du Territoire, Université Libre de Bruxelles [cit. 2011-1-5]. Dostupné z URL: < [http://www.ecognition.com/sites/default/files/226\\_frauman\\_urs2005.pdf](http://www.ecognition.com/sites/default/files/226_frauman_urs2005.pdf)>
- HOFMANN, P. 2008. *Detect buildings and roads from Ikonos and DEM data with Definiens eCognition* [online]. Definiens [cit. 2011-1-4]. Dostupné z URL: < [http://www.ecognition.com/sites/default/files/definiens\\_Ikonos\\_DEM\\_data.pdf](http://www.ecognition.com/sites/default/files/definiens_Ikonos_DEM_data.pdf)>
- GRIFFITH, S.J. 2005. *Object – Oriented Method to Classify the Land use and Land cover in San Antonio using eCognition Object – Oriented Image Analysis*[online]. ES 6973 – Remote Sensing Image Process and Analysis[cit. 2011-1-21]. Dostupné z URL: < <http://www.utsa.edu/lrsg/teaching/es6973/project/jayar1.pdf>>
- GISAT. 2011. *Družicová data*[online] [cit. 2011-3-11]. Dostupné z URL: < <http://www.gisat.cz/content/cz/druzicova-data>>
- GODER, J. 2007. *Poloautomatické určení parametrů klasifikačního modelu objektově orientované klasifikace* [rukopis]. Diplomová práce na Přírodovědecké fakultě Univerzity Karlovy na katedře aplikované geoinformatiky a kartografie. Vedoucí diplomové práce Jan Kolář
- HÁJEK, F. 2006. *Object – Oriented Classification of Ikonos satellite data for the identification of tree species composition*[online]. Journal of Forest Science[cit. 2011-1-22]. Dostupné z URL: < [http://www.cazv.cz/attachments/JFSa\\_52\\_181-187.pdf](http://www.cazv.cz/attachments/JFSa_52_181-187.pdf)>
- HARAYAMA, A.; JAQUET, J.M. 2004. *Multi-source object-oriented classification of landcover using very high resolution imagery and digital elevation model* [online]. eCognition [cit. 2011-1-22]. Dostupné z URL: < [http://www.ecognition.com/sites/default/files/291\\_grid.pdf](http://www.ecognition.com/sites/default/files/291_grid.pdf)>
- HEROLD, M.; GUENTHER, S.; CLARKE, K.C.. 2003. *Mapping urban areas in the Santa Barbara South Coast using Ikonos data and Definiens eCognition*[online]. Remote Sensing Research Unit, Department of Geography, University of California Santa Barbara, 2003 [cit. 2011-1-3]. Dostupné z URL: < [http://www.ecognition.com/sites/default/files/Definiens\\_urban\\_areas\\_santa\\_barbara\\_ikonos\\_definiens\\_ecognition.pdf](http://www.ecognition.com/sites/default/files/Definiens_urban_areas_santa_barbara_ikonos_definiens_ecognition.pdf)>

- HERMOSILLA, T.; RUIZ, L.A.; RECIO, J.A.; ESTORNELL, J. 2011. *Evaluation of Automatic Building Detection Approaches Combining High Resolution Images and Lidar data* [online]. Remote Sensing [cit. 2011-6-20]. ISSN 2072-4292, Dostupné z URL: < <http://www.mdpi.com/2072-4292/3/6/1188/pdf> >
- JIANG, N. ...[et al.] 2008. *Object oriented building extraction by DSM and very high resolution orthoimages* [online]. The international Archives of the Photogrammetry, Remote Sensing and Spatial Information Science [cit. 2011-8-17]. Dostupné z URL: < [http://www.isprs.org/proceedings/XXXVII/congress/3b\\_pdf/84.pdf](http://www.isprs.org/proceedings/XXXVII/congress/3b_pdf/84.pdf)>
- KAMAGATA, N. ...[ et al.] 2005. *Comparison of pixel – based and object – based classifications of high resolution satellite data in urban fringe areas* [online]. Proceedings of the 26th Asian Conference on Remote Sensing. Hanoi [cit. 2011-1-5]. Dostupné z URL: < [http://www.ecognition.com/sites/default/files/235\\_d2\\_p20.pdf&pli=1](http://www.ecognition.com/sites/default/files/235_d2_p20.pdf&pli=1)>
- KOLANKIEWICZOVÁ, S. 2009. *Klasifikace liniových prvků z družicových dat* [rukopis]. Diplomová práce na Přírodovědecké fakultě Univerzity Karlovy na katedře aplikované geoinformatiky a kartografie. Vedoucí diplomové práce Markéta Potůčková
- KOLÁŘ, J.; HALOUNOVÁ, L.; PAVELKA K. 2000. *Dálkový průzkum Země 10*. Praha: ČVUT, 200. 164 s.
- KOPALOVÁ, I. 2007. *Semiautomatická aktualizace digitálních topografických map s využitím snímků vysokého rozlišení* [rukopis]. Diplomová práce na Přírodovědecké fakultě Univerzity Karlovy na katedře aplikované geoinformatiky a kartografie. Vedoucí diplomové práce Markéta Potůčková
- KUPIDURA, P.; GWADERA, L. 2010. *Comparison of different approaches to extract heterogenous objects from an image using an orchards example*[online]. IAPRS, vol. XXXVIII [cit. 2011-1-21]. Dostupné z URL: < [http://www.isprs.org/proceedings/XXXVIII/part3/b/pdf/13\\_XXXVIII-part3B.pdf](http://www.isprs.org/proceedings/XXXVIII/part3/b/pdf/13_XXXVIII-part3B.pdf)>
- KUPKOVÁ, L.; POTŮČKOVÁ, M.; KOPALOVÁ, I.; KOLÁŘ, J. 2010. *Object Based Image Analysis for Urban Areas* [online]. 2010. Department of Applied GEoinformatics and Cartography, Faculty of Nature, Charles University Prague [cit. 2011-1-3]. Dostupné z URL: < [http://web.natur.cuni.cz/ksgrrsek/urrlab/user/documents/default/suburbanizace/Kupkova\\_Potuckova\\_Kopalova\\_Kolar\\_2010.pdf](http://web.natur.cuni.cz/ksgrrsek/urrlab/user/documents/default/suburbanizace/Kupkova_Potuckova_Kopalova_Kolar_2010.pdf) >
- KUPKOVÁ, L.; NOVÁK, J. 2010. *Analýza vývoje suburbanizace na základě dat DPZ v obci Jirny*[online]. Suburbanizace [cit. 2011-6-20]. Dostupné z URL: < [http://www.suburbanizace.cz/analyzy/2\\_KUPKOVA,\\_L.,\\_NOVAK,\\_J.\\_\(2010\)\\_Analyza\\_vyvoje\\_suburbanizace\\_na\\_zaklade\\_dat\\_DPZ\\_v\\_obci\\_Jirny.pdf](http://www.suburbanizace.cz/analyzy/2_KUPKOVA,_L.,_NOVAK,_J._(2010)_Analyza_vyvoje_suburbanizace_na_zaklade_dat_DPZ_v_obci_Jirny.pdf)>

- LALIBERTE, A.S. ... [et al.] 2004. *Object-Oriented image analysis for mapping shrub encroachment from 1937 to 2003 in southern New Mexico*[online]. Remote Sensing of Environment [cit. 2011-1-20]. Dostupné z URL: < <http://ddr.nal.usda.gov/bitstream/10113/15631/1/IND44027168.pdf>>
- MANSOR, S. ... [et al.] 2004. *Object Oriented Classification for Land Cover Mapping*[online]. The Geospatial Resource Portal – GIS Development [cit. 2011-1-21]. Dostupné z URL: < <http://www.gisdevelopment.net/application/environment/overview/envo0010.htm>>
- MARANGOZ, A.M.; ORUC, M; BUYUKSALIH, G. 2010. *Object – oriented image analysis and semantic network for extracting the roads and buildings from Ikonos pan – sharpened images*[online]. ISPRS Journal of Photogrammetry and Remote Sensing [cit. 2011-1-21]. Dostupné z URL: < <https://docs.google.com/viewer?url=http%3A%2F%2Fwww.isprs.org%2Fproceedings%2FXXXXV%2Fcongress%2Fcomm3%2Fpapers%2F301.pdf>>
- OUŘEDNÍČEK, M. 2010. *Suburbanizace*[online] [cit. 2011-5-18]. Dostupné z URL: < [http://www.suburbanizace.cz/01\\_teorie\\_suburbanizace.htm](http://www.suburbanizace.cz/01_teorie_suburbanizace.htm)>
- OUŘEDNÍČEK, M. 2007. *Differential Suburban development in Prague urban region* [online] Geografiska Amater 88B, č.2 [cit. 2011-8-5].
- POLÁČKOVÁ J. 1996. *Podoba a struktura kvalifikační práce na katedře* [online]. Praha, 2008 [cit. 2008-7-25]. Dostupné z URL: <<http://www.natur.cuni.cz/gis>>
- RASHED, T.; JÜRGENS, C. 2010. *Remote Sensing of Urban and Suburban Areas*[online]. Remote Sensing and Digital Image Processing [cit. 2011-1-15]. Dostupné z URL: < <http://www.springer.com/series/6477>>
- REPAKA, R.S. et. al. 2004. *Comparing spectral and object based approaches for classification and transportation feature extraction from high resolution multispectral imagery* [online]. ASPRS The Imaging & Geospatial Information Society [cit. 2011-8-15]. Dostupné z URL: < [http://www.ecognition.com/sites/default/files/312\\_asprs\\_2004\\_0204.pdf](http://www.ecognition.com/sites/default/files/312_asprs_2004_0204.pdf)>
- RUSSNÁK, J. 2009. *Analýza tvorby DTM u vybraných platforem GIS*[online]. Bakalářská práce[cit. 2011-7-15]
- SCHWARZ, M.; STEINMEIER, CH.; WASER, L. 2000. *Detection of storm losses in alpine forest areas by different methodic approaches using high-resolution satellite data* [online]. DEFINIENS eCognition [cit. 2011-7-18]. Dostupné z URL: <<http://www.definiens-imaging.com>>


- SYED, S.; DARE, P.; JONES, S. 2005. *Automatic classification of land cover features with high resolution imagery and lidar data: an object oriented approach* [online]. Proceeding of SSC2005 Spatial Intelligence, Innovation and Praxis, Spatial Science Institute [cit. 2011-6-21]. ISBN 0-9581366-2-9, Dostupné z URL:  
< [http://www.ecognition.com/sites/default/files/266\\_0185.pdf](http://www.ecognition.com/sites/default/files/266_0185.pdf)>
- TEO, T.A.; CHEN, L.CH. 2004. *Object-based building detection from Lidar data and high resolution satellite imagery* [online]. 25<sup>th</sup> ACRS 2004 [cit. 2011-7-20]. Dostupné z URL:  
< [http://www.ecognition.com/sites/default/files/318\\_ps\\_5\\_5.pdf](http://www.ecognition.com/sites/default/files/318_ps_5_5.pdf)>
- THOMAS, N. ... [et al.] 2003. *A comparison of urban mapping methods using high resolution digital imagery*[online]. Photogrammetric Engineering and Remote Sensing [cit. 2011-1-20]. Dostupné z URL:  
< [http://www.asprs.org/publications/pers/2003journal/september/2003\\_sep\\_963-972.pdf](http://www.asprs.org/publications/pers/2003journal/september/2003_sep_963-972.pdf)>
- VOLPE, F.; ROSS, L. 2003. *QuickBird High Resolution Satellite Data for Urban Areas*[online]. Urban 2003 – Remote sensing and data fusion over urban areas [cit. 2011-1-13]. Dostupné z URL: < [http://www.eurimage.com/products/tech\\_papers/qb\\_urban-applications.pdf](http://www.eurimage.com/products/tech_papers/qb_urban-applications.pdf)>
- XIAOXIA, S.; JIXIAN, Z.; ZHENGJUN, L. 2004. *An object-oriented classification method on high resolution satellite data* [online]. 25<sup>TH</sup> ACRS 2004 [cit. 2011-7-21]. Dostupné z URL:  
< [http://www.ecognition.com/sites/default/files/316\\_b\\_4\\_6.pdf](http://www.ecognition.com/sites/default/files/316_b_4_6.pdf)>
- XIE. 2005. *Object Oriented Classification* [online]. ES 6974 – Remote Sensing Image Process and Analysis[cit. 2011-1-21]. Dostupné z URL:  
< <http://www.utsa.edu/lrsg/Teaching/EES5083/L11.pdf>>
- ZENG, Y.; ZHANG, J.; WANG, G.; LIN, Z. 2002. *Urban land use classification using integrated airborne laser scanning data and high resolution multi-spectral satellite imagery* [online]. FIEOS 2002 Conference Proceedings [cit. 2011-7-29]. Dostupné z URL:  
< <http://www.isprs.org/proceedings/XXXIV/part1/paper/00100.pdf>>

## SEZNAM PŘÍLOH


<b>Příloha 1</b>	<b>Georeference družicových snímků .....</b>	<b>80</b>
<b>Příloha 2</b>	<b>Tvorba nDSM.....</b>	<b>81</b>
<b>Příloha 3</b>	<b>Klasifikační báze OBIA .....</b>	<b>85</b>
<b>Příloha 4</b>	<b>Výsledky objektově orientované klasifikace .....</b>	<b>87</b>
<b>Příloha 5</b>	<b>Zhodnocení přesnosti klasifikace.....</b>	<b>90</b>
<i>Příloha 5.1</i>	<i>Přesnost klasifikace budov v komerční zóně Modletice .....</i>	<i>90</i>
<i>Příloha 5.2</i>	<i>Přesnost klasifikace zpevněných povrchů v komerční zóně Modletice.....</i>	<i>91</i>
<i>Příloha 5.3</i>	<i>Přesnost klasifikace budov v komerční zóně Jirny.....</i>	<i>92</i>
<i>Příloha 5.4</i>	<i>Přesnost klasifikace zpevněných povrchů v komerční zóně Jirny .....</i>	<i>93</i>
<i>Příloha 5.5</i>	<i>Přesnost klasifikace budov s upravenou klasifikační bází v komerční zóně Jirny .....</i>	<i>94</i>
<i>Příloha 5.6</i>	<i>Přesnost klasifikace zpevněných povrchů s upravenou klasifikační bází v komerční zóně Jirny .....</i>	<i>95</i>
<i>Příloha 5.7</i>	<i>Konečný upravený tematický výstup zpracovaný na základě výsledků podrobné klasifikace pro komerční zónu Modletice .....</i>	<i>96</i>
<i>Příloha 5.8</i>	<i>Konečný upravený tematický výstup zpracovaný na základě výsledků podrobné klasifikace pro komerční zónu Jirny .....</i>	<i>97</i>
<i>Příloha 5.9</i>	<i>Konečný upravený tematický výstup zpracovaný na základě výsledků podrobné klasifikace s upravenou klasifikační bází pro komerční zónu Jirny.....</i>	<i>98</i>
<b>Příloha 6</b>	<b>Klasifikace budovy na základě výšky .....</b>	<b>99</b>

# Příloha 1: GEOREFERENCE DRUŽICOVÝCH SNÍMKŮ

Příloha 1.1: Transformace družicového snímku pro lokalitu Modletice



Příloha 1.2: Transformace družicového snímku pro lokalitu Modletice





## Příloha 2: TVORBA NDSM

Příloha 2.1: Nastavení parametrů nástroje „Create fishnet“

Output Feature Class  
C:\Users\Asus\Documents\ArcGIS\Default.gdb\fishnet

Template Extent (optional)  
D:\diplomka\28\_6\_zpracovani\_s\_Kubou\teren.shp

Top  
-1053745,000000

Left  
-732560,000000

Right  
-732445,000000

Bottom  
-1053890,000000

Clear

Fishnet Origin Coordinate  
X Coordinate  
-732560

Y Coordinate  
-1053890

Y-Axis Coordinate  
X Coordinate  
-732560

Y Coordinate  
-1053880

Cell Size Width  
4

Cell Size Height  
4

Number of Rows  
0

Number of Columns  
0

Opposite corner of Fishnet (optional)  
X Coordinate  
-732445

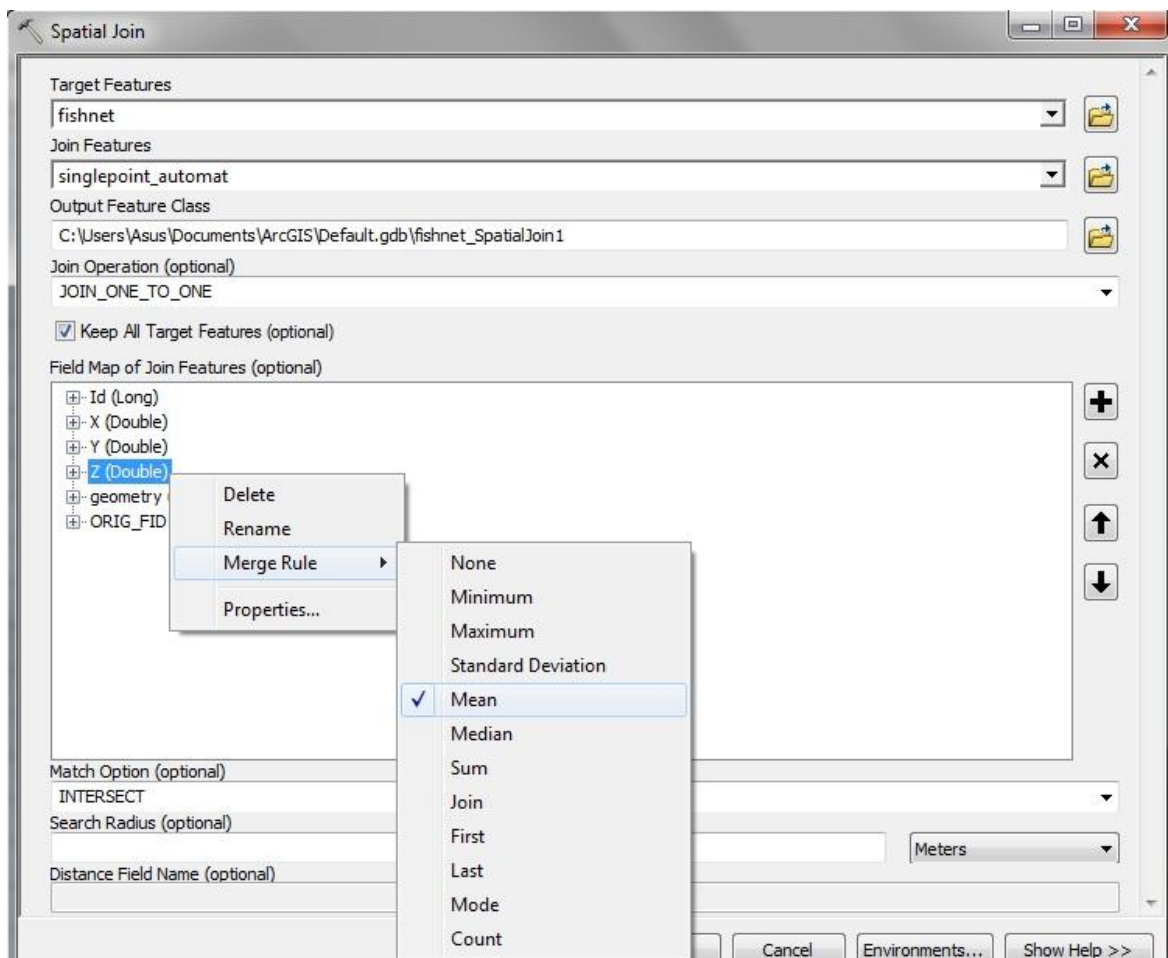
Y Coordinate  
-1053745

Create Label Points (optional)

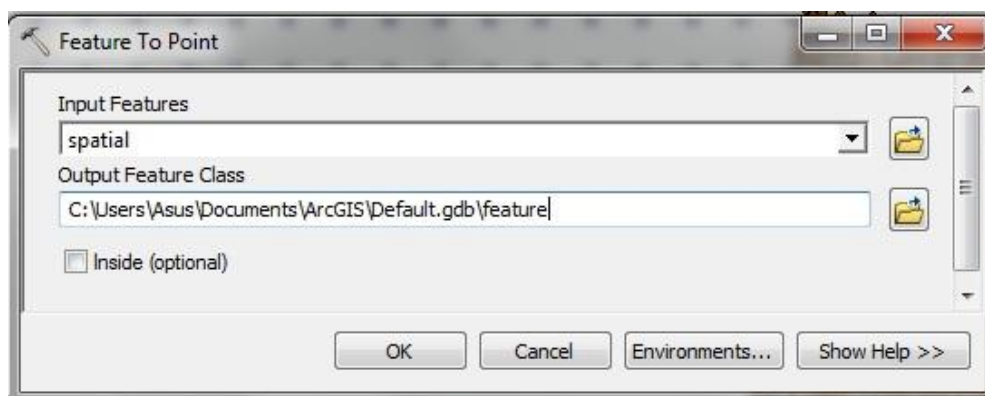
Geometry Type (optional)  
POLYGON

OK Cancel Environments... Show Help >>

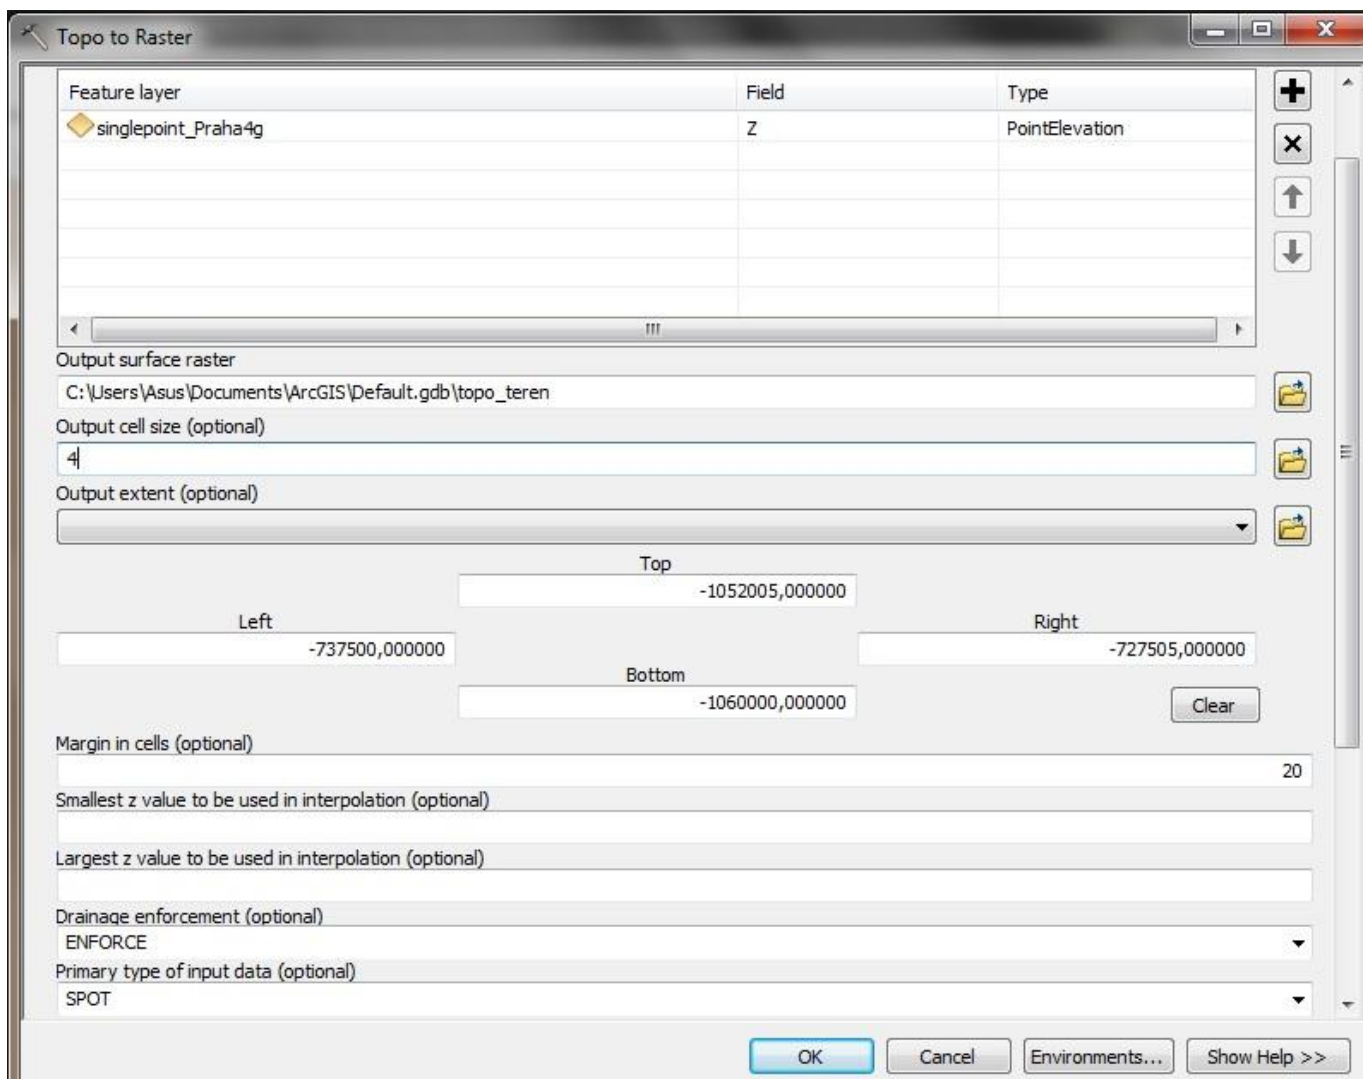
**Příloha 2.2:** Nastavení parametrů nástroje „Spatial join“



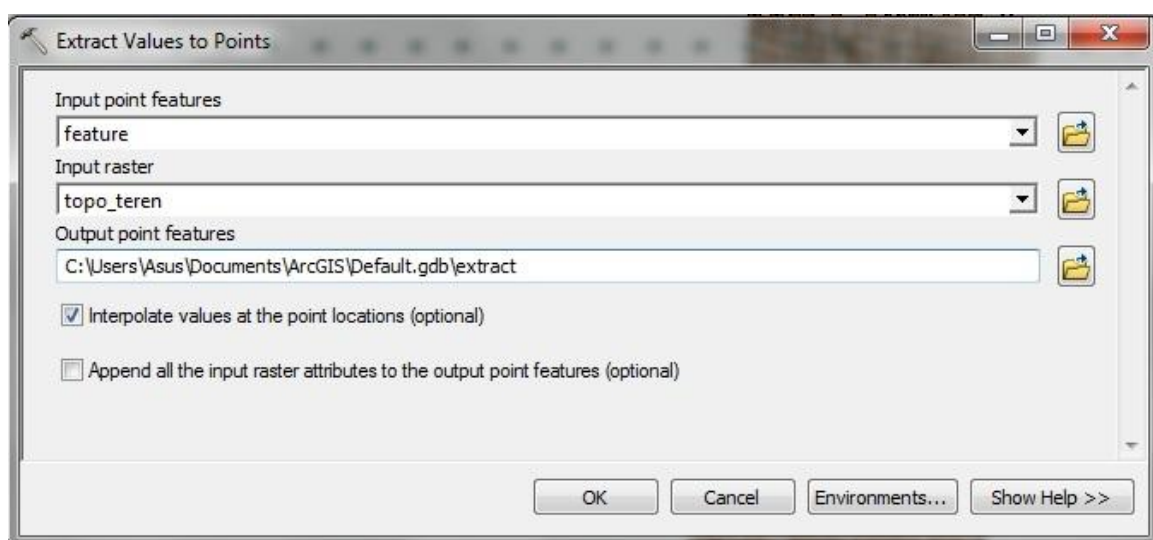
**Příloha 2.3:** Nastavení parametrů nástroje „Feature to Point“




**Příloha 2.4:** Nastavení parametrů nástroje „Topo to raster“



**Příloha 2.5:** Nastavení parametrů nástroje „Extract values to Points“



**Příloha 2.6:** Nastavení parametrů nástroje „Point to raster“



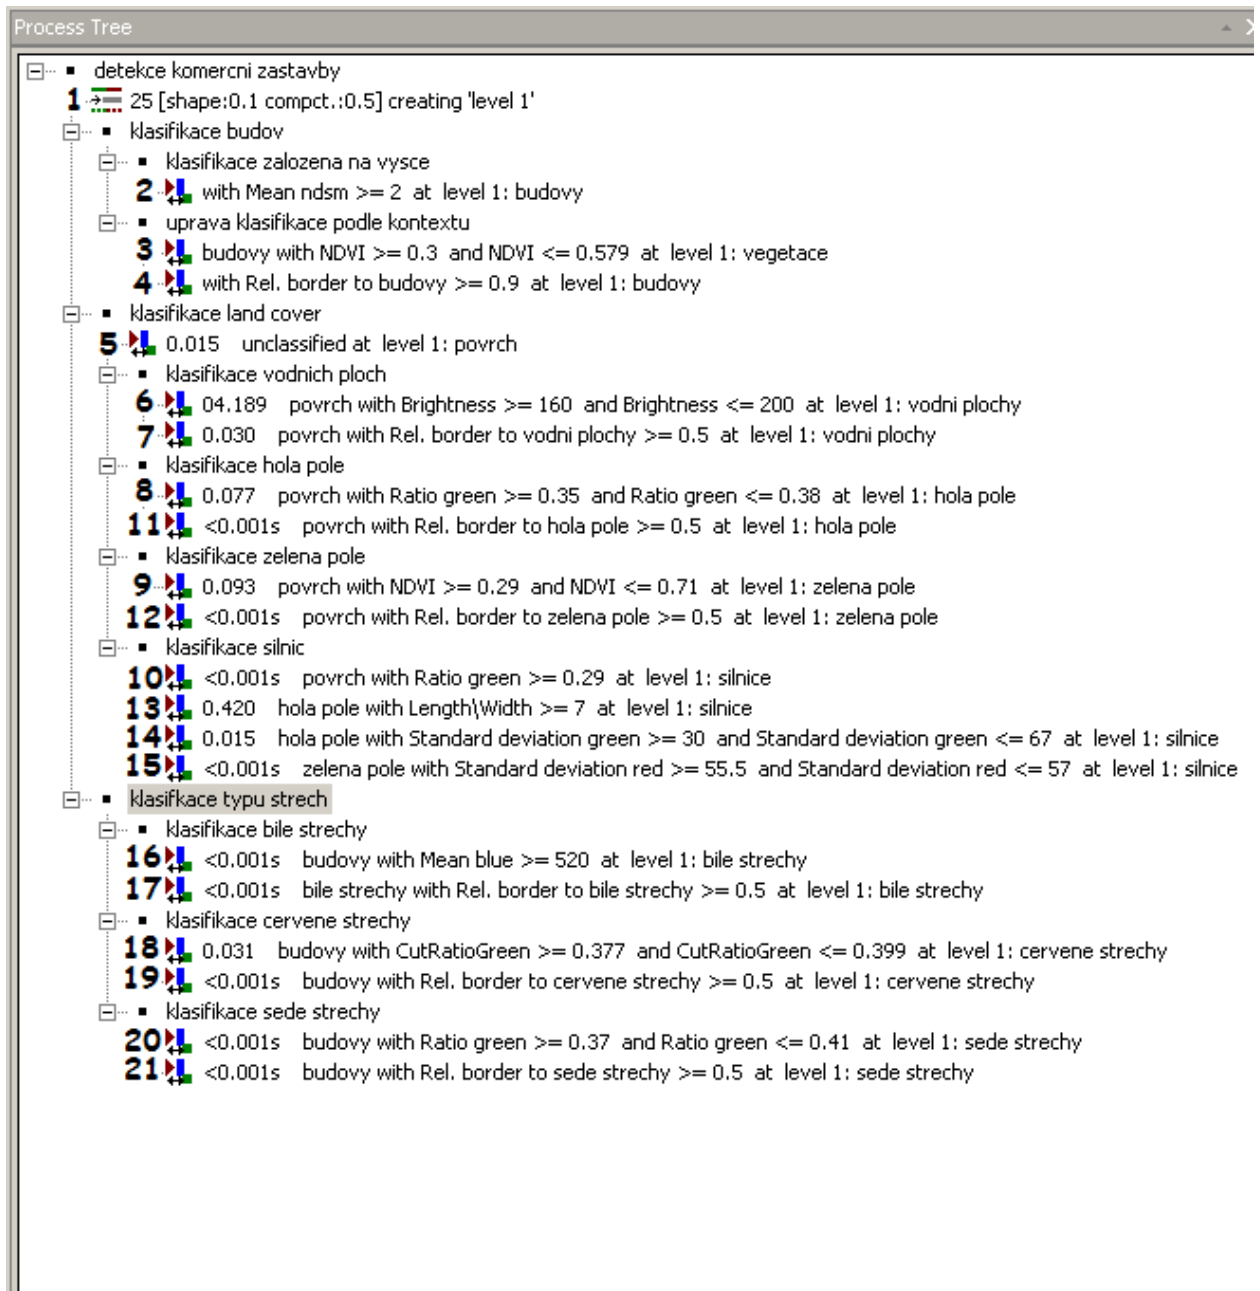
## Příloha 3: KLASIFIKAČNÍ BÁZE OBIA

**Příloha 3.1:** Klasifikační báze vytvořená na modelovém území Modletice včetně pořadí klasifikačních pravidel

The screenshot displays a QGIS Process Tree window titled "Process Tree". The tree structure is as follows:

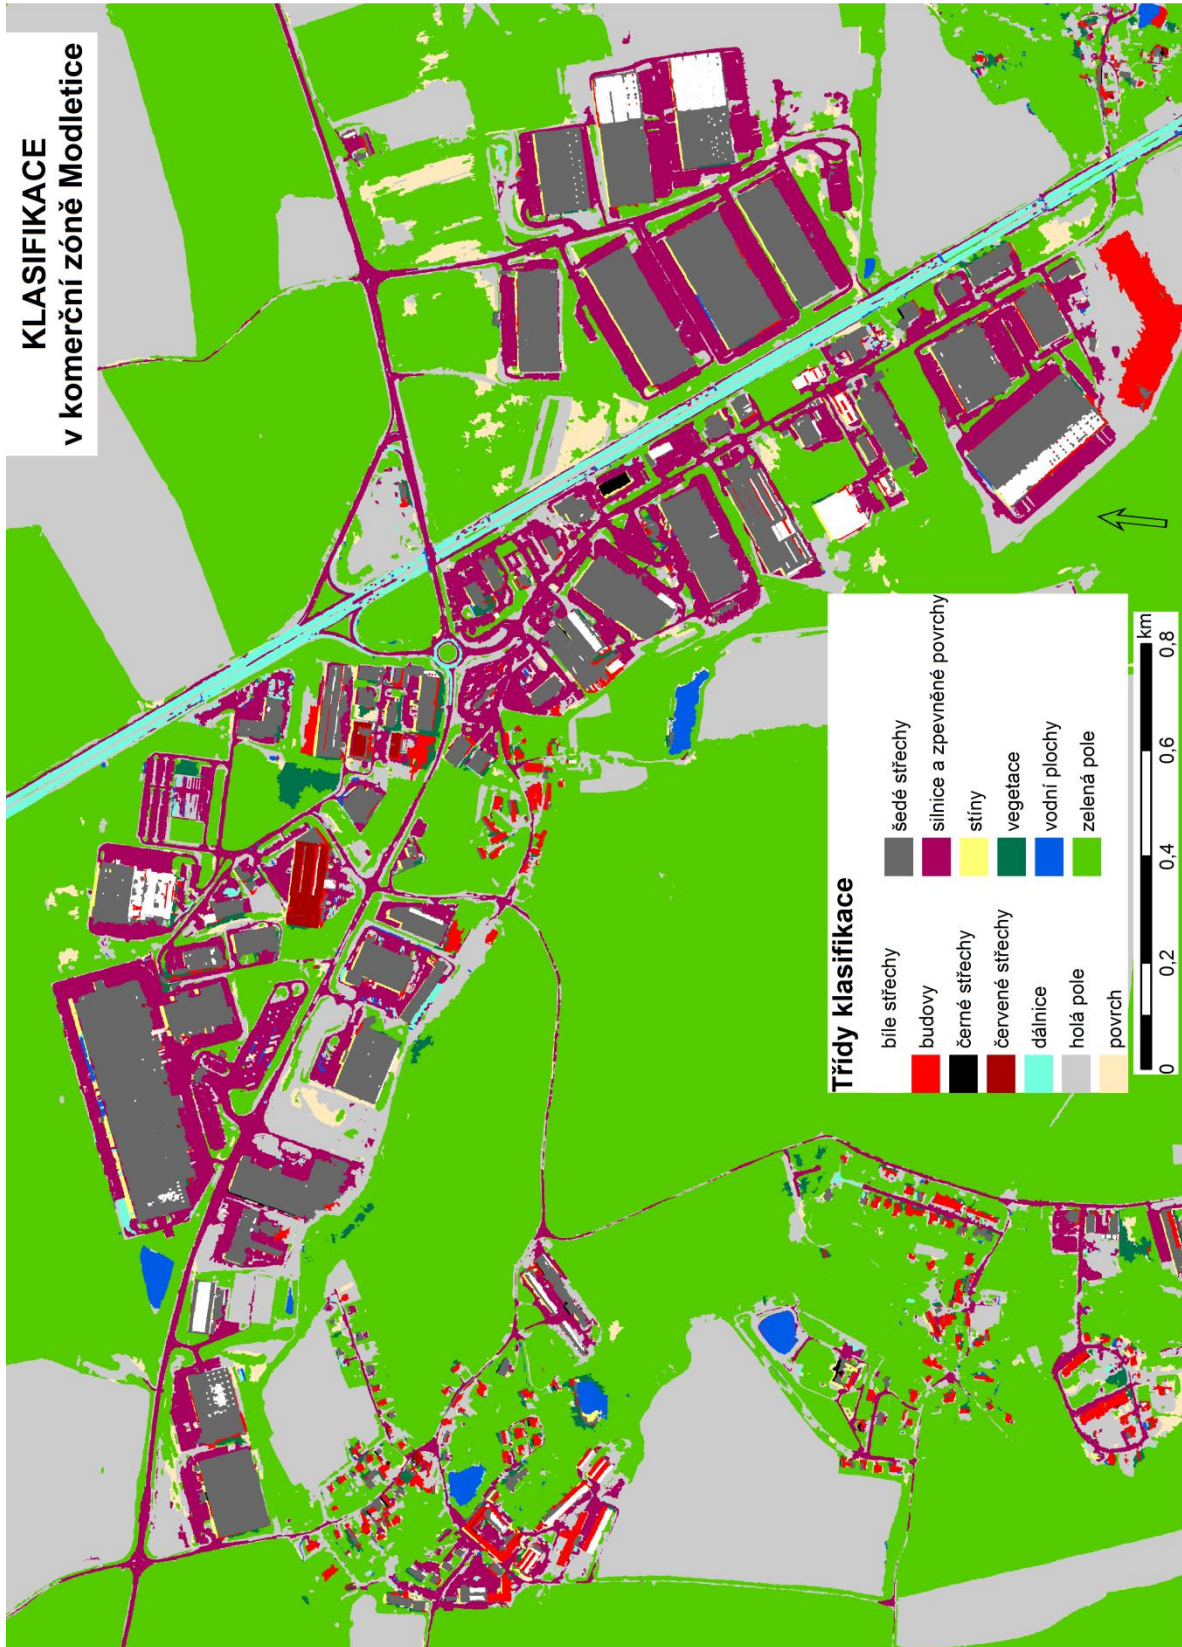
- detekce komercni zastavby
  - 1 02:49.969 28 [shape:0.1 compct.:0.5] creating 'level 1'
  - klasifikace budov
    - klasifikace zalozena na vysce
      - 2 0.047 with Mean ndsm  $\geq 2$  at level 1: budovy
    - uprava klasifikace podle kontextu
      - 3 0.020 budovy with NDVI  $\geq 0.3$  and NDVI  $\leq 0.579$  at level 1: vegetace
      - 4 0.040 with Rel. border to budovy  $\geq 0.9$  at level 1: budovy
  - klasifikace land cover
    - 5 0.020 unclassified at level 1: povrch
    - klasifikace vodnich ploch
      - 6 0.041 povrch with Brightness  $\geq 121$  and Brightness  $\leq 160$  at level 1: vodni plochy
      - 8 0.055 povrch with Mean nir  $\geq 107$  and Mean nir  $\leq 146.5$  at level 1: vodni plochy
      - 9 0.041 povrch with Mean nir  $\geq 151$  and Mean nir  $\leq 169.9$  at level 1: vodni plochy
      - 10 0.055 povrch with Mean nir  $\geq 182$  and Mean nir  $\leq 185$  at level 1: vodni plochy
    - klasifikace silnic
      - 7 0.041 povrch with Ratio green  $\geq 0.38$  and Ratio green  $\leq 0.41$  at level 1: silnice
      - 14 0.030 povrch with NDVI  $\geq 0.11$  and NDVI  $\leq 0.2$  at level 1: silnice
      - 15 0.015 povrch with Rel. border to silnice  $\geq 0.5$  at level 1: silnice
      - 16  $<0.001s$  silnice with Brightness  $\leq 200$  at level 1: dalnice
    - klasifikace zelena pole
      - 11 0.150 povrch with NDVI  $\geq 0.39$  and NDVI  $\leq 0.71$  at level 1: zelena pole
      - 13 0.015 povrch with CutRatioGreen  $\geq 0.44$  and CutRatioGreen  $\leq 0.47$  at level 1: zelena pole
      - 17 0.016 povrch with Rel. border to zelena pole  $\geq 0.5$  at level 1: zelena pole
    - klasifikace hola pole
      - 12 0.030 povrch with Ratio green  $\geq 0.322299$  and Ratio green  $\leq 0.37$  at level 1: hola pole
      - 18  $<0.001s$  povrch with Rel. border to hola pole  $\geq 0.5$  at level 1: hola pole
  - klasifikace typu strech
    - klasifikace bile strechy
      - 19 0.015 budovy with Mean blue  $\geq 580$  and Mean blue  $\leq 1049.1$  at level 1: bile strechy
      - 20  $<0.001s$  bile strechy with Rel. border to bile strechy  $\geq 0.5$  at level 1: bile strechy
    - klasifikace cervene strechy
      - 21 0.046 budovy with CutRatioGreen  $\geq 0.3042$  and CutRatioGreen  $\leq 0.36$  at level 1: cervene strechy
      - 22  $<0.001s$  budovy with Rel. border to cervene strechy  $\geq 0.5$  at level 1: cervene strechy
    - klasifikace sede strechy
      - 23 0.015 budovy with Ratio green  $\geq 0.37$  and Ratio green  $\leq 0.4089$  at level 1: sede strechy
      - 24  $<0.001s$  budovy with Rel. border to sede strechy  $\geq 0.5$  at level 1: sede strechy
    - klasifikace cerne strechy
      - 25 0.015 sede strechy with Mean nir  $\geq 147$  and Mean nir  $\leq 162$  at level 1: cerne strechy
  - klasifikace stiny
    - 26  $<0.001s$  budovy with Mean nir  $\geq 110$  and Mean nir  $\leq 160$  at level 1: stiny
    - 27  $<0.001s$  budovy with Rel. border to stiny  $\geq 0.5$  at level 1: stiny
    - 28 0.015 sede strechy with Mean nir  $\geq 110$  and Mean nir  $\leq 160$  at level 1: stiny
    - 29 0.077 vodni plochy with Distance to sede strechy  $\leq 17$  Pxl at level 1: stiny
    - 30 0.031 vodni plochy with Distance to bile strechy  $\leq 25$  Pxl at level 1: stiny
    - 31 0.016 vodni plochy with Distance to cervene strechy  $\leq 25$  Pxl at level 1: stiny
    - 32 0.807 vodni plochy with Distance to sede strechy  $\geq 19$  Pxl and Distance to sede strechy  $\leq 24.17$  Pxl at level 1: stiny

**Příloha 3.2:** Upravená klasifikační báze vytvořená na modelovém území Jirny včetně pořadí klasifikačních pravidel

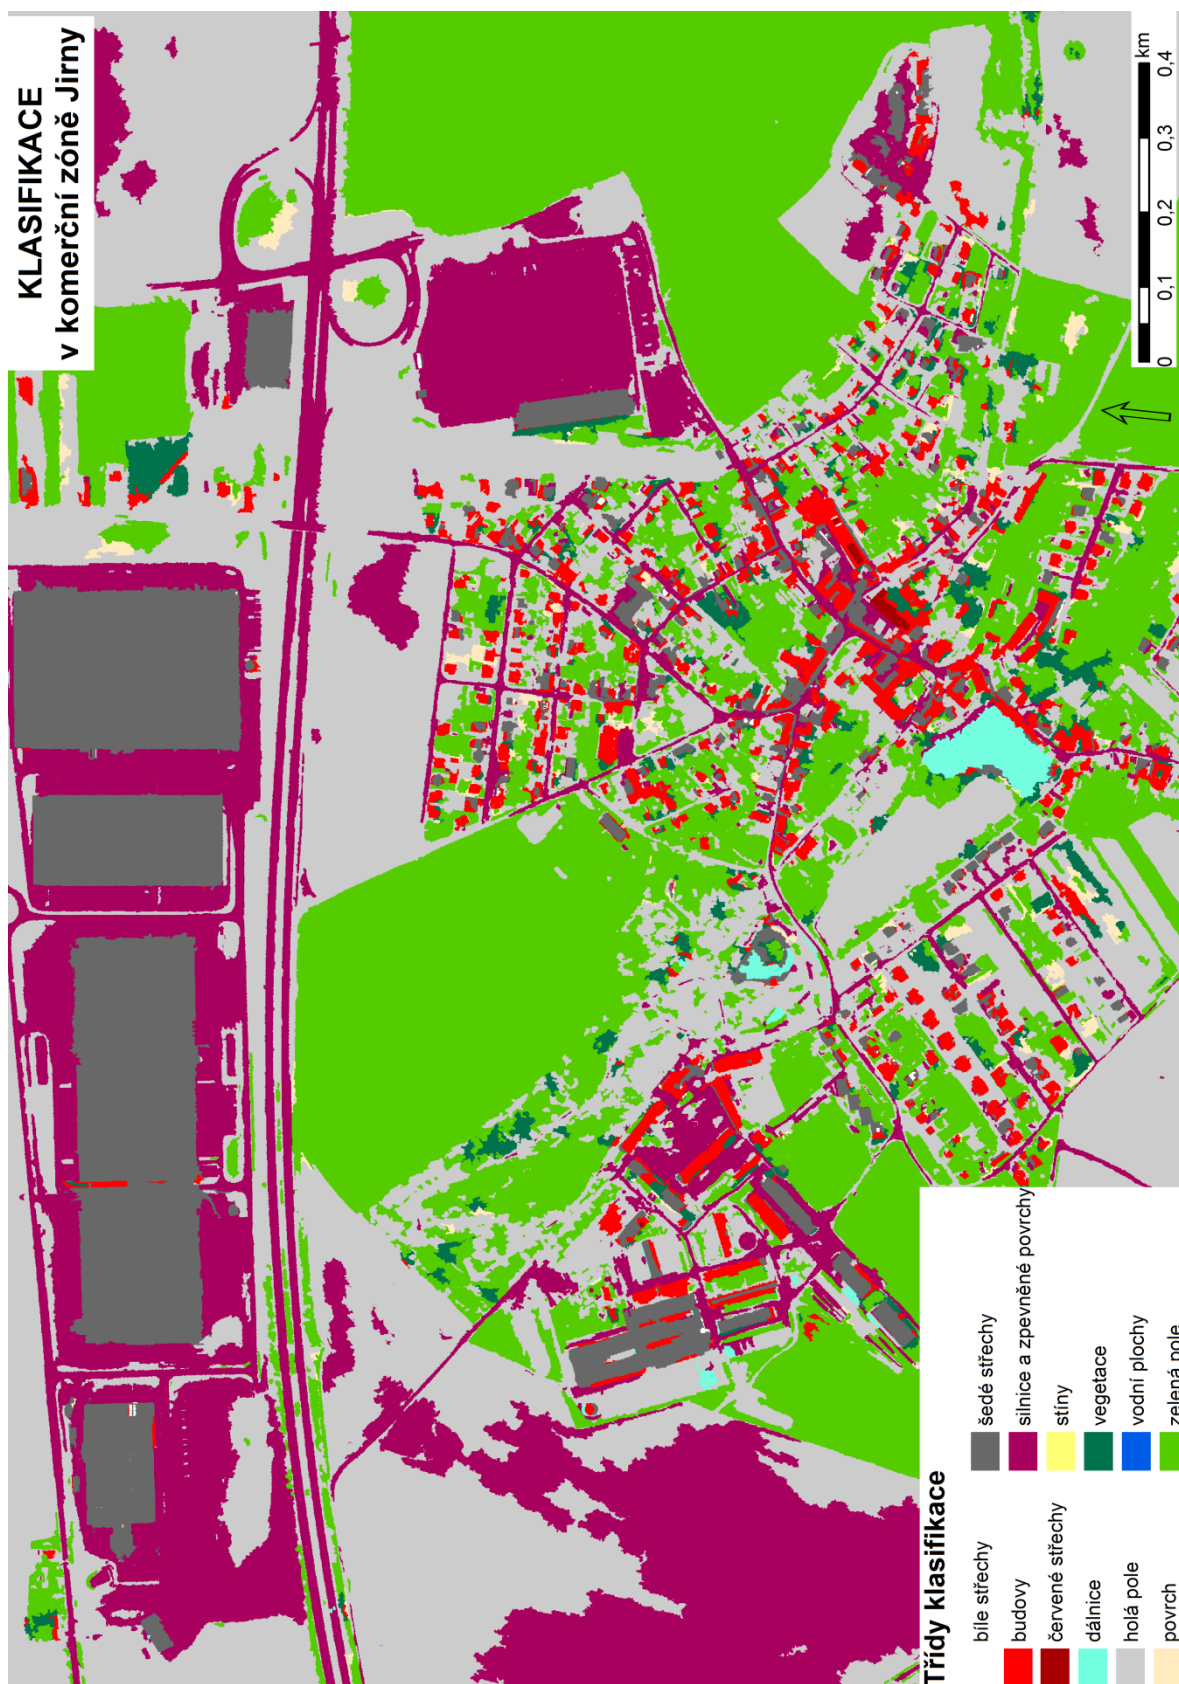


# Příloha 4: VÝSLEDKY OBJEKTIVĚ ORIENTOVANÉ KLASIFIKACE

Příloha 4.1: Výsledek objektivě orientované klasifikace pro modelové území Modletice

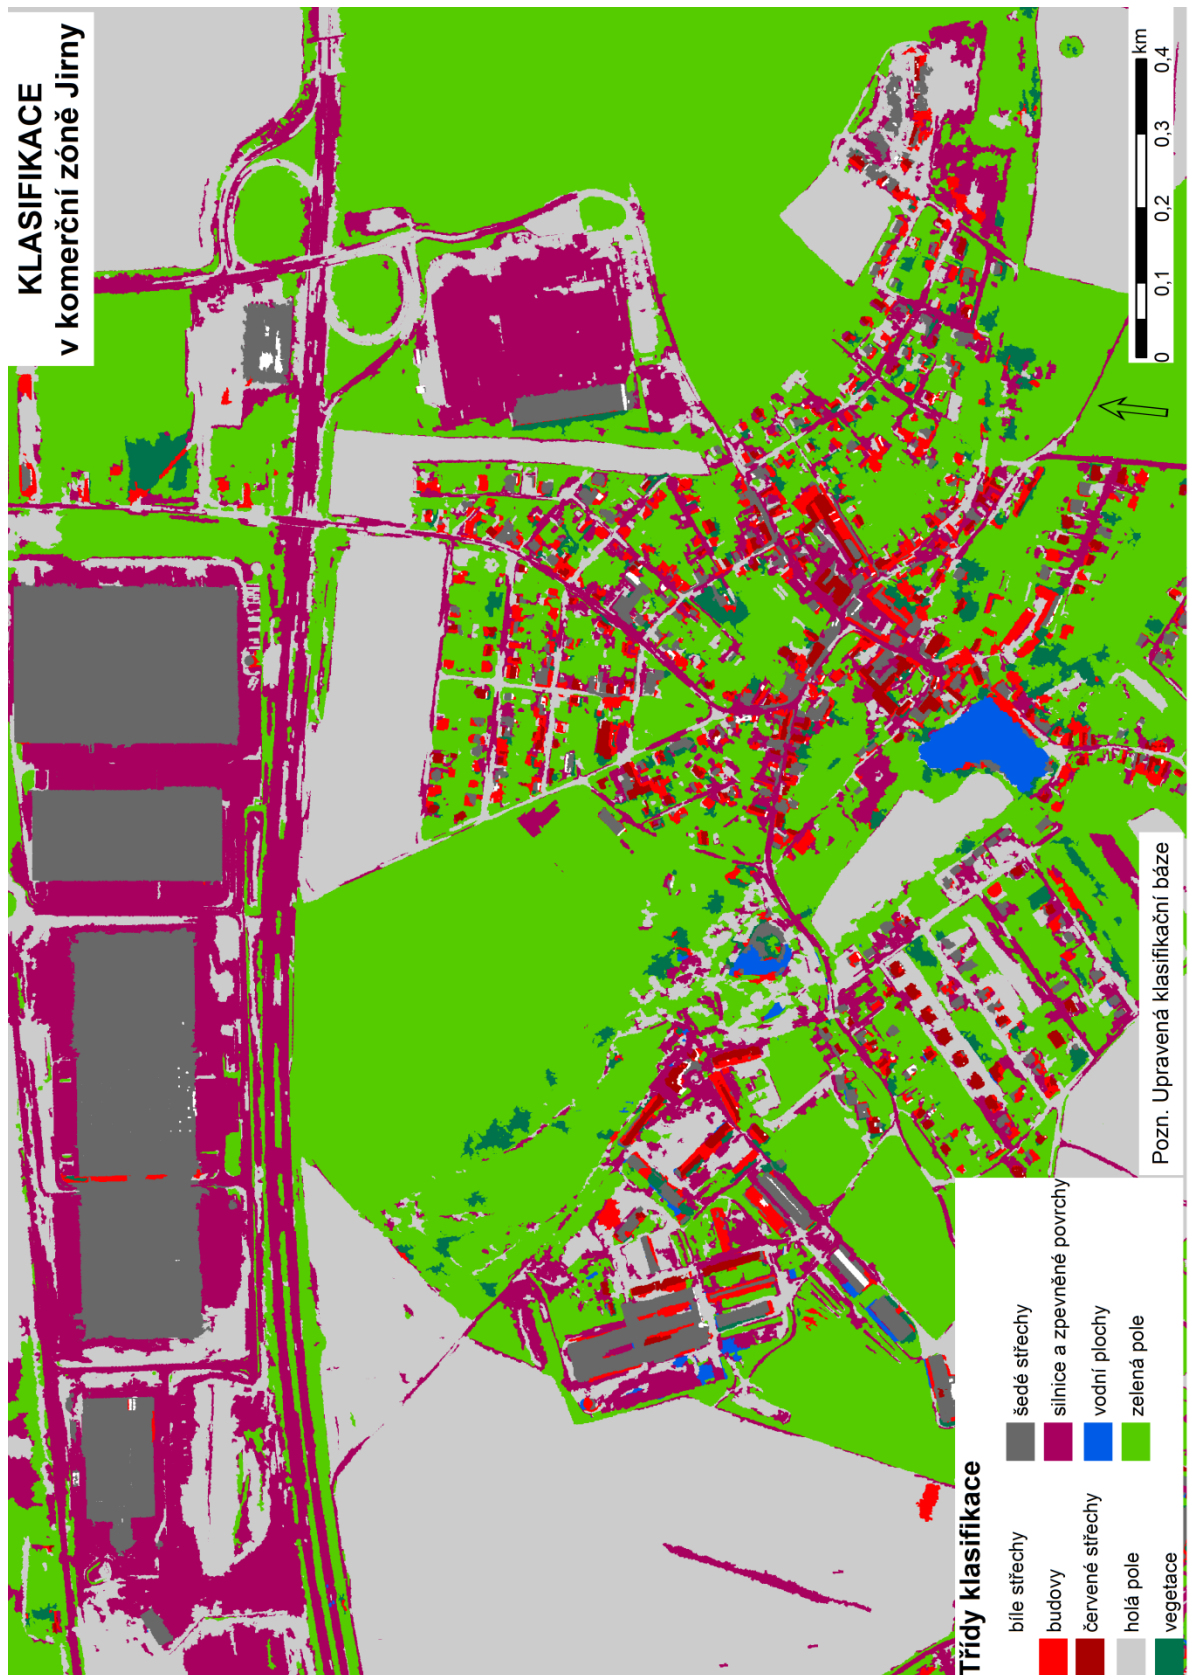


Příloha 4.2: Výsledek objektově orientované klasifikace pro modelové území Jirny



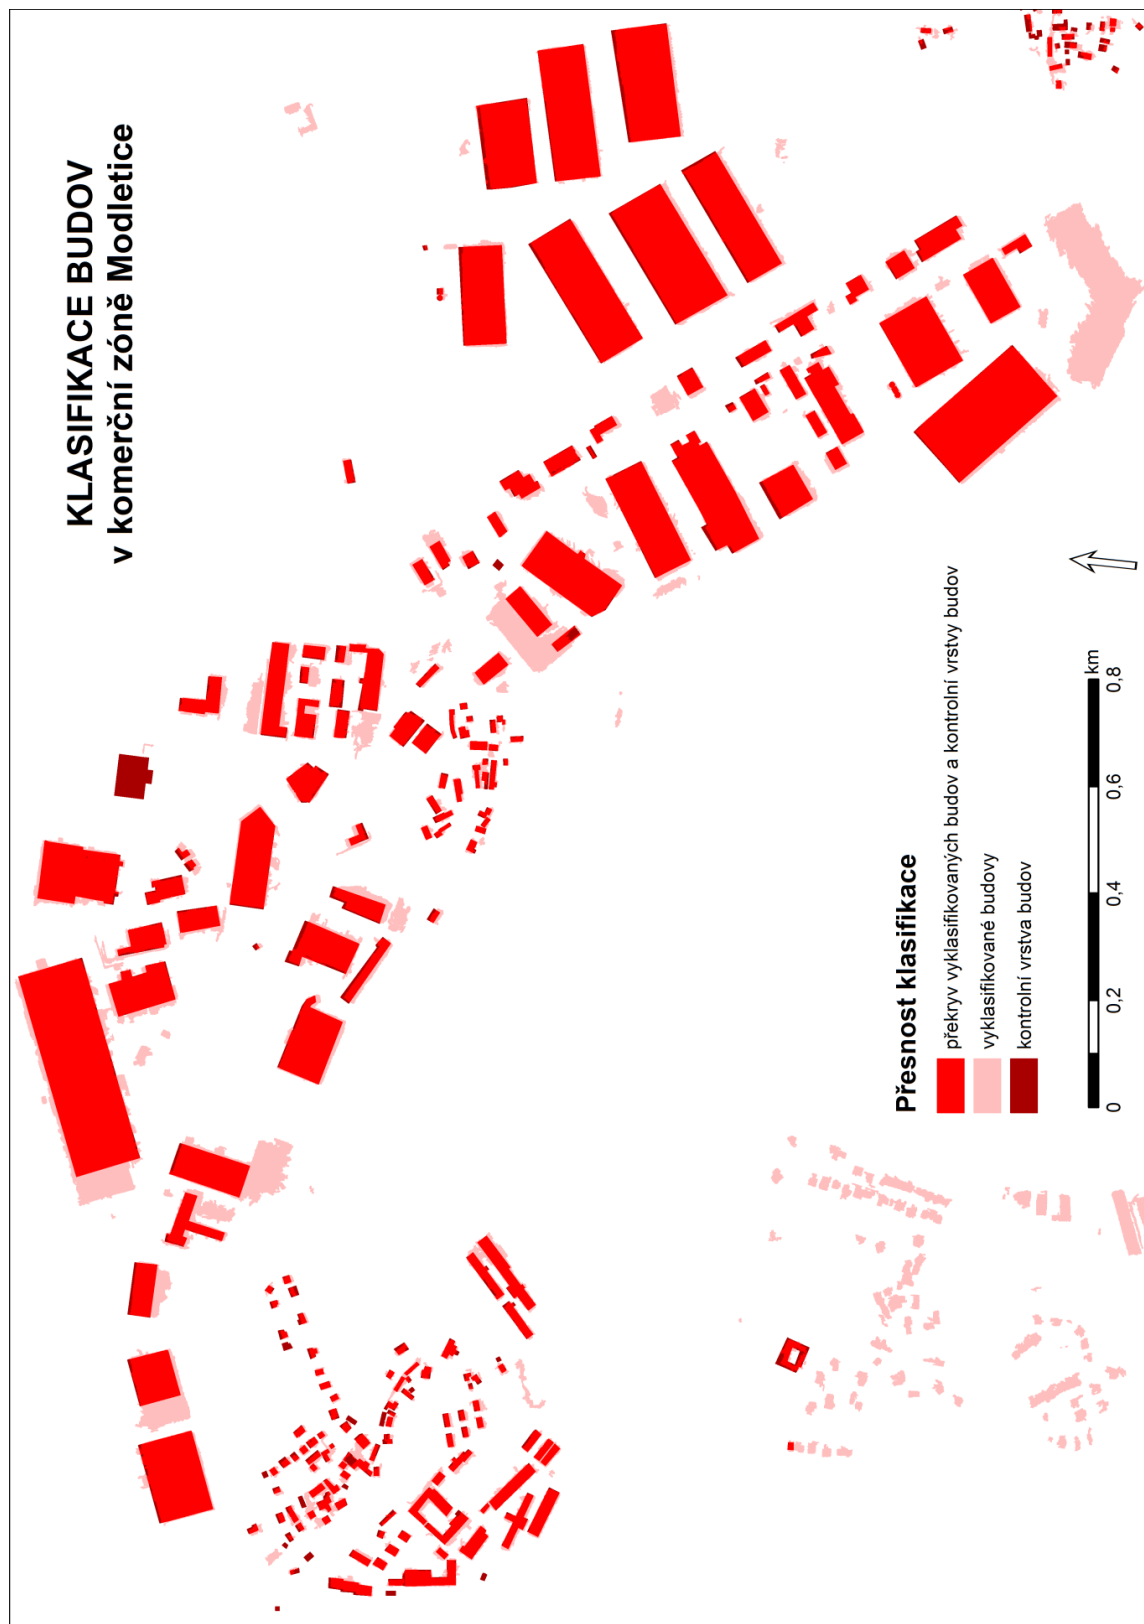


**Příloha 4.3:** Výsledek objektově orientované klasifikace s upravenou klasifikační bází pro modelové území Jirny



# Příloha 5: ZHODNOCENÍ PŘESNOSTI KLASIFIKACE

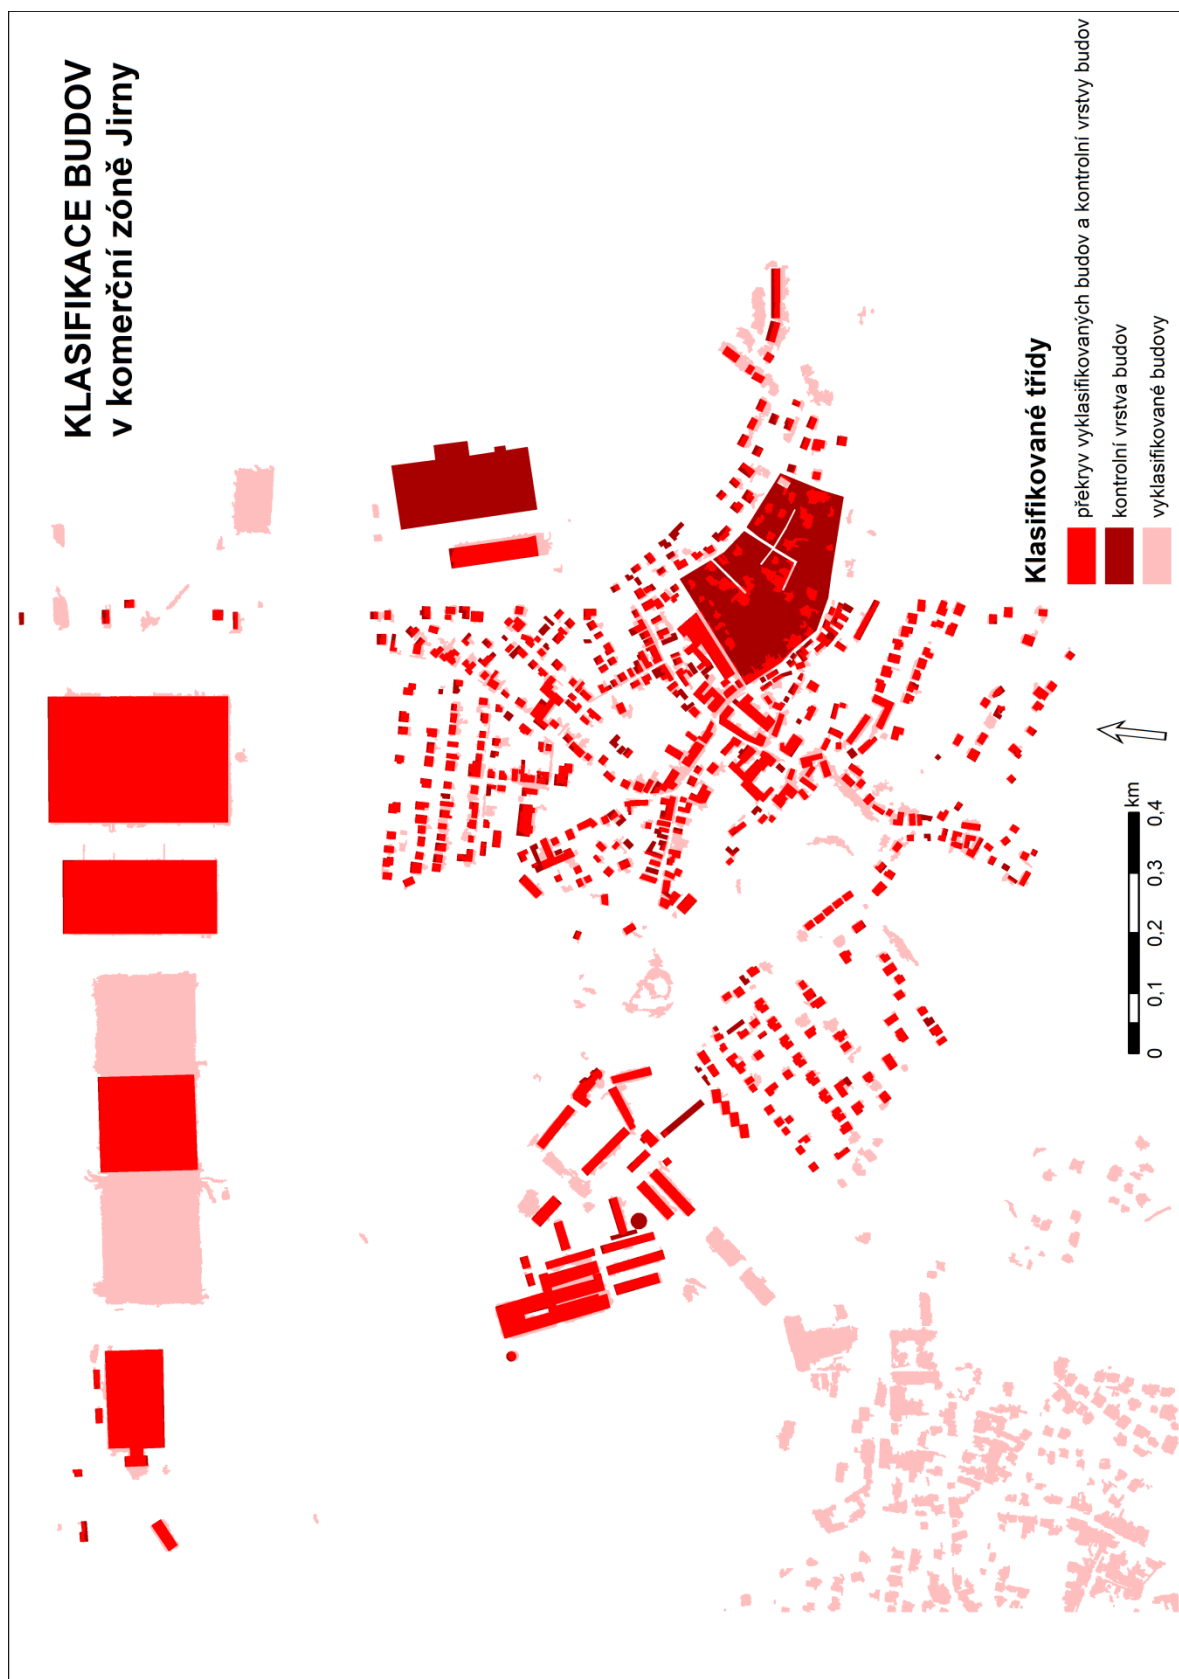
Příloha 5.1: Přesnost klasifikace budov v komerční zóně Modletice



Příloha 5.2: Přesnost klasifikace zpevněných povrchů v komerční zóně Modletice



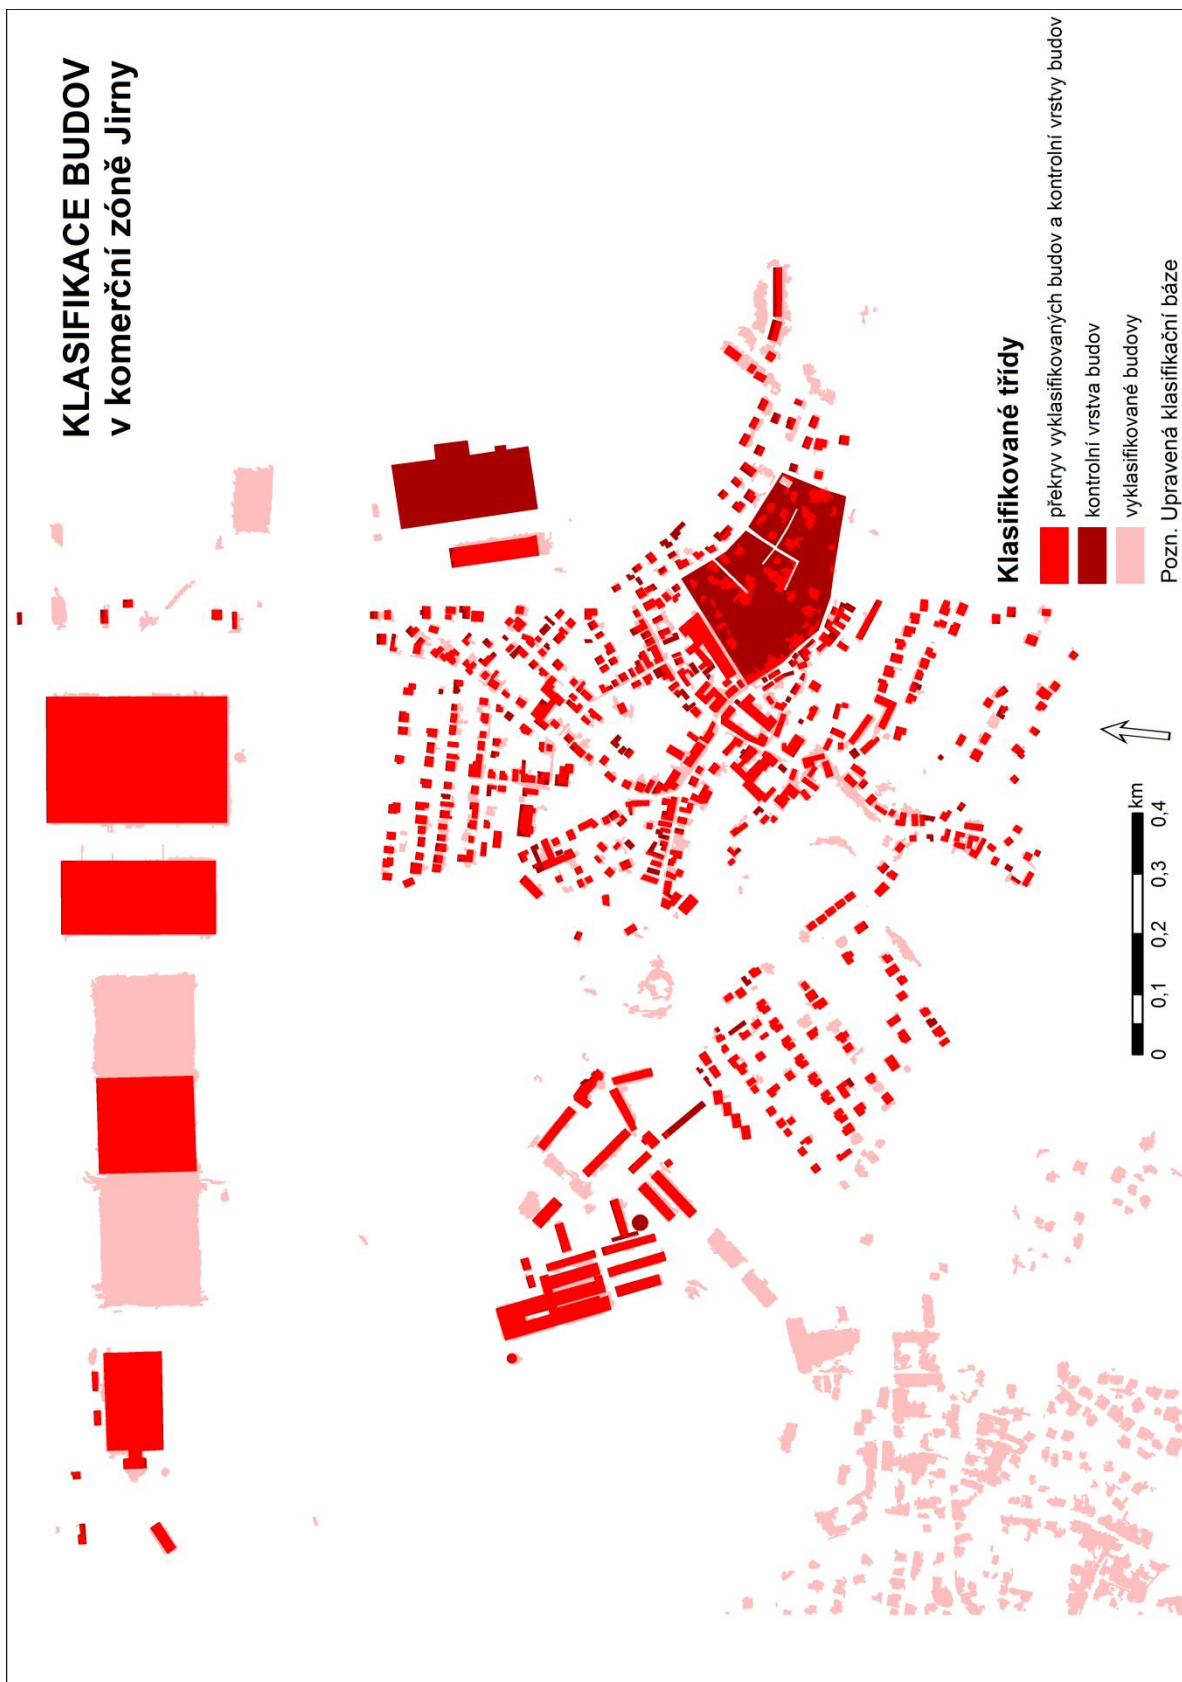
Příloha 5.3: Přesnost klasifikace budov v komerční zóně Jirny



Příloha 5.4: Přesnost klasifikace zpevněných povrchů v komerční zóně Jirny



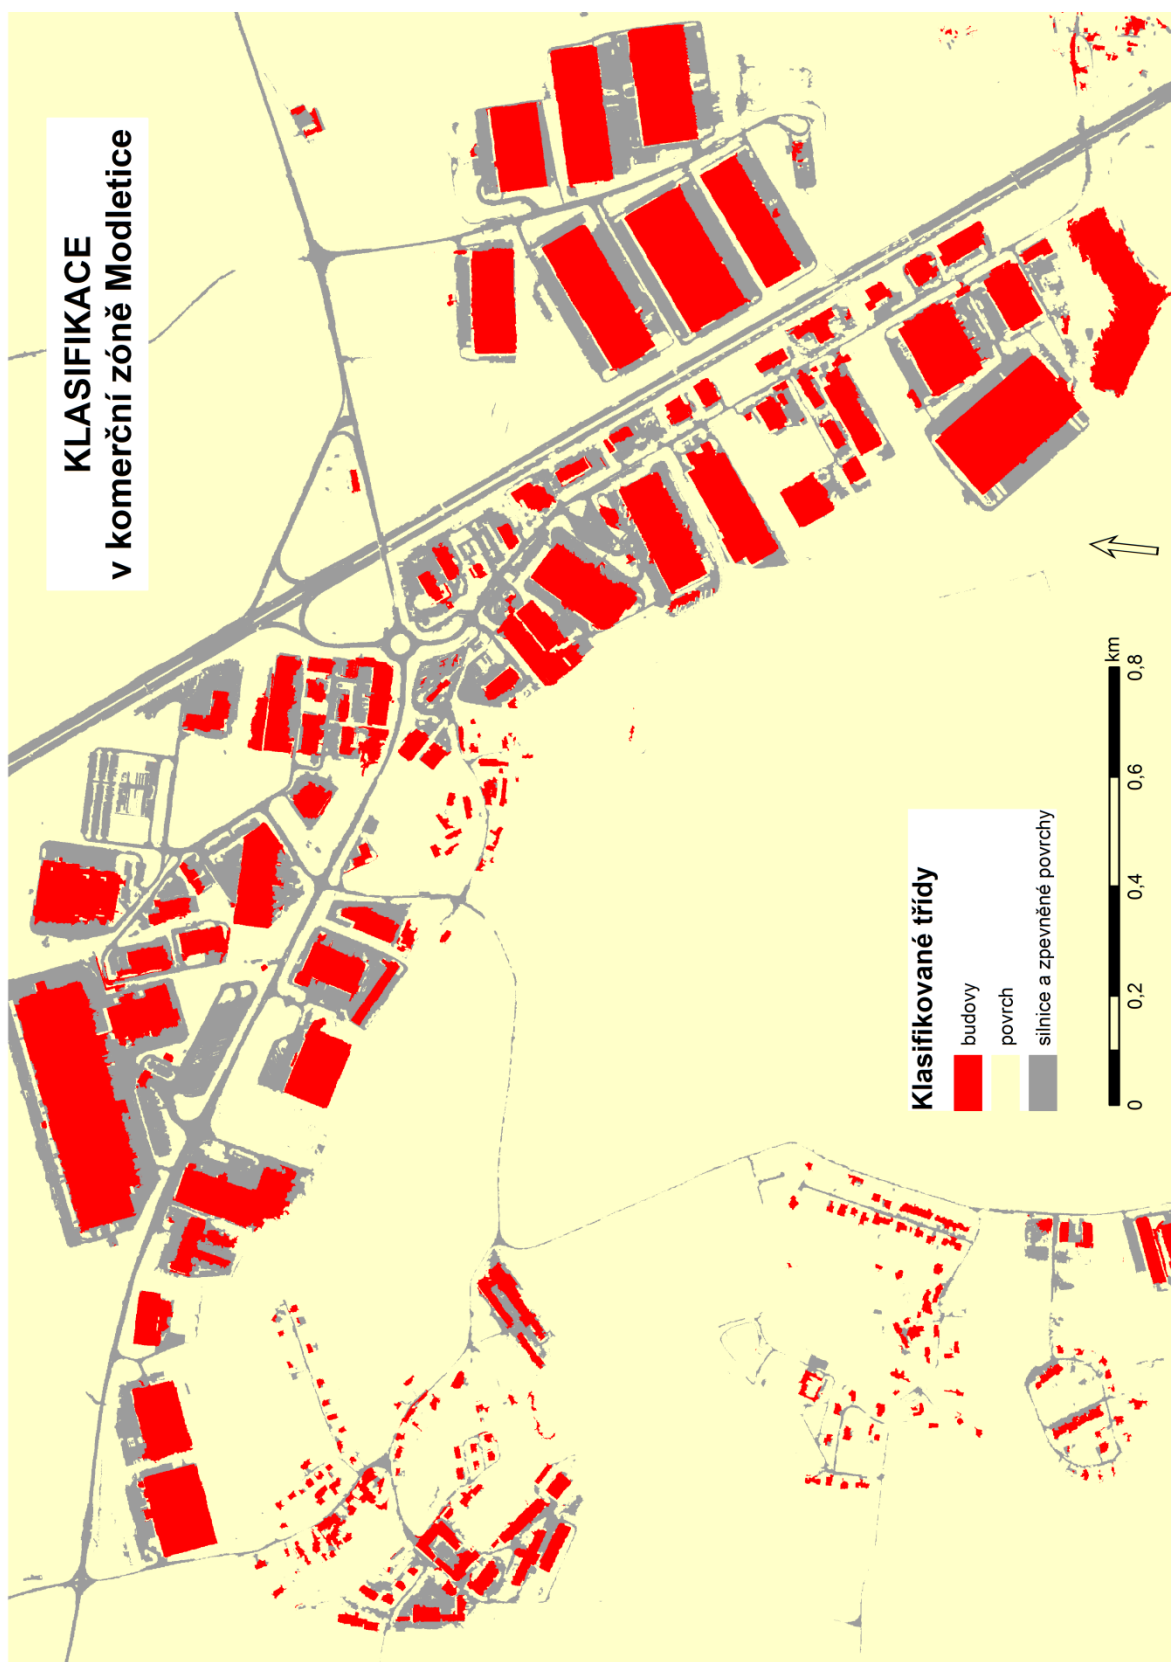
**Příloha 5.5:** Přesnost klasifikace budov s upravenou klasifikační bází v komerční zóně Jirny



**Příloha 5.6:** Přesnost klasifikace zpevněných povrchů s upravenou klasifikační bází v komerční zóně Jirny

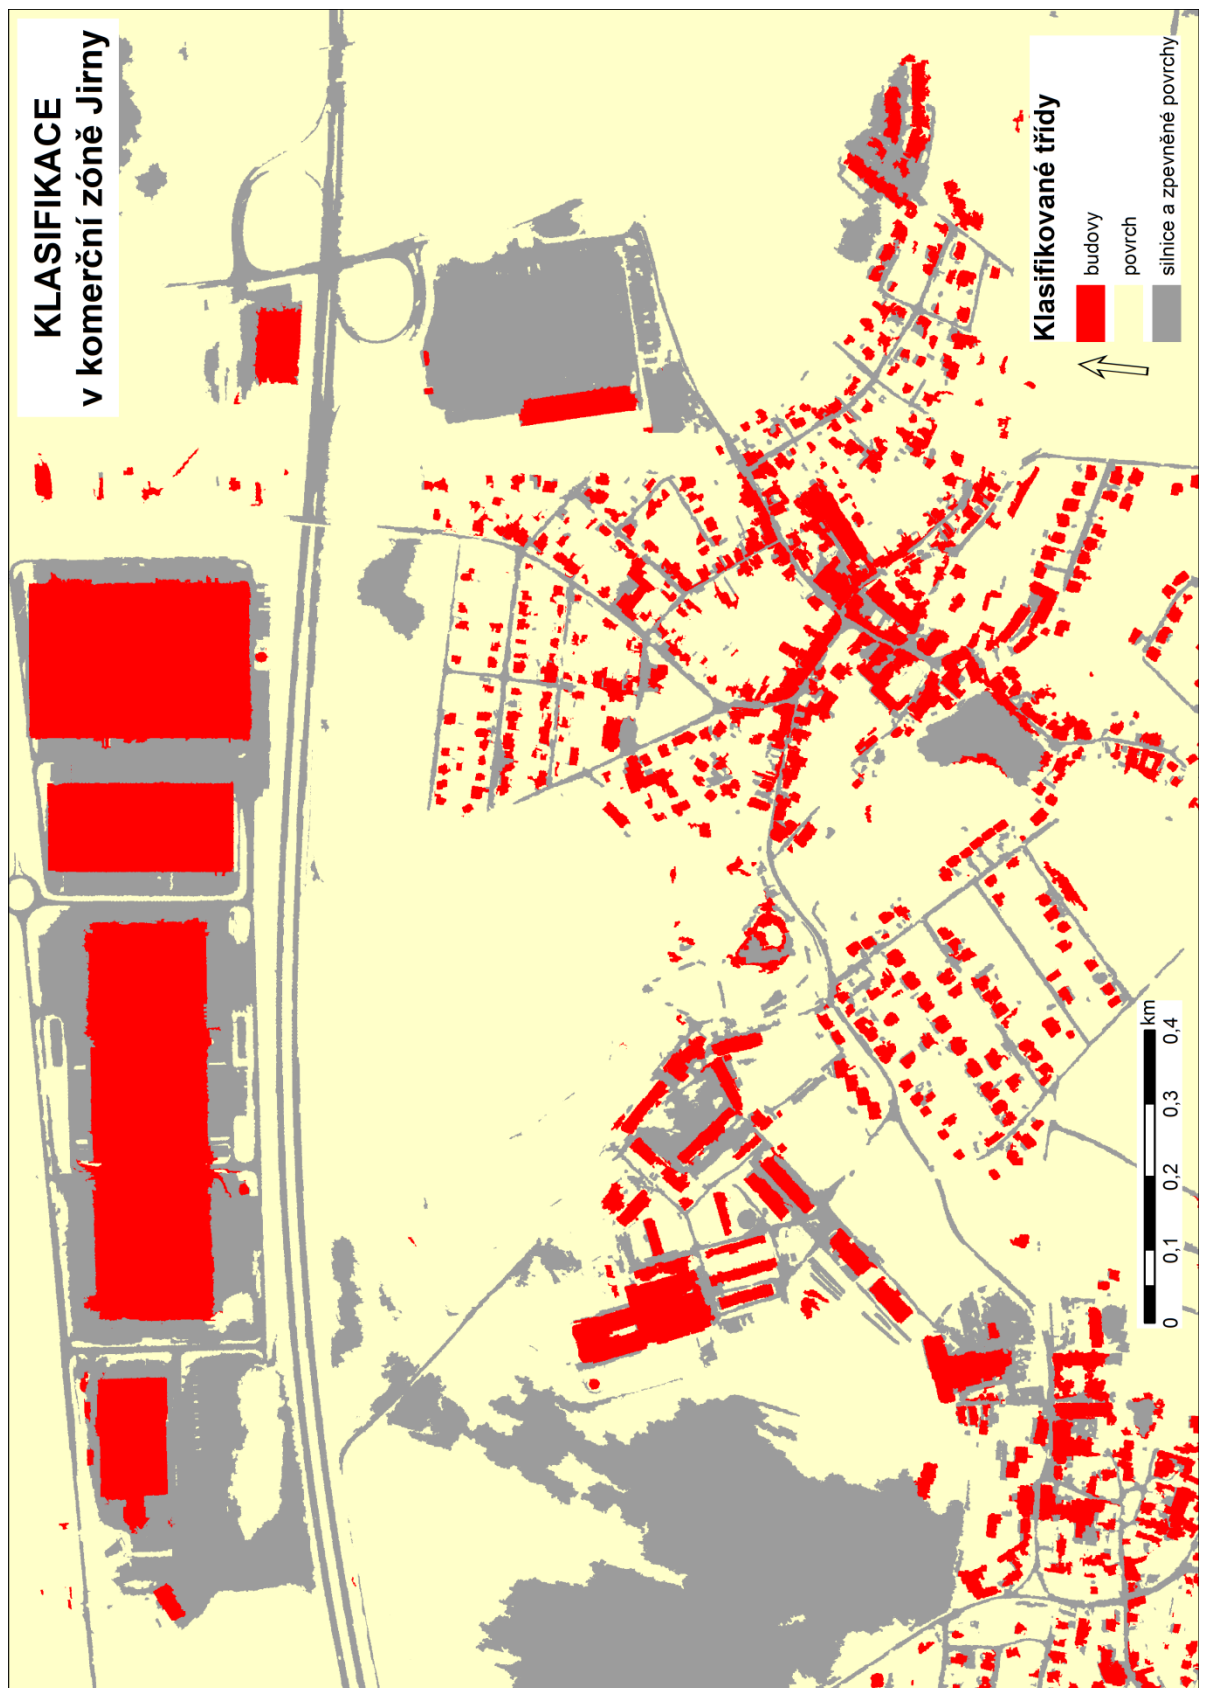


**Příloha 5.7:** Konečný upravený tematický výstup zpracovaný na základě výsledků podrobné klasifikace pro komerční zónu Modletice

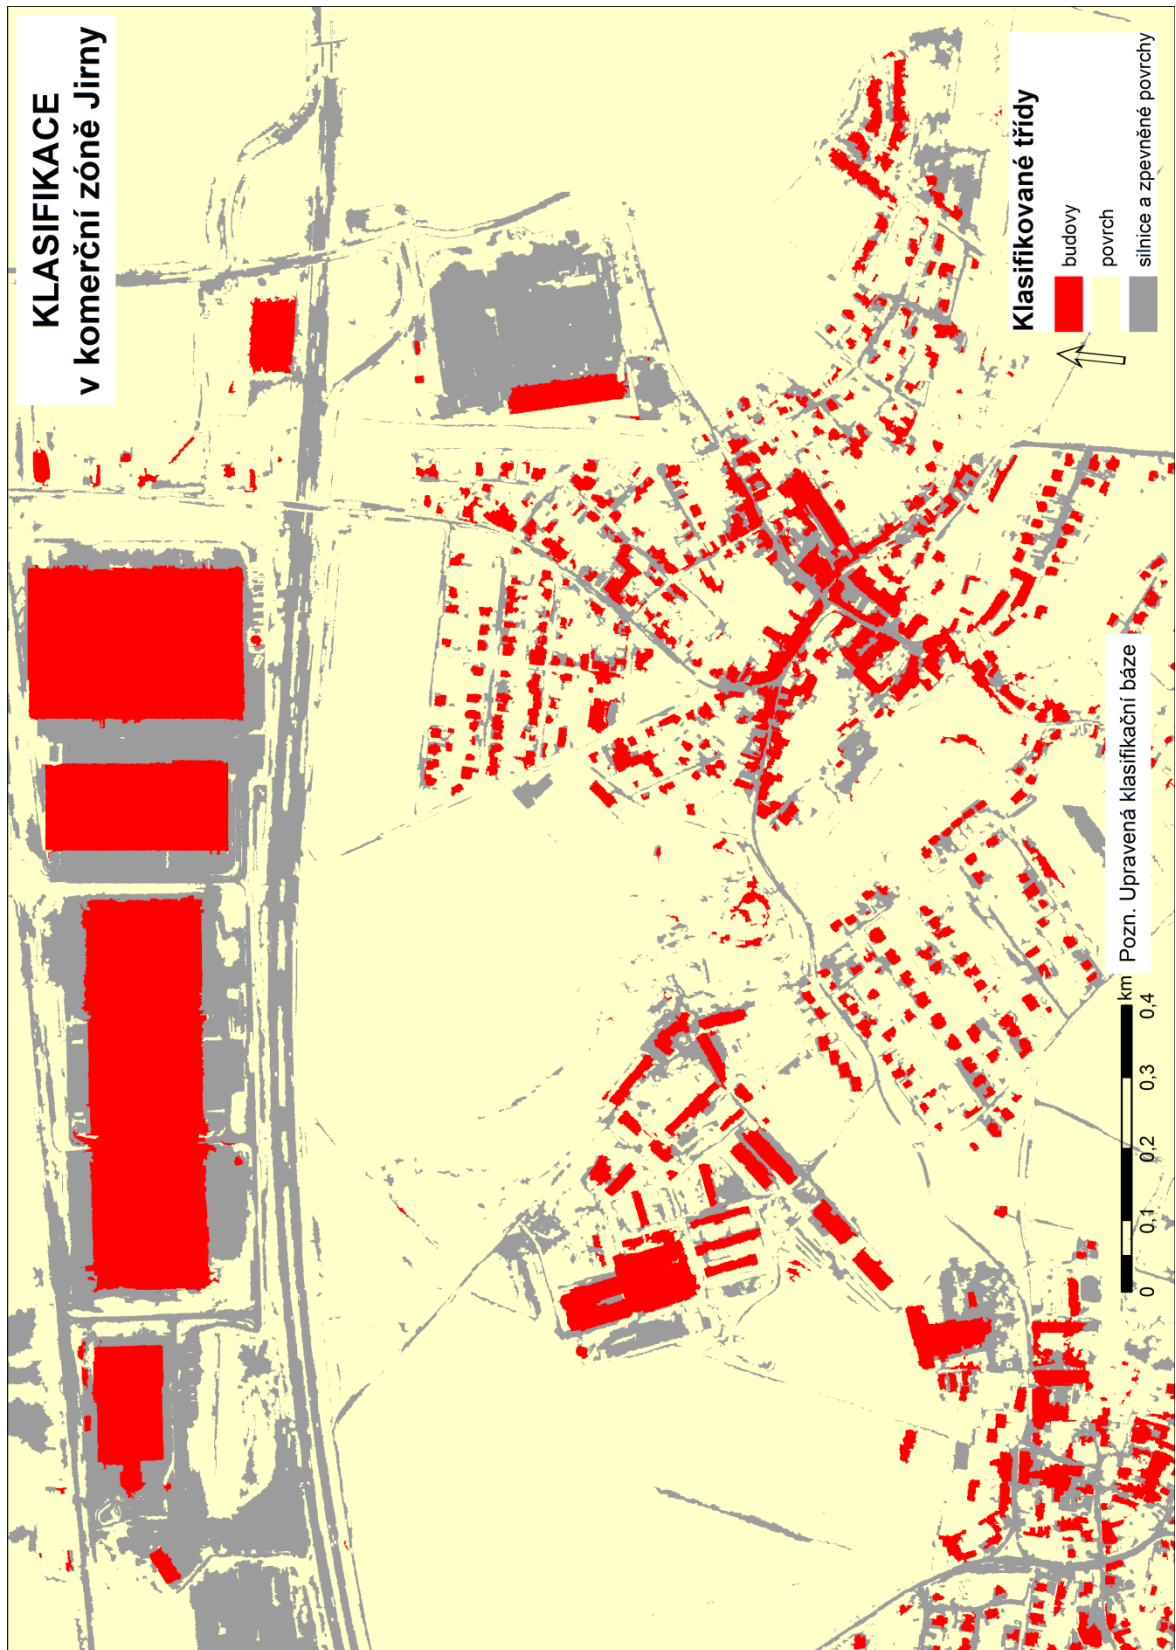




**Příloha 5.8:** Konečný upravený tematický výstup zpracovaný na základě výsledků podrobné klasifikace pro komerční zónu Jirny



**Příloha 5.9:** Konečný upravený tematický výstup zpracovaný na základě výsledků podrobné klasifikace s upravenou klasifikační bází pro komerční zónu Jirny



## Příloha 6: KLASIFIKACE BUDOVY NA ZÁKLADĚ VÝŠKY

**Příloha 6.1:** Staveniště na družicovém snímku (vlevo nahoře), budova ve vrstvě nDSM (vpravo nahoře), vyklasifikovaná budova (vlevo dole), budova na aktuálním ortofotu (vpravo dole)

