

Univerzita Karlova v Praze
Přírodovědecká fakulta

DIPLOMOVÁ PRÁCE

Irena Kopalová

***Semiautomatická aktualizace digitálních topografických
map s využitím snímků vysokého rozlišení***

Katedra aplikované geoinformatiky a kartografie

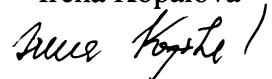
Vedoucí diplomové práce: Ing. Markéta Potůčková, Ph.D.

Studijní program: Kartografie a geoinformatika

Praha 2007

Prohlašuji, že jsem svou diplomovou práci napsala samostatně a výhradně s použitím citovaných pramenů. Souhlasím se zapůjčováním práce.

V Praze dne 2. 5. 2007

Irena Kopalová


Za odborné vedení mé diplomové práce, cenné náměty a podnětné připomínky děkuji Ing. Markétě Potůčkové, Ph.D. Za ochotné poskytnutí dat ZABAGED pak děkuji Českému úřadu zeměměřickému a katastrálnímu.

Zadání diplomové práce

pro Irenu Kopalovou
obor Kartografie a geoinformatika

Název tématu: Semiautomatická aktualizace digitálních topografických map s využitím snímků vysokého rozlišení

Aktualizace digitálních topografických map je v současné době prováděna z velmi většiny manuálně s využitím leteckých měřických snímků, ortofot, či družicových snímků. Diplomová práce se zaměří na postupy vedoucí k automatizaci tohoto časově náročného a nákladného procesu.

Zásady pro vypracování

1. Podat přehled stávajících v praxi využívaných metod aktualizace digitálních topografických map.
2. Navrhnut metodiku semiautomatického popř. automatického vyhledávání změn vybraných obsahových prvků topografické mapy s využitím obrazových dat.
3. Navrženou metodiku ověřit na Základní bázi geografických dat (ZABAGED) se zaměřením na zástavbu.

Dílčí úkoly:

- Volba vstupních dat
- Objektově orientovaná klasifikace zástavby v prostředí eCognition
- Porovnání výsledků klasifikace se stavem ZABAGED v prostředí GIS, vizualizace změn
- Zhodnocení dosažených výsledků a navržené metodiky, doporučení pro její praktické využití

Rozsah grafických prací: minimálně 2 (vizualizace výsledků klasifikace, přehled detekovaných změn)

Rozsah průvodní zprávy: 60 – 70 stran

Seznam odborné literatury:

Proceedings of ASPRS 2006 Annual Conference, Reno, Nevada; May 1-5, 2006.

ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 58, Issues 3-4, pp.127-258, Theme Issue: Integration of Geodata and Imagery for Automated Refinement and Update of Spatial Databases, January 2004

BLASCHKE, T. (2005): A framework for change detection based on image objects. In: Erasmi, S., Cyffka, B., Kappas, M. (Eds.) Göttinger Geographische Abhandlungen, Vol. 113, Göttingen.

KRESSLER, F.P., K. STEINNOCHER and M. FRANZEN (2005): Object-Oriented Classification of Orthophotos to support update of Spatial Databases. In: Proceedings of the IGARSS 2005 Symposium. Seoul, Korea. July 25-29, 2005.

Hnojil J., Zaoralová J. (2003): Řešení vybraných problémů spojených s aktualizací ZABAGED, Zdiby, VÚGTK, 25 s.

Vedoucí diplomové práce: Ing. Markéta Potůčková, Ph.D.

Konzultant diplomové práce:

Datum zadání diplomové práce: 23.10.2006

Termín odevzdání diplomové práce: duben 2006



Vedoucí diplomové práce



Vedoucí katedry

V Praze dne 23.10.2006

OBSAH

1	ÚVOD	8
2	ÚVOD DO PROBLEMATIKY	10
3	REŠERŠE LITERATURY	15
4	AKTUALIZACE TOPOGRAFICKÝCH MAP	19
4.1	AKTUALIZACE POMOCÍ LETECKÝCH MĚŘICKÝCH SNÍMKŮ	20
4.2	AKTUALIZACE POMOCÍ DRUŽICOVÝCH SNÍMKŮ VYSOKÉHO ROZLIŠENÍ.....	21
4.3	AKTUALIZACE POMOCÍ DRUŽICOVÝCH SNÍMKŮ VELMI VYSOKÉHO ROZLIŠENÍ.....	21
4.4	DALŠÍ METODY AKTUALIZACE TOPOGRAFICKÝCH MAP.....	23
4.5	AUTOMATICKÁ AKTUALIZACE MAP	23
5	VÝVOJ ZABAGED A METODY AKTUALIZACE	24
6	ANALÝZA OBRAZU	26
6.1	METODY KLASIFIKACE	26
6.2	METODY SEGMENTACE	28
7	METODY SEGMENTACE A KLASIFIKACE V PROGRAMU DEFINIENS ..	32
7.1	SEGMENTACE S MULTIROZLIŠENÍM	32
7.2	DALŠÍ METODY SEGMENTACE	34
7.3	KLASIFIKAČNÍ PROCES.....	34
8	POUŽITÁ DATA A JEJICH PŘÍPRAVA.....	36
8.1	SNÍMEK DRUŽICE QUICKBIRD	36
8.2	DATA ZABAGED	38
8.3	DIGITÁLNÍ MODEL POVRCHU	39
8.3.1	<i>Program SilverEye</i>	40
9	METODY	42
9.1	PRŮBĚH KLASIFIKAČNÍHO PROCESU.....	42
9.2	SEGMENTACE	43
9.3	KLASIFIKACE.....	45
9.3.1	<i>Základní úvaha</i>	45
9.3.2	<i>Obecný průběh postupu klasifikace</i>	46
9.3.3	<i>Klasifikace druhé segmentační úrovně</i>	47
9.3.4	<i>Klasifikace první segmentační úrovně</i>	49
9.4	SEGMENTACE A KLASIFIKACE S PŘIDÁNÍM INFORMACE O RELATIVNÍ VÝŠCE	53
10	VÝSLEDKY	55
10.1	ZHODNOCENÍ VÝSLEDKŮ KLASIFIKACE.....	55
10.1.1	<i>Vizuální interpretace</i>	55
10.1.2	<i>Statistické zhodnocení.....</i>	56
10.1.3	<i>Test přenositelnosti metody na výřezu obce Blatno</i>	60
10.2	VÝSLEDKY AKTUALIZACE ZABAGED	62

11	DISKUSE POUŽITÝCH DAT, METOD A VÝSLEDKŮ.....	64
11.1	DATA	64
11.2	POSTUP A VÝSLEDKY	65
11.3	POUŽITÍ VÝSLEDKŮ.....	66
12	ZÁVĚR	67
13	ABSTRAKT	69
14	SEZNAM LITERATURY	71
14.1	PRAMENY	71
14.2	LITERATURA.....	72
15	SEZNAM OBRÁZKŮ.....	79
16	SEZNAM TABULEK.....	80
17	SEZNAM PŘÍLOH	81

1 Úvod

Mapovací úřady a organizace vytvářející topografické mapy a geodatabáze pokrývající rozsáhlá území se potýkají s úkolem jejich dostatečně časté aktualizace. Manuální aktualizace map, kterou dodnes mapovací úřady ve většině případů využívají, je však velmi časově a finančně náročná. Tato práce se proto zaměří na zautomatizování tohoto procesu se zaměřením na budovy, které tvoří jednu z nejdůležitějších a nejrychleji se měnících složek topografických map.

Za podkladová data byl zvolen multispektrální snímek velmi vysokého rozlišení pořízený družicí Quickbird. Použití družicových dat pro topografické mapování není dosud obvyklé, do budoucnosti však představuje velký potenciál. Problematice automatické či semiautomatické aktualizace map na podkladu družicových snímků je ve světové literatuře věnována značná pozornost, v Česku je však doposud pouze zřídka předmětem výzkumu.

Hlavním cílem práce je vyvinutí metody pro provedení klasifikace družicového snímku Quickbird se záměrem nalezení změn v zástavbě pro aktualizaci Základní báze geografických dat (ZABAGED). Práce má odpovědět na otázku, zda může být vyvinuta taková metoda automatické klasifikace družicového snímku velmi vysokého rozlišení, kterou by bylo možné použít pro aktualizaci topografických dat a geodatabází.

Pro provedení klasifikace byl vybrán program Definiens 5 Professional, který používá objektově orientovaný způsob klasifikace. Jeho výhoda oproti metodám per pixel spočívá v tom, že kromě spektrálních příznaků mohou být při klasifikaci vyžity i další příznaky objektů jako např. tvar, textura nebo vztahy k sousedním objektům. Mimo to je možné se vyhnout vzniku málo spolu souvisejících tříd (tzv. efekt „soli a pepře“), který se často projevuje při použití konvenčních metod.

Dále budou v práci a při vývoji metody sledovány následující dílčí cíle:

- Bude podán přehled současných v praxi používaných metod a zdrojů dat pro aktualizaci topografických map.
- Výsledek klasifikace snímku Quickbird budou představovat polygony budov ve vektorovém formátu. Tato data budou porovnána se stávajícím stavem vektorové vrstvy budov v ZABAGED a data ZABAGED budou na podkladu výsledku klasifikace aktualizována.
- Snahou bude maximální stupeň automatizace procesu.

- K posouzení kvality navržené metodiky bude statistickými metodami určena přesnost klasifikace a zhodnoceny výsledky.
- Na dalším výřezu snímku Quickbird bude proveden test přenositelnosti navržené metody.

V návaznosti na stanovené cíle následují po tomto úvodu teoretické kapitoly věnující se rešerši literatury, metodám aktualizace topografických map, obecně metodám segmentace a klasifikace obrazu, objasnění principu objektově orientované klasifikace a principu klasifikace v programu Definiens. V druhé části jsou zařazeny kapitoly pojednávající o vyvinutých metodách a zhodnocení výsledků.

2 Úvod do problematiky

Pro organizace, které vytváří a spravují rozsáhlé kartografické databáze a geografické informační systémy, představuje hlavní problém požadavek dostatečně časté aktualizace těchto databází. Především aktualizace národních vektorových topografických dat, jako je digitální geografický model území ZABAGED spravovaný Českým úřadem zeměměřickým a katastrálním (ČÚZK), je velmi časově a finančně náročná. Stejný problém řeší i podobné instituce ve světě. Z tohoto důvodu jsou metody, které by vedly k urychlení a usnadnění tohoto procesu, cílem výzkumu již po dlouhou dobu (Ridley et al. 1997, Li 1998, Holland, Guilford, Murray 2002, Holland, Boyd, Marshall 2006). Výzkum v této oblasti zahrnuje 2 základní směry: metody vedoucí k automatické aktualizaci a metody detekce ploch, které se s velkou pravděpodobností změnily od poslední aktualizace (umožňují zaměřit zkoumání pouze do určitých oblastí a tím pádem zefektivnit manuální aktualizaci).

Široká dostupnost satelitních snímků velmi vysokého rozlišení přinesla nové možnosti detekce změn a aktualizace map užitím družicových dat. Prostorová rozlišovací schopnost multispektrálního skeneru neseného družicí QuickBird je 2,4 m a představuje v současnosti nejvyšší dostupné prostorové rozlišení družicového snímku. Multispektrální snímky pořízené družicemi Ikonos a Kompsat 2 mají prostorové rozlišení 4 m. Před dostupností těchto dat velmi vysokého rozlišení bylo k dispozici pouze prostorové rozlišení 20 m poskytované multispektrálním systémem neseném družicí Système Pour L'Observation de la Terre (SPOT). Zvýšení prostorového rozlišení je pro účely aktualizace map velmi důležité vzhledem k tomu, že mnoho zájmových objektů nemohlo být v družicových snímcích takto malého rozlišení jednoznačně určeno.

Uživatelé map a kartografických databází požadují, aby data byla pokud možno co nejaktuálnější. To je i cílem mapovacích úřadů a organizací. ČÚZK aktualizuje ZABAGED manuálně s využitím leteckých snímků a barevných ortofot ve tříletých intervalech (Český úřad zeměměřický a katastrální, 2007). Družicové snímky velmi vysokého rozlišení představují alternativu použitelnou pro tento účel, výhodu představuje zejména velikost plochy, kterou snímky pokrývají. Projekt organizace OEEPE (Holland, Guilford, Muray 2002) však demonstruje, že družicové snímky velmi vysokého rozlišení

trpí také některými podobnými neduhy jako digitální mono panchromatické letecké snímky, jako například:

- Pokrytí mraky
- Problémy způsobené nepřesným georeferencováním
- Ztížená interpretace objektů v kompaktních urbánních oblastech
- K přesnému zachycení objektů by napomohlo především použití stereo snímků a zaostření multispektrálních snímků snímkem panchromatickým.

Úroveň poskytovaných detailů je však v družicových snímcích velmi vysokého rozlišení značná i u scén, které obsahují relativně malé objekty. Potencionální aplikace těchto snímků mohou být rovněž v detekci změn v zastavěných oblastech, kde objekty zájmu dosahují velikosti alespoň 2x2 pixely, tzn. u snímků družice QuickBird 4,6 m (velmi malé budovy, části budov). Tabulka č. 1 předkládá analýzu různých typů objektů, které mohou být získány ze snímků družice QuickBird v různých měřítkách mapování.

Tab. 2.1: Analýza typů objektů, které mohou být získány ze snímků družice QuickBird v měřítkách mapování 1 : 2 500, 1 : 10 000 a 1: 25 000

Objekt	Popis výsledků analýzy	Měřítko 1:x		
		2500	10000	25000
Domy	Jednoduchá identifikace, možné zachytit jednoduchý tvar, není možné identifikovat výklenky, zákoutí	n	m	a
Ostatní budovy	Jednoduchá identifikace rozlehlých budov, především hospodářských budov; komplexní, mnohaúrovňové a střešní struktury obtížně identifikovatelné	n	a	a
Silnice	Uspořádání silnic zřejmé, obtížně identifikovatelné obruby, bílé linie viditelné	a	a	a
Významné krajinné změny	Velmi jasně identifikovatelné	a	a	a
Zemědělská pole	Jasně viditelné, obtížně klasifikovatelné	m	m	m
Vodní plochy a toky	Jasně identifikovatelné, některé malé toky obtížně identifikovatelné	m	a	a
Vegetace	Dobře definovaná v zaostřených snímcích	a	a	a

Pozn.: a = ano – objekt může být zachycen, n = ne – objekt nemůže být úspěšně zachycen, m = možná – objekt může být za určitých okolností zachycen

Zdroj: Holland, Boyd, Marshall (2006)

Detekci budov v družicových snímcích velmi vysokého rozlišení ovlivňuje nejen velikost prostorového rozlišení, ale i další faktory, které mohou způsobit chybnou analýzu obrazu. Chyby specifické pro urbánní prostředí mohou mít vliv na možné využití snímku a jeho klasifikaci. Jejich hlavní zdroje jsou podle Lhomme, He a Morina (2003) tři:

- Zemský reliéf ovlivňuje geometrickou přesnost snímku.
- Urbánní prostředí má vliv na kvalitu snímku. Význačnou charakteristikou urbánního prostředí je jeho složitost. Ta je způsobena častým opakováním mnoha prvků – přírodních i člověkem vytvořených, jejich proměnlivou velikostí a tvarem a jejich komplikovaným materiálovým složením. Tato složitost se mění od sídla k sídlu, ale vždy jasně odlišuje sídlo od krajiny.
- Komplikovanost urbánního prostředí způsobuje poruchy v odrazivosti, které mohou náhodně modifikovat záznam měřeného signálu. Snižují tedy tematický význam spektrálních příznaků. V extrémních případech, jako jsou stíny, mohou tyto poruchy zapříčinit chybu v klasifikaci snímku.

Snímky dálkového průzkumu Země s velmi vysokým rozlišením přesto poskytují velké množství dat o zemském povrchu použitelných pro detekci změn. V minulosti byly vyvinuty účinné metody zpracování signálu (např. Zhang 1999, Zhang et al. 2005 a další). Tyto metody však aplikují příslušné algoritmy na jednotlivé pixely nebo pravoúhlé plochy a neberou do úvahy informace vyplývající z kontextu. Tento způsob klasifikace je nazýván pixelově založený přístup nebo klasifikace per pixel. Při velké složitosti dat vede tento přístup k nežádoucímu efektu nazývanému „sůl a pepř“. Vzniká zde tedy rozdíl mezi teoreticky dostupnou informací a informací získanou a tedy využívanou. Výsledky jsou navíc ve většině případů prezentovány v rastrovém formátu, který není příliš vhodný pro kombinaci s jinými rastrovými daty ani s vektorovými GIS daty. Aby mohla být využita celá informace (spektrální charakteristiky i souvislosti uvnitř obrazu), musí být při zpracování obrazu použity další metody.

Možný způsob, jak se s výše uvedeným problémem vypořádat, je redukovat složitost snímku jeho rozdelením do homogenních segmentů ještě před vlastní klasifikací, která je pak označována jako objektově orientovaná. Ta je vhodná především u dat velmi vysokého prostorového rozlišení, u nichž je překročena určitá mez měřítka. Informace, která je zaznamenána pro jediný pixel, zde již není spjata s charakterem objektu nebo oblasti jako celkem, ale představuje jednotlivé komponenty objektů. Počet

interpretovatelných tříd narůstá a složitost skutečnosti se stává problémem (Hoffmann, van der Vegt, Lehmann 2000).

Základními jednotkami, se kterými se při objektově orientované analýze obrazu pracuje jsou segmenty, které nejsou analyzovány jen na základě svých spektrálních charakteristik. Výhodou objektově orientované analýzy je možnost využití statistických výpočtů, zahrnout do klasifikace strukturu objektů a jejich další vlastnosti jako tvar (délka, plocha, délka hranic apod.) nebo topologické vlastnosti (vztahy k sousedním objektům, vztahy k nadřazeným objektům apod.). Pozitivum představuje také blízký vztah a podobnost objektů ve snímku k objektům skutečně existujícím.

V závěru této kapitoly bych ráda uvedla několik pojmu, které jsou úzce spjaty s tématem objektově orientované analýzy obrazu a jejichž vysvětlení přispěje k jejímu porozumění (Steilen 2002):

- **Příznak (feature):** V rámci objektově orientované analýzy obrazu je nutné rozlišovat mezi příznaky obrazu a příznaky objektu. Příznaky obrazu, jako například spektrálně nebo texturálně homogenní oblasti, jsou použity k segmentaci, zatímco takto vytvořené segmenty resp. objekty jsou popsány příznaky objektů.
- **Obrazové objektové prvky (image object primitives):** Jsou výsledkem iniciální segmentace obrazu. Pouze v ideálním případě odpovídají geofyzikálním objektům. Většinou pokrývají pouze část zkoumaného objektu.
- **Objekty zájmu (objects of interest):** Objekty zájmu jsou vlastní předměty zkoumání. Vznikají složením z objektových prvků. Jsou vytvořeny pomocí znalostí o zkoumané oblasti nebo o sémantických souvislostech mezi objektovými prvky.
- **Fuzzy logika:** Software Definiens, ve kterém je tato práce zpracována, podporuje při klasifikaci fuzzy přístup. Klasický postup je založen na Booleově logice, která zná pouze stavy „pravda“ a „nepravda“. Podle této metody náleží objekt buď jednoznačně k určité třídě nebo do ní jednoznačně nenáleží. To ale neodpovídá lidskému vnímání. Fuzzy logika je přístup, který operuje s neurčitými a neprecizními vstupy způsobem podobným lidskému rozhodování (Zhang, Maxwell 2006). Nezná pouze dva jasné definované stavy, ale také mezihodnoty, které mohou být chápány jako stupeň pravděpodobnosti. Fuzzy klasifikátory jsou tedy vhodné pro extrakci vágních informací dálkového průzkumu Země. Při použití fuzzy klasifikace nedojde pouze k zapsání třídy k určitému objektu, ale objektu je přiřazen stupeň příslušnosti ke všem potencionálním třídám. Fuzzy logika také podporuje kombinace různých druhů vlastností objektů uvnitř

jednoho popisu třídy prostřednictvím rozdílných logických operátorů (Definiens AG, 2006a).

3 Rešerše literatury

Tématu zautomatizování procesu aktualizace map a detekce změn v obrazových datech byla již v minulosti věnována velká pozornost. Výzkum se zintenzivnil především poté, co začala být k dispozici satelitní a letecká data velmi vysokého rozlišení. Literatura zabývající se touto problematikou se objevuje zejména v zahraničních vědeckých časopisech a sbornících. V českém prostředí se jí dosud nedostalo značné pozornosti.

Zájem o automatickou aktualizaci digitálních topografických map a získávání topografické informace vzbudil u národních mapovacích agentur různých států světa příchod družicových a leteckých dat velmi vysokého rozlišení. Ridley et al. (1997) zkoumali potenciál simulovaných snímků družice IKONOS ještě předtím, než byly komerčně dostupné, pro aktualizaci a zlepšení kvality národní topografické databáze Velké Británie. Zaměřuje se na zautomatizování procesu aktualizace topografické informace a na redukci nákladů tohoto procesu. Hoffmann, van der Vegt a Lehmann (2000) uveřejnili metodu automatické aktualizace topografických map produkovaných národní nizozemskou topografickou službou (TDN). Cílem projektu byl test nových datových zdrojů a metod tak, aby mohl být zmenšen interval aktualizace mapových děl. Vývojem metody plně automatizované aktualizace topografických databází se zabývali Jodouin et al. (2002). Zveřejněný postup je založen na použití aktivních kontur v multispektrálních snímcích. Výsledky mezinárodního projektu, který se věnoval automatické aktualizaci land-use databází Rakouska, Belgie, Dánska, Finska, Německa, Irska, Švýcarska a Turecka publikovali Kressler, Steinnocher a Franzen (2005). Autoři prověřují možnosti přenositelnosti uveřejněné metody na databáze různých států. Holland, Boyd a Marshall (2006) zjišťují možnosti satelitních snímků velmi vysokého rozlišení pro aktualizaci topografických map. Uvádějí přehled dat, která je možno použít pro tento účel a příklady dosavadních projektů automatického mapování. Autoři se zaměřují na možné dnešní způsoby využití satelitních snímků velmi vysokého rozlišení mapovacími úřady a závěrem diskutují možný vývoj této problematiky v budoucnosti.

Problematiku multitemporální analýzy objektů řeší v teoretické rovině Blaschke (2005) a navrhuje konstrukční rámec pro objektově orientovanou detekci změn. Ten je dělen do dvou hlavních aspektů – geometrie a tematického obsahu. Autor odpovídá na některé specifické otázky týkající se detekce změn v družicových a leteckých snímcích.

Detekci změn se věnují i Lang, Schöpfer a Blaschke (2003). Navrhují postup objektově orientované klasifikace multitemporálních leteckých snímků městského prostředí pro získání změn specifických objektů. Walter (2004) se zabývá aktualizací GIS databáze využitím dat dálkového průzkumu Země. Představuje základní postup založený na objektově orientované klasifikaci, diskutuje použitá data a jejich multispektrální kanály, v závěru uvádí výsledky metody aplikované na modelovém území a rozsáhle diskutuje možnosti rozšíření a vylepšení. Metodu automatického získávání informací z leteckých a družicových snímků pro použití v GIS systémech uveřejnili Benz at al. (2004). Ve studii vysvětlují hlavní principy objektově orientované analýzy obrazu, popisují vlastnosti objektů, zdroje chyb v interpretaci snímku a postupy převodu objektů na vektor pro využití v GIS aplikacích. V závěru práce vše dokumentují na praktickém příkladu.

V Česku se tématu automatické aktualizace map věnuje pouze nevelké množství literatury. Hnojil a Zaoralová (2003) se zabývají vybranými problémy při aktualizaci ZABAGED pomocí dat katastru nemovitostí. Porovnávají typy objektů ZABAGED a katastru nemovitostí, jejich polohovou přesnost, možnosti současného zobrazení dat ZABAGED a změnových dat katastru nemovitostí pro identifikaci změn ZABAGED a možnosti případného převzetí některých typů objektů, například budov a správních hranic. Webové stránky Českého úřadu zeměměřického a katastrálního (<http://www.cuzk.cz>) popisují proces tvorby ZABAGED a postup současné manuální aktualizace. Hanuš (2002) zkoumá možnosti aktualizace polohopisných vektorových dat ZABAGED užitím družicových dat pořízených družicí EROS A1. Porovnává družicová data s polohopisem vektorizovaným metodikou Českého úřadu zeměměřičského a katastrálního.

Tématem hodnocení snímků velmi vysokého rozlišení a jejich vlastností pro aktualizaci národních mapových produktů se zabýval již Li (1998). Analyzuje satelitní snímkы velmi vysokého rozlišení, které v době vydání článku dosud nebyly dostupné, a jejich potenciál pro aktualizaci topografických databází. Zaměřuje se zejména na reprezentaci a extrakci výškové informace a geometrie a z tohoto zorného úhlu porovnává satelitní snímkы se snímkы leteckými. Zkoumá také možnosti využití získané informace k tvorbě a aktualizaci národních mapových produktů. Kumar a Castro (2001) podávají přehled vlastností snímků pořízených družicí Ikonons z hlediska použití těchto snímků pro účely mapování. Zaměřují se na odlišnosti od jiných komerčních satelitních snímků. Tyto vlastnosti jsou demonstrovány na praktickém příkladu land-cover mapování. Autoři se zabývají obzvláště geometrickou přesností a radiometrickou hloubkou obrazu. Analýze

chyb Ikonos snímků při identifikaci budov v městském prostředí se věnují autoři Lhomme, He a Morin (2003). Teoretická část studie obsahuje rozbor charakteristik snímků velmi vysokého rozlišení a zdrojů chyb specifických pro urbánní prostředí, druhá část dokládá teoretické aspekty na praktickém příkladu. Rossi (2003) podává přehled možných aplikací snímků z družice Quickbird. Studie se zaměřuje také na popis vlastností a hodnocení snímků a porovnání se snímky Ikonos.

Mezi nejrychleji se měnící složku map a topografických databází patří zástavba. Automatické detekci budov a domů se věnuje množství zahraniční literatury, která nahlíží na tuto problematiku z různých úhlů pohledu a nabízí různorodé metodiky řešení tohoto úkolu. Jeden z možných způsobů členění klasifikačních technik je rozdelení na vývojově starší pixelově založený přístup a modernější objektově orientovaný přístup, oba přístupy pak zpravidla kombinují další metody pro vylepšení výsledku klasifikace.

Objektově orientovaný přístup ke klasifikaci leteckých snímků použili již Lin a Nevatia (1998). Vyvinuli metodu vedoucí k segmentaci obrazu a extrakci budov i s jejich třetím rozměrem z 2-D leteckých snímků. Uplatňují techniku získání třetího rozměru z velikosti stínů vrhaných budovami. Hofmann (2001) se zabývá detekcí budov a silnic na snímku pořízeném družicí Ikonos. Užívá objektově orientované klasifikace obrazu. Porovnává výsledky klasifikace provedené s pomocí výškových dat laserového skenování a bez těchto dat. Lee, Shan a Bethel (2003) se věnují automatické extrakci budov užitím obou multispektrálních i panchromatických Ikonos snímků. Uvedená metoda spočívá v provedení klasifikace multispektrálních snímků za účelem získání přibližné polohy budov, přesná poloha a hranice budov jsou pak získávány z panchromatického snímku. Autoři používají tzv. ECHO klasifikátor (Extraction and Classification of Homogeneous Object), který nejprve segmentuje obraz do homogenních skupin pixelů, na které je poté aplikován klasifikátor maximální pravděpodobnosti. Objektově orientovaný přístup pro aktualizaci budov a silnic v mapách velkých měřítek pomocí Ikonos snímků zvolili autoři Marangoz, Oruc a Buyuksalih (2004). Výsledek klasifikace pak exportují do prostředí GIS pro účely aktualizace existujících topografických map a jiných map velkých měřítek. Stejný přístup ke klasifikaci snímků družice Quickbird s cílem extrahat budovy popisují i autoři Liu, Wang a Liu (2005). Klasifikační pravidla založili na fuzzy logice. Lemp a Weidner (2005) řeší problém klasifikace různých typů povrchů střech užitím hyperspektrálních a laserových dat přístupem založeným na segmentaci obrazu. Laserová data používají pro

získání přesných geometrických charakteristik střech a multispektrální data pro klasifikaci materiálu.

Konvenční multispektrální klasifikaci a pixelově založený přístup pro detekci budov popisuje Zhang (1999). Používá satelitní snímky s rozlišením 10 m. Metoda je určena pro rychlé informativní zjištění stavu budov a vývoje měst především v městských oblastech rozvojových zemí. Jung (2004) řeší problém detekce změn budov pro účely aktualizace geografické databáze. Postup je založen na porovnání multitemporálních stereopárů černobílých leteckých snímků a následné klasifikaci zájmových území, v nichž došlo ke změně výšky. Metodu detekce nově vzniklých vícepatrových budov v městském prostředí publikovali Zhang et al. (2005). Satelitní snímky středního rozlišení klasifikoval za užití pixelově založeného přístupu. Metoda měla vytvořit levnější alternativu dosavadního výzkumu založeného na leteckém snímkování. Ünsalan a Boyer (2005) kombinují pixelově založený a objektově orientovaný přístup klasifikace obrazu pro automatickou tvorbu map z Ikonos snímků. Cílem autorů je detektovat domy a ulice z velkých částí zemského povrchu v rychle rostoucích městských oblastech zejména pro účely vládních organizací států. Systém má umožnit rychlé automatické generování map nebo urychlení aktualizace map stávajících.

Porovnání objektově orientované a pixelově založené metody klasifikace obrazu z hlediska potenciálu těchto metod pro automatickou extrakci budov se venují Marangoz et al. (2004). Porovnáním obou klasifikačních přístupů pro různé aplikace se zabývají například Whiteside a Ahmad (2005), Kamagata et al. (2005) a další (Oruc et al. 2004, Willhauck 2000). Autoři se shodují, že objektově orientovaný přístup představuje efektivnější nástroj klasifikace leteckých i družicových snímků a dává přesnější výsledky než metody per pixel.

4 Aktualizace topografických map

Úkolem topografické kartografie je především kartografické zobrazení Země, tzn. objektů, které vznikly činností člověka nebo přírody. Tyto objekty bývají v čase i prostoru relativně stabilizované a lze je polohopisně i výškopisně zaměřovat metodami geodetickými, fotogrammetrickými, dálkovým průzkumem Země, či jinými vhodnými metodami (Veverka 2001).

Topografické mapování pomocí snímků dálkového průzkumu Země je prováděno po celém světě a využívá dat, která jsou pořizována neustále se zvětšujícím počtem senzorů. Tradiční fotografické komory jsou postupně nahrazovány digitálními komorami a skenery. V současnosti prováděné topografické mapování se stále ve většině případů opírá o letecký dálkový průzkum.

Mapování Země z vesmíru je předmětem výzkumu již téměř půl století. Po skončení Druhé světové války byly vystřeleny bývalé vojenské rakety nesoucí kamery, aby vyfotografovaly zemský povrch a již v šedesátých letech vznikla družicová fotogrammetrie na základě špionážních a interpretačních snímků specializovaných družic. Praktické civilní uplatnění přišlo po startu družice Landsat s multispektrálním skenerem s rozlišením 80 m v roce 1972 a později po startu družice Spot-1 v roce 1984, která byla vybavena elektronickým skenerem s rozlišením 10 m v panchromatickém režimu (Pavelka 2003).

Úkolem národních mapovacích úřadů je pořizovat a aktualizovat topografickou informaci co možná nejfektivněji a nejrychleji. Tento proces obvykle staví na velkém množství již dříve pořízených dat, shromažďovaných často i celá desetiletí. S výjimkou rozvojových zemí není většinou třeba mapovat znova celé území, ale pouze aktualizovat a rozšiřovat již dříve pořízené topografické informace. Použít družicové snímky vysokého a velmi vysokého rozlišení je možné podle dosavadních výzkumů v různých aplikacích, a to zejména pro detekci změn (pouze zjištění, že došlo ke změně), aktualizaci topografických map (měření a zanesení změny do databáze), kontrolu správnosti obsahu mapy (nezávislá kontrola správnosti databáze) a land-cover mapování. V současnosti se družicové snímky používají pro aktualizaci topografických map v době zmapovaných zemích pouze minimálně, výzkum však napovídá, že družicová fotogrammetrie bude hrát při sběru topografické informace stále větší roli (Holland, Boyd, Marshall 2006).

4.1 Aktualizace pomocí leteckých měřických snímků

Fotogrammetrie je již několik desetiletí používána ke sběru topografické informace. Dlouhou dobu bylo úkolem fotogrammetrů aktualizovat papírovou mapu pomocí leteckých měřických snímků velkého měřítka. Během přibližně posledního desetiletí se cíl práce fotogrammetrů změnil, jejich úkolem je nyní aktualizovat geodatabázi, obvykle pomocí digitálních snímků, které jsou buď skenovány nebo jsou přímo pořízeny digitální komorou.

Mapovací úřady často spravují rozsáhlé geodatabáze, každý objekt je v nich uložen se svou geometrií a připojenými atributy. Hlavním úkolem těchto úřadů je udržovat data v geodatabázích aktuální. Geometrické vlastnosti objektů jsou často získávány fotogrammetrickými metodami, přičemž letecké snímky budou hrát v tomto procesu s největší pravděpodobností i nadále významnou roli. Aktualizace map se v některých případech vztahuje k velkým inženýrským projektům jako jsou nové silnice a dálnice nebo nová sídliště, často ale znamená aktualizaci malých detailů, jako jsou změny jednotlivých budov, změny hranic polí nebo nové vedlejší silnice. Největší podíl na procesu aktualizace představuje vyhledávání těchto malých změn ve snímku. Pro tento účel se často používají letecké snímky vysokého rozlišení. Pro většinu činností mapovacích úřadů mohou poskytovat data i družicové skenery pořizující snímky vysokého a velmi vysokého rozlišení (Holland, Boyd, Marshall 2006).

Hoffmann, van der Vegt a Lehmann (2000) popisují obecný postup aktualizace digitálních topografických dat ve vektorovém formátu měřítka 1 : 10 000. Vektorové prvky databáze jsou aktualizovány na podkladu leteckých měřických snímků. Mimo to probíhá terénní šetření, při němž je také určena velká část změn. Proces aktualizace začíná vizuálním porovnáním leteckých snímků zvětšených do měřítka 1 : 10 000 s vektorovými daty vytisknými na průhledném filmu. Změny jsou poznamenány na leteckém snímku resp. na průhledném filmu. Toto porovnání je prováděno částečně v kanceláři a částečně v terénu. Po ověření v terénu jsou letecké snímky včetně změn skenovány. Paralelně s interpretací a prací v terénu probíhá fotogrammetrické zpracování dat. Nakonec jsou na podkladu naskenovaných měřických leteckých snímků změny digitalizovány.

4.2 Aktualizace pomocí družicových snímků vysokého rozlišení

V minulosti byla většina mapování pomocí družicových snímků prováděna v regionálním měřítku. Byly mapovány větší územní celky v malém měřítku za použití snímků pořízených družicemi SPOT, Landsat nebo podobnými družicovými skenery s rozlišením v řádu desítek metrů. Většina těchto projektů se týkala tematického mapování land-coveru spíše než tradičního topografického mapování. Tematické mapy vzniklé na podkladu družicových snímků se osvědčily především v oborech zemědělství, lesnictví, obhospodařování půd a jiných. V Evropské unii je běžné jejich použití při monitoringu výnosů zemědělské půdy. Bylo uskutečněno i několik pokusů o topografické mapování ze snímků družic Landsat, SPOT a dalších. Experimenty probíhaly zejména v těch částech světa, kde nejsou dostupné snímky z leteckého snímkování. Úspěšně byly vytvořeny například mapy Tanzanie (za použití Landsat MSS), Jemenu a Ománu (za použití SPOT), Vánočního ostrova (za použití Landsat TM a SPOT) (Ordnance Survey, 2007). Přestože tyto projekty byly z technického hlediska úspěšné, náklady spojené s vyrobením takovýchto map byly příliš vysoké ve srovnání s tehdejšími metodami leteckého snímkování. Důsledkem toho se tyto metody získávání a aktualizace topografických map nikdy nevyvinuly do takové míry, aby byly v praxi schopné provozu.

4.3 Aktualizace pomocí družicových snímků velmi vysokého rozlišení

Od poloviny 90. let, kdy bylo ohlášeno vypuštění komerčních družic schopných pořizovat snímky velmi vysokého rozlišení, se mapovací úřady začaly zajímat o možnosti využití těchto snímků pro své programy obnovy a údržby map. Jedním z prvních, kteří se zajímali o potenciál snímků družic Ikonos a Quickbird, byl britský Ordnance Survey. Výzkum simulovaných snímků Ikonos započal již v roce 1996, tedy dlohu předtím, než skutečné snímky pořízené touto družicí byly komerčně dostupné. Ridley et al. (1997) popisují projekt z roku 1996, během něhož byly zkoumány možnosti aktualizace topografických map pomocí Ikonos snímků, které byly pro tento účel syntetizovány ze snímků leteckých. Stejně tak Li (1998) předpokládal značný rozvoj ve využití satelitních snímků pro účely

mapování a ve svém výzkumu se zabýval potenciálem snímků Ikonos, Quickbird a OrbView pro účely aktualizace vektorových databází v měřítku 1 : 24 000.

Zpráva organizace Oeepe (Holland, Guilford, Murray 2002) popisuje výzkum využití snímků Ikonos pro topografické mapování, na němž se podílelo několik evropských mapovacích úřadů a institucí. Výsledky ukazují, že satelitní snímky velmi vysokého rozlišení mohou u mapovacích úřadů nalézt uplatnění. Je možné je použít především pro land-cover mapování a aktualizaci mnoha objektů obsažených v topografických mapách v měřítku 1 : 10 000 nebo menším.

Projekt Ordnance Survey (Holland, Marshall 2003; Holland, Marshall 2004; Holland, Boyd, Marshall 2006), zahájený roku 2003, zkoumal možnosti snímků Quickbird pro aktualizaci topografických map ve středním měřítku (1 : 25 000 až 1 : 50 000) a velkém měřítku (1 : 10 000 a větším). Závěry tohoto projektu ukazují, že je možné pomocí snímků Quickbird vytvořit topografickou mapu v měřítku až 1 : 6 000. Největší potenciál družicových snímků velmi vysokého rozlišení spočívá v jejich použití pro detekci změn a ověření správnosti mapy.

Družicové snímky pořízené družicemi Ikonos a Quickbird se v minulosti osvědčily zejména při mapování jinak nedostupných území, například oblastí vojenských konfliktů, jako Afghánistán nebo Irák. Tyto snímky byly také použity k aktualizaci map nebo vytváření kompletně nových map různých oblastí světa, jako například Saudské Arábie, Indonésie a Aljašky (Holland, Marshall 2004; Kumar, Castro 2001). Ve většině případů se jednalo o země, které nemají tradici podrobného mapování. V těchto oblastech, které obvykle nemají prostředky pro provádění systematického leteckého snímkování, mohou družicové snímky velmi vysokého rozlišení představovat rychlý a kvalitní zdroj dat pro vytváření topografických i tematických map.

V tradičních dobře zmapovaných oblastech světa, jako je například západní a střední Evropa, je situace odlišná. Podrobné databáze prostorových dat byly vytvářeny v průběhu mnoha let za použití jak metod geodetických tak fotogrammetrických. Navíc systém pořizování leteckých snímků je velmi dobře vybudován a ověřen. V těchto zemích je hlavním úkolem mapovacích úřadů údržba map, spíše než vytváření nové informace. Družicové snímky velmi vysokého rozlišení byly v takovýchto dobře zmapovaných oblastech použity jako zdroj dat ve velkých projektech pouze v několika málo případech (kupříkladu mapování Flander - European Space Imaging 2003).

4.4 Další metody aktualizace topografických map

Charakteristiku dalších metod aktualizace topografických map, které nejsou založeny na interpretaci obrazových dat a jejichž popis v dostatečné míře uvádějí jiná díla, jako jsou geodetické metody mapování (např. Anderson, Mikhail 1998) nebo mapování pomocí GPS (např. Owings 2005), zde pomíjím.

4.5 Automatická aktualizace map

Při extrakci topografických objektů, které se hodí pro automatický způsob mapování, je nutné si uvědomit, že krajina je velmi komplexní a současná inteligence počítačů se při získávání informací nevyrovnaná lidské intuici. Automatická extrakce objektů je v digitální fotogrammetrii předmětem výzkumu již přes 20 let (viz kap. 3) a využívá různých metod analýzy obrazu (viz kap. 6). Kontinuální výzkum této problematiky provádí již po několik let Ordnance Survey (Tompkinson et al. 2005). V současné době používá tato organizace převážně manuální metody sběru dat opírající se o interpretaci snímku člověkem. Přestože tyto metody jsou zavedené a ověřené mnoha lety používání, Ordnance Survey neustále usiluje o vylepšení efektivity a výkonnosti aktualizace topografických map prostřednictvím zvětšování podílu automatických technologií interpretace obrazu.

I přes dlouhotrvající výzkum se dosud nepodařilo vynalézt takový detektor hran, který by je vždy uspokojivě identifikoval a označil (Tompkinson 2005). Pokud se zaměříme na urbánní oblasti, objekty, které mohou být aktualizovány, představují budovy, silnice a parkoviště. Extrakce těchto objektů se nemusí zdařit, protože pouze zřídka kdy existuje nějaký obecný vzor, podle něhož by bylo možné tyto objekty od sebe rozpoznat. Například budovy jsou topografické objekty, u kterých je pro jejich úspěšnou extrakci nutná i znalost sémantických informací. Tyto objekty mají rozdílnou velikost a uspořádání, navíc faktory, jako například stíny a úhel dopadu slunečních paprsků (především na odlišně skloněné části střechy), způsobují zmatení algoritmu zkonstruovaného pro extrakci obrysů budov. Pro úspěšnou extrakci objektů reálného světa je proto nutné do procesu detekce a extrakce začlenit i sémantickou informaci (Tompkinson 2005).

5 Vývoj ZABAGED a metody aktualizace

ZABAGED je digitální geografický model území České republiky, který svou přesností a podrobností zobrazení geografické reality odpovídá přesnosti a podrobnosti Základní mapy České republiky v měřítku 1 : 10 000 (ZM 10). Má charakter geografického informačního systému (GIS), integrujícího prostorovou složku vektorové grafiky s topologickými relacemi objektů a složkou atributovou, obsahující popis objektů a další informace. Obsah ZABAGED je řazen ve třech úrovních: kategoriích typů objektů (8 kategorií), typech objektů (106 typů) strukturovaných v databázi do 63 tematických vrstev a attributech objektů, jež podrobněji charakterizují většinu typů objektů (Mikšovský, Šídlo 2001). ZABAGED obsahuje informace o sídlech, komunikacích, rozvodných sítích a produktovodech, vodstvu, územních jednotkách a chráněných územích, vegetaci a povrchu a prvcích terénního reliéfu. Součástí ZABAGED jsou i vybrané údaje o geodetických, výškových a tíhových bodech na území České republiky a výškopis reprezentovaný prostorovým 3D souborem vrstevnic.

Prvotní naplnění ZABAGED zahájil Zeměměřický úřad již v roce 1995 vektorovou digitalizací tiskových podkladů ZM 10. Tato základní digitalizace byla s výjimkou zástavby sídel dokončena v roce 2001. V období do konce 1. čtvrtletí roku 2004 byla ZABAGED doplněna o geografické objekty zástavby sídel, do databáze byly přidány další popisné a kvalitativní atributy včetně vybraných druhů identifikátorů a jednotlivé ukládací jednotky v kladu ZM 10 byly spojeny do tzv. bezešvé databáze (Český úřad zeměměřický a katastrální, 2007). Současně od roku 2001 probíhala první celoplošná aktualizace ZABAGED s cílem zpřesnění a zaktualizování polohopisné složky a revize a doplnění atributové části databáze. Technologie plošné aktualizace byla založena převážně na superimpozici digitálních ortofotomap s vektorovým obrazem získaném po prvotním naplnění databáze. Tento postup se využíval převážně v extravilánech a malých intravilánech s řídkou zástavbou. Ve velkých intravilánech byla použita metoda stereofotogrammetrického vyhodnocení. Využíváno bylo také topografické šetření přímo v terénu (Koncepce 2. etapy vývoje Základní báze geografických dat, 1999). Tato první aktualizace byla ukončena v roce 2005.

V letech 2005 a 2006 byla vedle pokračující aktualizace dat vyprojektována a v závěru roku 2006 provozně nasazena nová technologie aktualizace a správy ZABAGED.

Vytvořena je centrální databáze, která bude nadále aktualizována v režimu online z detašovaných teritoriálních pracovišť Zeměměřického úřadu. Souběžně bude centrálními pracovišti Zeměměřického úřadu v Praze zajišťována aktualizace vybraných prvků ZABAGED ve spolupráci s centrálními orgány státní správy s cílem zajištění systémových vazeb informačních systémů veřejné správy. Další periodická aktualizace a doplňování ZABAGED budou realizovány ve tříletých cyklech s využitím vždy nově zpracovaných leteckých měřických snímků a barevných ortofot, která budou každoročně vytvářena pro jednu třetinu území České republiky (Český úřad zeměměřický a katastrální, 2007).

6 Analýza obrazu

6.1 Metody klasifikace

V praktické části této práce je aplikován software Definiens 5 Professional, který používá objektově orientovanou metodu klasifikace. Tato kapitola má objasnit, v čem spočívá výhoda objektově orientované klasifikace v porovnání s tradičními pixelově založenými metodami. Nejprve je zapotřebí podat přehled metod per pixel.

Při pixelové klasifikaci dat dálkového průzkumu pomocí počítače je využíváno rozdílných odrazivých vlastností objektů, přičemž objekty (resp. pixely) s podobnou odrazivostí jsou přiřazeny k jedné skupině v příznakovém prostoru. Příznakový prostor je určen počtem použitých spektrálních kanálů. Aby mohl být každý shluk bodů resp. každý pixel přiřazen v příznakovém prostoru určité třídě objektů s informačním obsahem, je potřeba rozhodovacího pravidla. Metody klasifikace jsou zpravidla rozlišovány na klasifikaci řízenou (supervised) a neřízenou (unsupervised) (Halounová, Pavelka 2005).

Principem neřízené klasifikace je agregace pixelů se stejnou nebo příbuznou spektrální odezvou do shluků (clusterů). Výsledkem jsou spektrální třídy založené pouze na blízkých hodnotách odrazivosti ve všech použitých spektrálních pásmech, kterým je až poté přiřazován informační obsah. Po klasifikaci je nutné provést šetření, co která třída představuje, na základě znalosti terénu nebo z dalších tematických podkladů (Halounová, Pavelka 2005). Tento způsob analýzy dat je často používán pro přípravu řízené klasifikace, protože rychle poskytuje informace o spektrální oddělitelnosti dat.

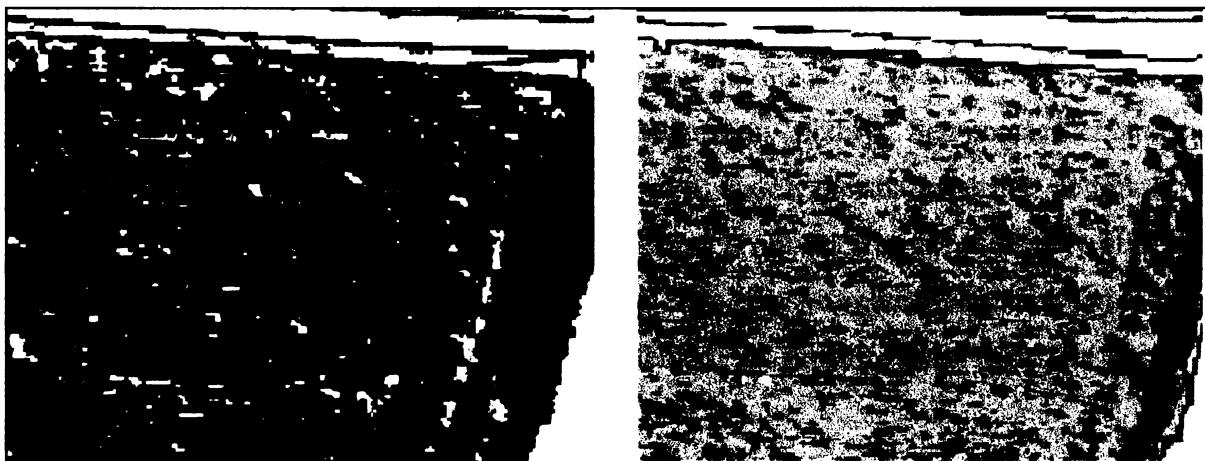
Naproti tomu řízená klasifikace používá známé spektrální vlastnosti hledané třídy. Začíná výběrem trénovacích ploch, tedy trénovacího souboru představitelů jednotlivých tříd, které jsou od sebe spektrálně oddělitelné. Kvalita klasifikace je přitom vždy závislá na výběru trénovacích ploch. Pro provedení řízené klasifikace jsou používány převážně tři klasifikační algoritmy (Tomowski et al. 2006):

- Klasifikátor minimální vzdálenosti (minimum distance classifier) používá informaci o umístění každé třídy v x-rozměrném kartezském prostoru definovaném x spektrálními pásmi. Pixel je zařazen do té definované třídy, jejíž střed se v tomto prostoru nachází nejblíže.
- U klasifikátoru pravoúhelníků (parallelepiped classifier) jsou ve spektrálních kanálech definovány horní a dolní hranice pro hledané třídy, které

v dvourozměrném prostoru vedou k vytvoření pravoúhelníků. Připsání pixelu ke třídě nastane tehdy, když naměřené spektrální hodnoty leží uvnitř definovaného pravoúhelníku, v opačném případě zůstane pixel neklasifikován. Pokud se pravoúhelníky překrývají, je nutné definovat pravidla pro zařazení pixelu.

- Klasifikátor maximální pravděpodobnosti (Maximum likelihood classifier) počítá hodnotu pravděpodobnosti náležitosti pixelu ke třídě na základě trénovacích ploch prostřednictvím statistických parametrů. Vychází z předpokladu, že spektrální hodnoty určitého objektu vykazují normální rozložení kolem střední hodnoty trénovací plochy. Připsání pixelu ke třídě nastane tehdy, když je pravděpodobnost náležitosti pixelu ke třídě nejvyšší. Korelace dat vede k eliptickému tvaru izolinií stejné pravděpodobnosti. Klasifikátor maximální pravděpodobnosti dospívá ve srovnání se třemi představenými metodami per pixel zpravidla k nejlepším klasifikačním výsledkům.

Obr. 6.1: Porovnání výsledku klasifikace per pixel, která způsobila vznik málo spolu souvisejících tříd (vlevo), a objektově orientované klasifikace (vpravo)



Zdroj: Schiewe, Tufte, Ehlers (2001, s. 35)

Pokračující technický vývoj vede ke stále lepšímu radiometrickému, spektrálnímu, prostorovému a časovému rozlišení, především neustále se zvětšující prostorové rozlišení umožňuje přesnější vizuální interpretaci a lepší vymezení objektů. Se zvyšováním prostorového rozlišení narážejí ale výše zmínované metody per pixel na své hranice. Sice již tak mnoho nedochází k míchání spektrálních hodnot v rámci jednoho pixelu a měřené

hodnoty odrazivosti jsou tedy jednoznačnější, přibývá ale spektrální heterogenita uvnitř jednotlivých objektů. To vede u klasifikace per pixel ke vzniku mnoha rozdílných a málo spolu souvisejících tříd (Blaschke, Strobl 2001), viz obrázek 6.1 představující efekt „soli a pepře“, který vznikl při použití klasifikátoru maximální pravděpodobnosti ve srovnání s objektově orientovanou metodou.

Další nevýhodou metod per pixel je vznik třídy neklasifikovaných pixelů, které je třeba přiřadit použitím následné analýzy pomocí neřízené klasifikace nebo prostřednictvím segmentačních technik založených na regionech (region-based segmentation techniques). Druhá metoda vychází z předpokladu, že pixel přísluší s vysokou pravděpodobností ke stejné třídě jako pixel sousední. To znamená, že obraz je nejdříve segmentován do homogenních regionů sestávajících z podobných pixelů a na závěr jsou vytvořené segmenty (objekty) klasifikovány (Tomowski et al. 2006). Přehled metod segmentace obrazu je podán v následující kapitole.

6.2 Metody segmentace

Metody segmentace pro analýzu obrazu jsou známy již 30 let. Základem všech metod je předpoklad pravděpodobné korelace mezi sousedními pixely. Segmentace znamená seskupení sousedících pixelů do regionů (segmentů) spočívající na kritériích podobnosti. Cílem je rozdělení obrazu do souvislých homogenních oblastí, kterým může být přiřazen nějaký význam. Nositeli významu jsou tedy objekty získané segmentací a ne jednotlivé pixely. Tak můžeme mimo jiné získat přehled o prostorovém rozložení pixelů (Braumann 2006).

I přes to, že výzkum v této oblasti probíhá již delší dobu (např. Kettig, Landgrebe 1976), prosadila se segmentace obrazu v dálkovém průzkumu Země teprve později. Především z důvodů zvyšujícího se prostorového rozlišení snímků nabývají dnes tyto metody na významu (Neubert, Meinel 2003).

Existuje zde souvislost mezi segmentací a klasifikací. Požadavek, aby segmenty představovaly reálné objekty, vede k základnímu problému segmentace. Vytvoření smysluplných objektů předpokládá určité vědomí o příslušných třídách. Příslušnost ke třídám je ale určena až v následné klasifikaci. Tato vzájemná závislost segmentace a

klasifikace může být zohledněna tím, že bude použita iterativní metoda (kroky segmentace a klasifikace jsou po sobě několikrát opakovány) (Schneider 2002). Kvalita klasifikace velmi závisí na výsledku a kvalitě segmentace. Kritéria pro tvorbu segmentů jsou podle Braumann (2006) následující:

- Spektrální a texturální homogenita pixelů uvnitř jednoho segmentu
- Spektrální a texturální nepodobnost pixelů sousedních segmentů
- Jednoduchý tvar hranic segmentů
- Speciální tematické vědomosti

Metody segmentace je možné rozdělit do následujících skupin, přičemž ne vždy je možné jejich jednoznačné vymezení (Schiewe 2006):

- Segmentace založená na detekci regionů (region-based segmentation)
- Segmentace založená na detekci hran (edge-based segmentation)
- Segmentace pomocí prahování (threshold-based segmentation)

Segmentace založená na detekci regionů

Základním principem je rozdělení obrazu do regionů s maximální homogenitou. Kritéria homogeneity se mohou vztahovat na různé parametry: hodnoty šedi, textura, tvar atd. Hledaná je homogenita uvnitř segmentu, tzn. mezi pixely. Tento způsob segmentace se ukázal jako dobře aplikovatelný pro klasifikace snímků velmi vysokého rozlišení.

Podle Tomowského et al. (2006) je principieltě možné rozlišovat tři způsoby segmentace založené na detekci regionů: segmentace metodou narůstání oblastí (region growing), segmentace metodou dělení oblastí (region splitting) a jejich kombinace metoda dělení a sloučení (split and merge).

Metoda narůstání oblastí je metoda „zdola nahoru“ (bottom-up), u které je na počátku definován startovací region prostřednictvím náhodného zadání tzv. seed pixelu. K tomuto pixelu jsou postupně přidávány další pixely z bezprostředního sousedství, pokud vyhovují definovaným kritériím homogeneity. Jakmile jsou překročeny mezní hodnoty kritérií homogeneity, je na jiném místě stanoven nový seed pixel. Tento proces pokračuje tak dlouho, dokud není celý obraz rozdelen do segmentů. Nevýhodou segmentace s jedním náhodně zvoleným startovním regionem je vznik nestejně velkých a různě rozložených segmentů. Pomocí může být stanovení více současně rostoucích seed pixelů.

Metoda dělení oblastí je metoda „shora dolů“ (top-down), u které je na počátku nahlíženo na celý obraz jako na potencionální segment. V prvním kroku je testováno, zda

je či není splněno definované kritérium homogeneity. Pokud tomu tak není, je celá plocha rozdělena do dělicích ploch a opakováno přezkoušení kritéria homogeneity pro každou takovouto plochu. To je opakováno u každé rozdělené plochy tak dlouho, až žádné další dělení ploch není možné. Nevýhodu představuje generování příliš velkého počtu malých regionů, které nereprezentují skutečné rozložení v prostoru a jejich hranice inklinují k tomu být hranaté a uměle vykonstruované.

Řešením tohoto problému může být kombinace těchto dvou metod, metoda dělení a sloučení. Po rozdělení rastru do čtverců je přezkoušeno, zda jsou sousední plochy natolik homogenní, že mohou být znova sjednoceny. Při použití tohoto algoritmu dochází sice k vytvoření větších segmentů než u metody dělení oblastí, nicméně zůstává u vzniklých objektů nepřirozený tvar (hranaté hrany) a je zapotřebí další dodatečné zpracování.

Segmentace založená na detekci hran

Na rozdíl od segmentace založené na detekci regionů je zde rozhodující nestejnorodost na okrajích segmentů. Tato metoda začíná hledáním oblastí diskontinuit v obraze s předpokladem, že se v těchto místech nacházejí hranice segmentů. Hrany jsou v obraze charakterizovány velkými změnami v hodnotách šedi. Pro tento postup vyhledávání jsou k dispozici různé detektory hran, jako například Laplaceův nebo Sobelův operátor. Po provedené detekci jsou hrany seskupeny a tím zhotovena síť hranic. Výhodou je vznik jednoduchých hranic segmentů (Braumann 2006). Nevýhodu představuje, že dochází k vytváření příliš velkého množství segmentů, které musí být dodatečně manuálně vyčištěny. Pro satelitní snímky velmi vysokého rozlišení je tato metoda vhodná pouze částečně, protože mnoho oblastí, jako jsou například oblasti s mnoha rozdílnými přechody hodnot šedi (kupříkladu urbánní prostředí), není pomocí gradientů hodnot šedi jednoznačně rozlišitelných (Schiewe 2006).

Segmentace pomocí prahování

Prahování je jedna z nejstarších a nejjednodušších metod segmentace obrazu a patří také k jedné z nejrychlejších. Zpravidla se používá, pokud je třeba získat binární obraz nebo obraz s redukovaným počtem hodnot šedi. Její využití je možné u obrazů, u nichž je obraz v „pozadí“ a hledaný objekt vystupuje do „popředí“, čímž je myšleno, že jasové (barevné) hodnoty prvků obrazové funkce objektů (pixelů) jsou odlišné od pozadí. Při segmentaci se nejprve posuzuje rozdělení hodnot šedi, ověřuje se, zda jsou si hodnoty šedi podobné. Poté

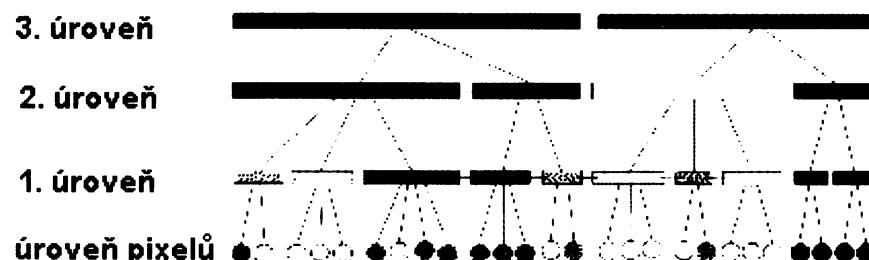
jsou pomocí analýzy histogramu hledány prahové hodnoty. V ideálním případě leží v lokálních minimech histogramu (Ličev 2001). Segmentace pomocí prahování se při vyhodnocování satelitních snímků používá zpravidla jen zřídkakdy, protože jeden objekt zde bývá reprezentován mnoha rozdílnými hodnotami šedi (Tomowski 2006).

7 Metody segmentace a klasifikace v programu Definiens

7.1 Segmentace s multirozlišením

Program Definiens používá pro segmentaci obrazu metodu nazvanou segmentace s multirozlišením (multiresolution segmentation), která je založena na metodě růstu regionů (region growing). Umožňuje extrakci homogenních objektů ve volitelných měřítkách, tzn. možnost generovat po sobě několik úrovní objektů vycházejíce z úrovně pixelů, přičemž úrovně se liší velikostí segmentů (rozlišením). Z nejnižší úrovně (úroveň pixelová) vychází 1. úroveň, shlukující určitý počet pixelů do tříd této úrovně, sloučením několika objektů 1. úrovně vznikají objekty 2. úrovně apod. Topologicky jsou data mezi úrovněmi čistá, tj. hranice třídy vyšší úrovně je shodná s jednou či více hranicemi tříd nižší úrovně. Segmentace v různých úrovních může vycházet z různých dat (Definiens, 2006b). Vzniklé segmentační úrovně a jejich vztahy jsou vyjádřeny hierarchickou sítí (viz obrázek 7.1).

Obr. 7.1: Vytváření hierarchické sítě v Definiens



Zdroj: Steilen, 2002

Velikost objektů (Scale Parameter) je jedním z rozhodujících kritérií a závisí na účelu, ke kterému chceme výsledky použít. Volba příliš velkých či naopak příliš malých objektů může vést k nežádoucí ztrátě informace. Průměrná velikost jednoho segmentu musí odpovídat požadovanému měřítku, protože obrazová analýza je založena na struktuře v rámci určitého měřítka. Velikost segmentů se vzájemně příliš neliší, protože všechny atributy obrazových objektů - barva, textura, tvar, vztahy k sousedním objektům - jsou více či méně funkcí měřítka a kvalitativní porovnání lze provádět pro objekty obdobného měřítka a velikosti (Halounová 2002).

Při metodě region growing je v obraze rozděleno několik současně rostoucích seed pixelů. Pokud je růst regionů v prvním cyklu uzavřen, jsou rozdeleny nové seed pixely na těch místech v obraze, která mají nejvyšší vzdálenost od všech předtím sloučených bodů. Cílem tohoto postupu je vznik segmentů s obdobnou velikostí pixelů (Tomowski et al. 2006).

Způsob segmentace vychází z kritéria, podle něhož průměrná heterogenita obrazových objektů vážená jejich velikostí by měla být minimální. Heterogenita je definována jednak jako heterogenita spektrální neboli barevná podle rovnice (7.1)

$$h = \sum_c w_c \cdot \sigma_c \quad (7.1)$$

kde heterogenita h je součet směrodatných odchylek σ_c ve vrstvách c

násobených vahami w_c v každé vrstvě,

a jednak jako heterogenita prostorová, kdy lze podle rovnice (7.2) vyjádřit odchýlení od kompaktního tvaru

$$h = \frac{l}{\sqrt{n}} \quad (7.2)$$

kde l je délka hranice objektu

a n je plocha objektu v pixelech.

Lze také vyjádřit tzv. hladkosť ako poměr délky hranice objektu (l) a nejkratší hranice (b) vytvořené ve směru rastru jako obal plochy podle rovnice (7.3)

$$h = \frac{l}{b} \quad (7.3)$$

Jedněmi z určujících hodnot pro segmentaci obrazu jsou volba míry vlivu spektrální heterogeneity a prostorové heterogeneity, u prostorové heterogeneity pak ještě míra vlivu kompaktnosti (Compactness) nebo hladkosti (Smoothness). Součet měr vlivu je vždy roven jedné - u prostorové i celkové heterogeneity (Halounová 2002).

7.2 Další metody segmentace

Chessboard Segmentation

Rozdělí obraz do čtvercových objektů. Aplikuje čtvercový grid určité velikosti zarovnaný k levému a hornímu okraji obrazu a rozdělí ho podle linií gridu.

Quad Tree Based Segmentation

Rozdělí obraz do různě velkých čtyřúhelníků vytvořených ze čtvercových objektů. Nejprve je obraz rozdelen podle čtvercové mřížky zarovnané k levému a hornímu okraji obrazu. Čtverce jsou pak spojovány až do maximální velikosti, kdy ještě splňují zadaná kritéria homogeneity.

Spectral Difference Segmentation

Tento segmentační algoritmus je používán ke sloučení sousedních objektů podle jejich středních hodnot vrstvy (spektrálních prvků). Sousední objekty jsou spojeny, pokud rozdíl ve středních hodnotách je menší než průměrný spektrální rozdíl. Tento algoritmus slouží k vylepšení výsledků segmentace spojením spektrálně podobných objektů vytvořených při předchozí segmentaci (Definiens, 2006b).

7.3 Klasifikační proces

Proces klasifikace v programu Definiens představuje specifickou kombinaci různých vzájemně se doplňujících procedur, základní aspekt ale tvoří objektově orientovaný přístup k analýze obrazu.

Nejprve je nutné definovat třídy, do kterých budou objekty podle zvolených kritérií zařazeny. K práci se třídami slouží funkce hierarchie tříd (Class Hierarchy), která umožnuje vytváření nových tříd. U každé třídy se definuje její název, barva a klasifikační metoda (tzv. klasifikátor). Kromě těchto údajů je možné definovat ještě parametry třídy (Class Description), podle kterých se budou objekty klasifikovat. Vytvořené třídy je možné různě seřazovat, přesouvat či vytvářet podtřídy (Definines, 2006b).

Klasifikace vychází z fuzzy logiky pro kvantifikaci nejistých tvrzení. Klasifikace využívající fuzzy logiku je metoda, která převádí hodnoty prvků do fuzzy hodnot mezi 0 a

1, čímž je naznačen stupeň příslušnosti do určité třídy. Převod do fuzzy hodnot umožňuje standardizaci jednotlivých jevů a jejich kombinaci i přes jejich velmi odlišný rozsah a rozměry. Je možné formulovat složitý popis prvku s použitím logických operací a hierarchického popisu tříd. Každá třída klasifikačního schématu se skládá ze souboru fuzzy výrazů dovolujících vyhodnocení určitých jevů a jejich logickou operaci (Steilen 2002).

Vlastní klasifikace může být provedena dvěma zásadními způsoby. První z nich je způsob, kdy se neberou v úvahu prvky vztažené ke třídám, druhým pak je ten, kdy se tyto prvky v úvahu berou. Druhý způsob je pro zadavatele obtížnější, protože musí pečlivě připravit popis tříd, aby nedošlo k zacyklení výpočtu. Klasifikaci pak je nutno provést několikrát, aby bylo dosaženo optimalizace ve všech podmírkách (Halounová 2002).

8 Použitá data a jejich příprava

8.1 Snímek družice *Quickbird*

Družice Quickbird byla vynesena na oběžnou dráhu 18. října 2001. Je schopna snímat zemský povrch s dosud nejvyšším prostorovým rozlišením, a to 0,6 m. Vyvinula a uvedla ji do provozu společnost DigitalGlobe.

Senzory na družici Quickbird umožňují snímat zemský povrch v nadiru a díky možnosti vychýlení senzoru až o 45 stupňů lze snímat i oblasti, které se nachází v širší oblasti pod družicí, čímž je zvýšena operabilita při snímání požadovaných oblastí. Šířka snímaného pásu činí 16,5 km (při snímání v nadiru). V případě snímání v bočním směru je šířka snímaného území větší a úměrně se snižuje prostorové rozlišení snímku. Na družici operují dva senzory: panchromatický, poskytující při snímání v nadiru černobílé snímky o zmíněném rozlišení 0,6 m, a multispektrální, který snímá zemský povrch s prostorovým rozlišením 2,4 m ve čtyřech spektrálních pásmech (modré, zelené, červené, blízké infračervené) (Arcdata Praha, 2007).

V práci byly použity snímky družice Quickbird, po jednom v panchromatickém a multispektrálním módu, pořízené v kvalitě Standard. Produkty Standard představují georeferencované snímky, u nichž je provedena radiometrická korekce (DigitalGlobe, 2007). Použité snímky jsou uloženy v kartografickém zobrazení WGS 84/UTM zone 33N, mají radiometrickou hloubku 16 bit a skenovací úhel snímku je 14,1°. Byly pořízeny 9. srpna 2003.

Jako podkladový snímek pro provedení klasifikace byl použit multispektrální snímek. V software PCI Geomatica V9.1 byl zaostřen pomocí algoritmu Pansharpen panchromatickým snímkem, jeho prostorové rozlišení se poté zvýšilo z 2,4 m na 0,6 m.

Testovací území se nachází v oblasti Jesenické pahorkatiny s nadmořskými výškami 350 – 600 m. Leží na území čtyř okresů – Louny, Rakovník, Plzeň – sever a Karlovy Vary. Na snímku se nacházejí tři obce – Lubenec, Blatno a Žihle. Snímek reprezentují následující typy land-cover:

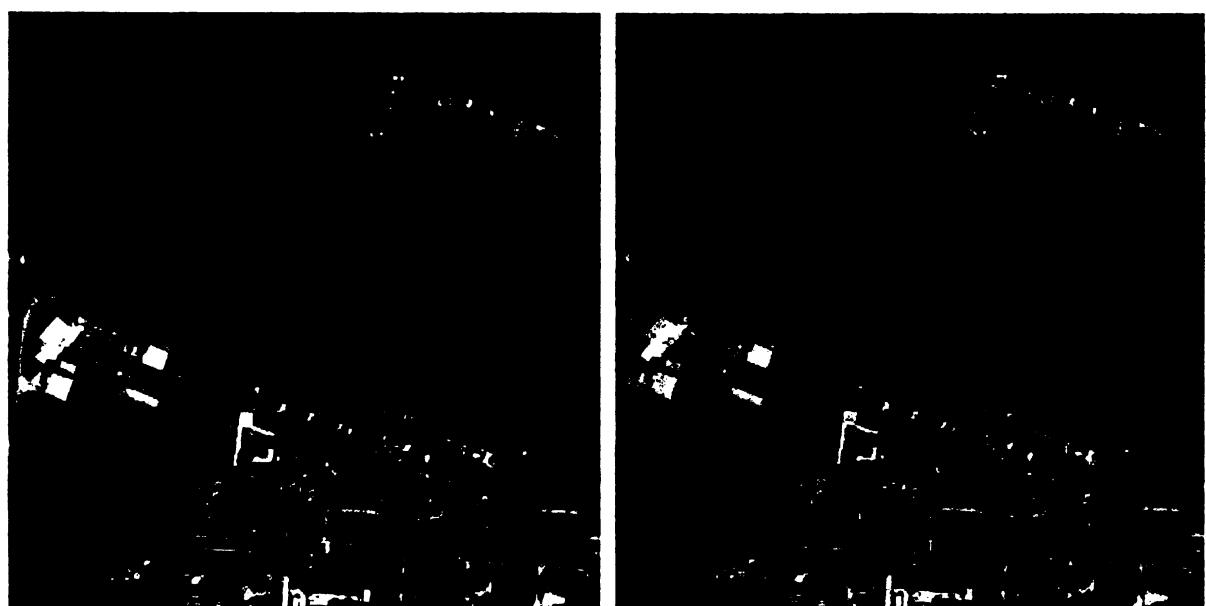
- urbánní
- venkovské prostředí
- zalesněné

- otevřené plochy

Z větší části pokrývají snímek porosty lesů, v okrajových částech snímku jsou pole. Vzhledem k období pořízení snímku (druhá polovina léta) jsou pole často bez vegetace. Sídla vytváří malé intravilány převážně s řídkou zástavbou, typické jsou rodinné domy se zahradou. Velikost jednoho pozemku se ve většině případů pohybuje mezi 300 m² a 1300 m². Pro účely provedení klasifikace byl ze snímku pořízen výřez obce Lubenec o rozloze 1500 m x 1300 m a výřez obce Blatno o stejně rozloze, na kterém byla testována přenositelnost použité metody.

Zastavěná území, která jsou předmětem zájmu této práce, jsou při vizuální interpretaci snímku jednoduše rozpoznatelná a vymezitelná. Podle kontextu je možné vzájemně odlišit obytné a průmyslové oblasti. Jednoduše rozpoznatelné jsou především větší budovy jako panelové a bytové domy. V zaostřeném snímku jsou dobře identifikovatelné i menší budovy (rodinné domy a chaty), obtížněji zachytitelné jsou výklenky a výčnělky zdí a velmi malé objekty, jako například chatky v zahrádkových osadách. Tyto objekty mají tendenci splývat se svým okolím. Obtížně rozpoznatelné jsou také domy zakryté vegetací, tento problém se týká především starší zástavby. Obrázek 8.1 ukazuje výřez z multispektrálního zaostřeného snímku při zobrazení v přirozených barvách a v kombinaci s infračerveným pásmem.

Obr. 8.1: Výřez z multispektrálního snímku družice Quickbird, vlevo zobrazení v přirozených barvách, vpravo kombinace s infračerveným pásmem



V horní části snímku lze rozpoznat zahrádkovou osadu s neidentifikovatelnými, vzájemně splývajícími objekty, v levé části se nachází průmyslový areál s velkými dobře rozpoznatelnými budovami, v dolní části je obytná zóna s menšími, avšak dobře identifikovatelnými rodinnými domy. V kombinaci s infračerveným pásem lze dobře rozeznat umělé povrchy a sklizená pole pouze řídce pokrytá vegetací.

Vizuální interpretace dat byla provedena v software PCI Geomatica V9.1. Nejlepších vizuálních vlastností dosahuje snímek při lineárním nebo adaptivním roztažení histogramu. Snímek lze nejsnáze vizuálně interpretovat při zobrazení v přirozených barvách, zobrazení v kombinaci s infračerveným pásmem je vhodné pro odlišení vegetace.

8.2 Data ZABAGED

Snímek družice Quickbird pokrývá přibližně 10 celých listů ZABAGED nebo jejich částí. Na základě jeho hranic a s ohledem na přítomnost zástavby v území bylo vybráno 9 mapových listů ZABAGED s označením 11-24-15, 20, 25; 12-13-11, 12, 16, 17, 21 a 12-31-01. Jejich klad je znázorněn na obrázku 8.2.

Obr. 8.2: Klad listů ZAGAGED



Zdroj: Český úřad zeměměřický a katastrální, 2007

U těchto mapových listů nebylo možno zjistit přesné datum poslední aktualizace. Podle plánu postupu aktualizace však předpokládám, že poslední aktualizace výše uvedených mapových listů proběhla v roce 2003. Změny v území jsou vzhledem k podobnému datu pořízení družicového snímku minimální, to však nebrání otestování klasifikačních algoritmů.

ČÚZK poskytnutá data jsou tvořena vektorovými soubory polohopisu v kartografickém zobrazení UTM a tabulkovým souborem obsahujícím vysvětlení kódů v atributových tabulkách jednotlivých vrstev. Z vektorových dat byla vybrána tematická vrstva budov (level 20) a konvertována z datového formátu dgn do formátu shapefile (shp), s kterým je možné pracovat v Definiens.

Podle definice objektů (Definice objektů ZABAGED, 2000) se v ZABAGED uvádí veškeré budovy o ploše větší než 50 m^2 . Menší budovy vstupují do ZABAGED pouze tehdy, jedná-li se o budovy významné, budovy osamělé, budovy orientačně či turisticky důležité a budovy nutné pro věrné znázornění charakteru zástavby. Ostatní budovy menší než 50 m^2 se vypouštějí. Blíže se popisem dat ZABAGED zabývá kapitola 5.

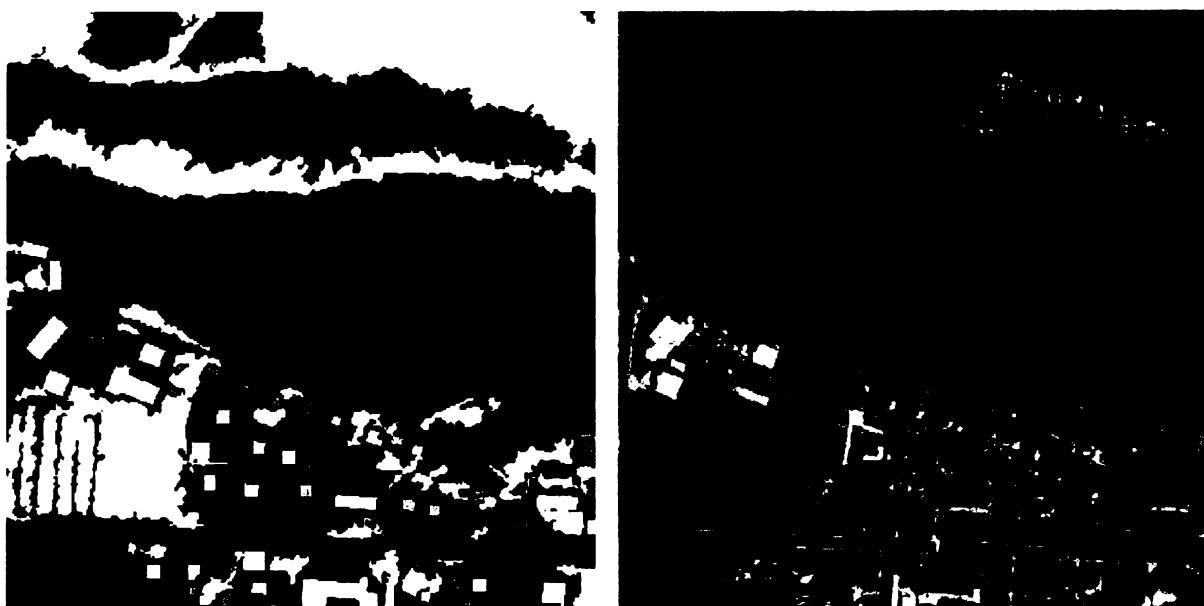
8.3 *Digitální model povrchu*

Digitální model povrchu (DMP) zobrazuje vedle geometrie terénu i objekty, které se na něm nacházejí, jako jsou stromy, budovy a další přírodní i antropogenní objekty. Tak je možné obdržet také informace o relativních výškách objektů nad povrchem terénu.

K zhotovení DMP se obvykle používají data laserového skenování nebo stereodvojice leteckých nebo družicových snímků. Protože ani jedna z těchto možností nebyla v době vytváření této práce k dispozici, použila jsem pro tento účel program SilverEye. Tento software umožňuje získat 3-D model z jediného satelitního snímku velmi vysokého rozlišení (Ikonos nebo Quickbird) bez nutnosti použití stereodvojic. Program obsahuje nástroje pro měření v 2-D a 3-D včetně měření výšek objektů podle velikosti vrhaných stínů. Tento nástroj byl využit pro vytvoření DMP, byly měřeny všechny objekty ve výřezech snímku družice Quickbird vystupující nad terén a poté vytvořena rastrová mapa relativních výšek (viz obrázek 8.3). Geometrie reliéfu byla zanedbána. Vytvořený

model relativních výšek má stejné prostorové rozlišení jako výřezy multispektrálního snímku (0,6 m) a pokrývá stejné území.

Obr 8.3: Znázornění relativních výšek vytvořené programem SilverEye (vlevo) a totéž území v přirozených barvách (vpravo)



8.3.1 Program SilverEye

Program SilverEye umožňuje vytvořit 3-D modely z jednoho satelitního snímku velmi vysokého rozlišení. Využívá model racionálních funkcí definovaných 78 koeficienty, jejichž parametry jsou poskytovány společně se snímkem Ikonos a Quickbird v metadatech (GeoTango, 2005). Program umožňuje také práci v režimu stereo, může dokonce pracovat se stereodvojicí snímků pořízených dvěma různými satelity.

V SilverEye je možné zobrazit jednotlivé nebo stereo snímky, vektorová data a digitální výškové modely. Program obsahuje nástroje pro měření v 2-D a 3-D umožňující určit polohu, délky, výšky, plochy a objemy. Pokud není k dispozici snímek pořízený ze šikmého skenovacího úhlu, umožňuje program určovat výšky objektů měřením velikosti vrhaných stínů. Uživatel má tedy například možnost měřit výšky a objemy budov nebo šířky a délky silnic. K dispozici jsou také nástroje pro redukci šumu, zaostření detailů, zvýraznění hran a nástroje pro zvýraznění nebo potlačení textury a zvýšení kontrastu.

Uživatel má možnost vytvářet 3-D perspektivní modely, generovat ortofota, označovat místa na snímku pomocí bodů, linií, polygonů a textu. Je také možné vytvářet body, linie a polygony a ukládat je jako samostatnou vrstvu ve formátu pro GIS. Program umožňuje uložení scén ve vlastním patentovaném formátu SEV a poté jejich zobrazení jako perspektivní pohledy v prohlížeči SEV Viewer, který je součástí programu SilverEye (viz obr. 8.4).

Program SilverEye je schopen číst tyto typy obrazových formátů dat: NITF, TIFF, GeoTIFF, GIF, IMG, JPG a BMP a podporuje formát ESRI SHP pro importování, vytváření a ukládání dat vektorových.

Obr. 8.4: Perspektivní pohled na část území obce Blatno vytvořený programem SilverEye z družicového snímku QuickBird



9 Metody

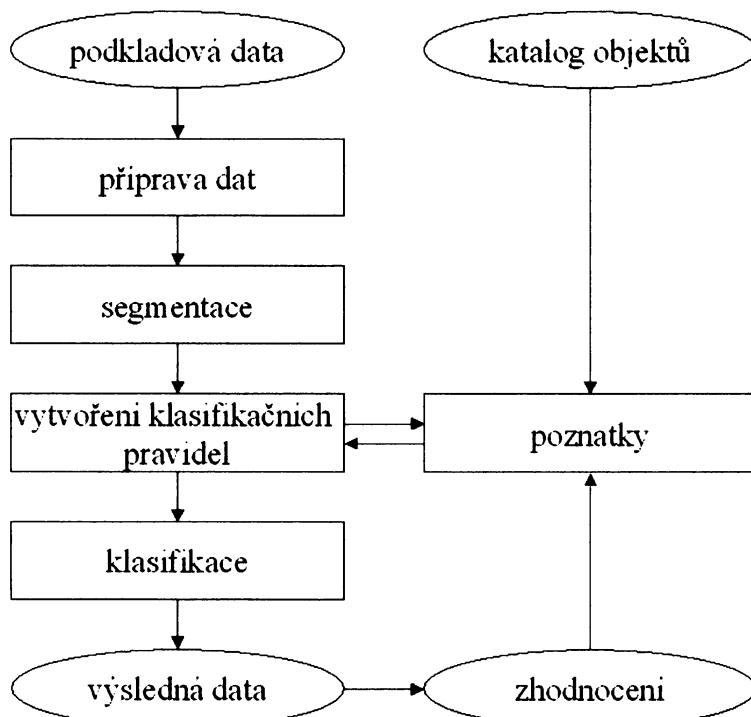
9.1 Průběh klasifikačního procesu

Hlavním záměrem bylo provést klasifikaci snímku pořízeného družicí Quickbird tak, aby bylo detekováno co největší množství budov, přičemž největší váha byla kladena na nalezení alespoň části hledaných objektů (např. nezastíněná část střechy), než na vytvoření a extrakci přesného tvaru budovy. Nalezené objekty slouží k upozornění lidského operátora, že v území došlo ke změně.

Pro účely vytvoření a otestování klasifikačních pravidel byl vytvořen výřez snímku Quickbird obce Lubenec. Nejprve byla provedena klasifikace snímku bez použití digitálního modelu povrchu a následně klasifikace téhož území s přidáním informace o relativních výškách objektů s předpokladem zlepšení výsledku klasifikace. Výřez obce Blatno byl použit k testování přenositelnosti vytvořené metody klasifikace.

Použitý obecný postup práce je znázorněn ve schématu 9.1. Ukazuje potřebné kroky pro provedení objektově orientované klasifikace.

Obr. 9.1: Schéma průběhu objektově orientované klasifikace dat dálkového průzkumu Země



Příprava dat zahrnuje vytvoření výřezů snímku Quickbird a zaostření multispektrálních dat, zhotovení digitálního modelu povrchu a uložení vrstvy budov ze ZABAGED do formátu SHP (blíže viz kapitola 8). V dalším kroku je provedena segmentace snímku a poté jsou přes hierarchii tříd vytvořena klasifikační pravidla na základě zadaného cíle (tj. definice budov v ZABAGED podle Definice objektů ZABAGED, 2000) a získaných poznatků. Podle definic jednotlivých tříd následuje klasifikace. Protože první výsledek klasifikace je pak zpravidla ještě možné vylepšit, je provedeno zhodnocení výsledků a získané poznatky se použijí k vylepšení klasifikačních pravidel.

9.2 Segmentace

Podle Schiewe et al. (2001, s. 38) „je třeba podotknout, že důležité kroky objektově orientované metody zahrnují časově náročné manuální interakce. Předně je třeba, aby uživatel během segmentačního procesu provedl výběr měřítkových parametrů a nastavení vah vstupních datových zdrojů.“.

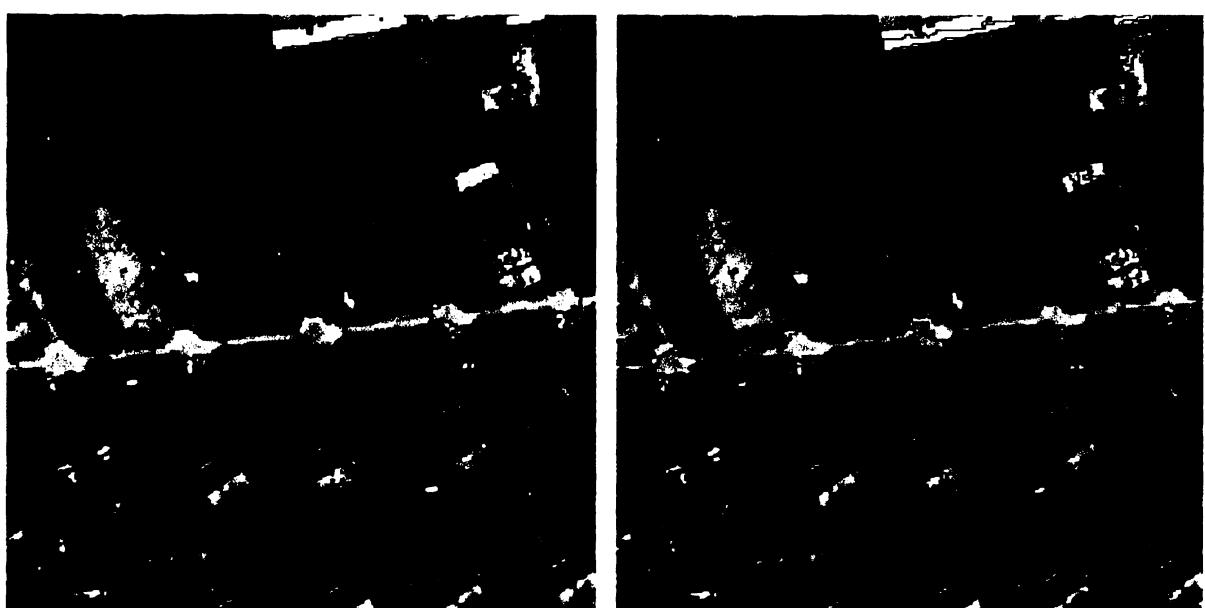
Při nastavení segmentačních kritérií jsem se řídila doporučením výrobce programu Definines AG, který radí vytvářet objekty největšího možného měřítkového parametru (scale parameter), které však stále reprezentují rozdílné oblasti v obraze (tak velké, jak je možné a tak detailní, jak je možné) (DEFINIENS AG 2006b). Dále musí být nalezeno smysluplné vyvážení spektrálního kritéria (color) a kritéria tvaru (shape). Principielně je možné dát větší váhu na kritérium tvaru, spektrální kritérium by však mělo zůstat tak vysoké, jak je to jen možné. Důvodem pro toto pravidlo je, že vysoká váha kritéria tvaru pracuje na úkor spektrální homogeneity a spektrální informace představuje primární informaci obsaženou v obrazových datech. Přiřazení velké váhy kritériu tvaru může proto snížit kvalitu výsledku segmentace (DEFINIENS AG 2006b).

Vycházející z těchto doporučení bylo provedeno několik pokusů s cílem vytvořit pro hledané budovy segmenty odpovídající velikosti. Byly vytvořeny dvě segmentační úrovně – první pro objekty budov, druhá pro vymezení obrysů sídel.

První segmentační úroveň charakterizuje budovy. Pro ně nejvíce vyhovovala segmentace v měřítkovém parametru 32. I přes výše uvedené doporučení bylo nakonec

nutné nastavit kritérium tvaru na hodnotu 0,8 a spektrální kritérium na 0,2, aby vznikly smysluplné objekty. Po prvních pokusech bylo jasné, že při přiřazení vyšší hodnoty spektrálnímu kritériu dochází ke vzniku široce rozvětvených objektů, které nemohou reprezentovat tvar budov vzhledem ke skutečnosti, že antropogenní objekty se zpravidla vyznačují kompaktnějším tvarem než přírodní plochy. Důvodem vzniku tohoto efektu je různorodý charakter povrchů nacházejících se uvnitř sídel, jež se projevuje mnoha rozdílnými hodnotami šedi. Parametry kompaktnost (Compactness) a hladkost (Smoothness) jsou v rovnováze, oba mají hodnotu 0,5. Obrázek 9.2 představuje porovnání segmentací na první úrovni s různými parametry. Pravý obrázek ukazuje segmentaci s důrazem na spektrální kritérium (color 0,8), levý segmentaci při spektrálním kritériu 0,2, která lépe vystihuje tvar budov.

Obr. 9.2: Ukázka segmentace s rozdílným nastavením parametrů pro spektrální kritérium – vlevo 0,2, vpravo 0,8



Váhy pro jednotlivé spektrální kanály byly ponechány na hodnotě 1 vzhledem k tomu, že střechy jsou reprezentovány různými povrhy s rozdílnou spektrální odrazivostí (dokonce i zastíněná a osvícená část jedné střechy vykazuje rozdílné spektrální charakteristiky). Všechny spektrální kanály proto mají stejnou váhu. V této segmentační úrovni byla jako tematická vrstva použita vektorová data budov ze ZABAGED, která pomohla vylepšit tvar segmentů stávajících budov.

Druhá segmentační úroveň reprezentuje obrysy sídel a nejvíce pro ni vyhovoval měřítkový parametr 300. Kritérium tvaru je nastaveno na hodnotu 0,7 a hodnoty kompaktnosti a hladkosti jsou 0,5. Nastavení kritérií pro obě segmentační úrovně uvádí tabulka 9.1.

Tab. 9.1: Nastavení segmentačních parametrů v Definiens

Úroveň	Měřítkový parametr	Barva	Tvar	Kompaktnost	Hladkost
1	32	0,2	0,8	0,5	0,5
2	300	0,3	0,7	0,5	0,5

9.3 *Klasifikace*

9.3.1 Základní úvaha

Na začátku práce vyvstala otázka, s jakou strategií klasifikace se podaří detektovat budovy nejlépe. Prvotní úvahou přitom bylo identifikovat střechy budov po provedené segmentaci na základě spektrálních charakteristik podle zvýšené odrazivosti v červené části spektra a podle tvaru segmentů je odlišit od silnic. První pokusy klasifikace třídy budov podle těchto příznaků byly sice částečně úspěšné, přesto byl podíl chybně klasifikovaných segmentů příliš vysoký.

Obr. 9.3: První zkušební klasifikace třídy budov



Na obrázku 9.3 jsou budovy zobrazeny červenou barvou a je vidět častá záměna střech se silnicemi, dvorky a nezpevněnými plochami bez vegetace.

Aby došlo ke zlepšení kvality klasifikace, musely být při dalším vývoji metody zohledněny zejména následující body:

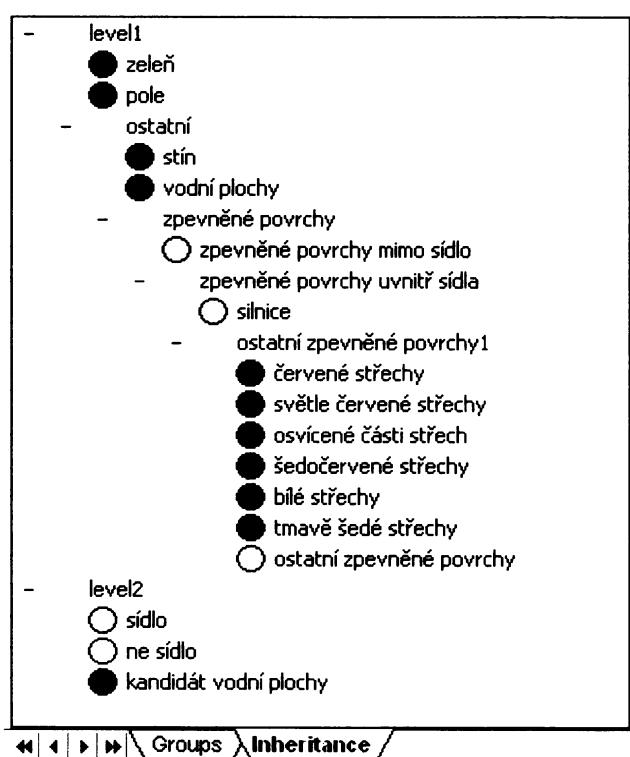
- Střechy bylo nutné rozdělit do více tříd podle materiálového složení a spektrálních charakteristik a pro každou třídu vytvořit přesný popis.
- Klasifikaci provádět postupným odmaskováním ostatních typů povrchů.

9.3.2 Obecný průběh postupu klasifikace

K lepšímu porozumění obecné strategie představené metody bude v této kapitole, předtím než bude průběh klasifikace detailně popsán, nastíněn její základní princip.

Na základě hierarchické sítě segmentů byly ve druhé segmentační úrovni určeny plochy sídel. Tímto vznikla možnost, pracovat v první úrovni již jenom s těmi segmenty, v nichž se nacházejí budovy.

Obr. 9.4: Hierarchie tříd v Definiens pro klasifikaci budov



Střechy byly rozděleny do různých tříd podle rozdílných spektrálních příznaků. Klasifikace probíhala postupným odmaskováváním ostatních typů povrchů. Ke každé třídě byl vytvořen její popis a určeny prahové hodnoty klasifikačních příznaků (spektrálních příznaků, tvaru, vztahů k sousedním objektům nebo subobjektům).

Tak vznikl první krok k provedení klasifikace – vytvoření klasifikačních pravidel. Podkladem pro to je v Definiens hierarchie tříd (class hierarchy) (viz obrázek 9.4), která tvoří základ pro kroky objasněné v následujících kapitolách, kde budou popsány v hierarchii definované třídy a jejich příznaky pro obě segmentační úrovně. Detailní popis tříd, klasifikačních příznaků, prahových hodnot a funkcí příslušnosti uváděných v kapitolách 9.3.3 a 9.3.4 je uveden v příloze této práce.

9.3.3 Klasifikace druhé segmentační úrovně

Druhá segmentační úroveň se skládá ze tříd „sídlo“, „ne sídlo“ a třídy „kandidát vodní plochy“. Třída „sídlo“ určuje místa, kde se nachází budovy. V první úrovni jsou pak budovy hledány pouze v těchto segmentech. Třída „kandidát vodní plochy“ pak určuje místa, která označují potenciální plochy vodní hladiny, klasifikovaná později v první úrovni.

Popis třídy „sídlo“ sestává ze dvou klasifikačních pravidel (viz obrázek 9.5). Jsou spojeny logickou spojkou „or (max)“, která vyjadřuje, že výstup se rovná maximálnímu splnění všech jednotlivých pravidel. Obě pravidla jsou založena na textuře subobjektů, protože sídlo se vyznačuje mnoha různými hodnotami šedi a z toho důvodu se projeví i odlišnou texturou. Jako nejlépe odlišitelná se ukázala v modré části spektra.

Obr. 9.5: Klasifikační pravidla třídy „sídlo“

- • Contained
 - and (min)
 - ✓ **Avrg. mean diff to neighbors of sub-objects B (1)**
 - ✓ **Mean of sub-objects: stddev B (1)**
- • Inherited
 - ○ and (min) (level2)
 - △ **Level**

„Mean of sub-objects: stddev. B“ je směrodatná odchylka vypočítávaná ze středních hodnot modré části spektra subobjektů. Vyjadřuje ji vzorec 9.1,

$$\sqrt{\frac{1}{\#S_v(d)} \left(\sum_{u \in S_v(d)} (\bar{c}_k(u))^2 - \frac{1}{\#S_v(d)} \sum_{u \in S_v(d)} \bar{c}_k(u) \sum_{u \in S_v(d)} \bar{c}_k(u) \right)} \quad (9.1)$$

kde $S_v(d)$ je počet subobjektů obrazového objektu v ve vzdálenosti d ,

$c_k(u)$ průměrná hodnota odrazivosti k obrazového objektu u

a d vzdálenost úrovní.

Toto pravidlo doplňuje pravidlo „Avrg. mean diff. to neighbors of subobjects B“. Popisuje kontrast uvnitř obrazových objektů vyjádřený průměrnou střední odchylkou všech jeho subobjektů pro modrou vrstvu. Je vyjádřen vzorcem 9.2

$$\frac{1}{\#S_v(d)} \sum_{u \in S_v(d)} \Delta_k(u) \quad (9.2)$$

kde $\Delta_k(u)$ je střední rozdíl k sousední vrstvě vrstvy k obrazového objektu u .

Třída „ne sídlo“ je vytvořena jako negace podobnosti ke třídě „sídlo“ a její popis neobsahuje žádná další klasifikační pravidla (viz obrázek 9.6).

Obr. 9.6: Klasifikační pravidla třídy „ne sídlo“

- • Contained
- and (min)
- ↔ not sídlo
- ↗ Inherited
- ○ and (min) (level2)
- ↗ Level

Třída “kandidát vodní plochy“ je určena pomocí nízkých hodnot odrazivosti v oblasti blízkého infračerveného záření prostřednictvím průměrných hodnot vrstvy tohoto spektrálního kanálu (Mean IR). Průměrná hodnota vrstvy se vypočítá pro každý segment jako aritmetický průměr hodnot jednotlivých pixelů tvořících jeden segment podle vzorce 9.3

$$\bar{c}_k(v) = \bar{c}_k(P_v) = \frac{1}{\#P_v} \sum_{(x,y) \in P_v} c_k(x,y) \quad (9.3)$$

kde P_v je soubor pixelů jednoho obrazového objektu,

$\#P_v$ celkový počet pixelů obsažených v P_v ,

$c_k(x,y)$ hodnota odrazivosti pixelu (x,y) ,
a c_k průměrná hodnota odrazivosti vrstvy k .

9.3.4 Klasifikace první segmentační úrovně

První segmentační úroveň se skládá ze šesti tříd představujících různé typy povrchů střech, dále třídy „zeleň“, „pole“, „vodní plochy“, „stín“, „zpevněné povrchy mimo sídlo“, „silnice“ a „ostatní zpevněné povrchy“. Základní třídy jsou „zeleň“, „pole“ a „ostatní“, další třídy jsou podtřídy těchto tříd, podle toho, jak probíhalo postupné odmaskování (viz obrázek 9.4). Podtřídy obsahují ve svém popisu klasifikační pravidla svých rodičovských tříd.

Klasifikace probíhala postupným odmaskováním povrchů zeleň, pole, stín, vodní plochy, zpevněné povrchy mimo sídlo a silnice. Ve zbylém území byly hledány střechy, zbývající plocha pak byla klasifikována jako „ostatní zpevněné povrchy“.

Třídy „zeleň“ a „pole“ byly klasifikovány pomocí normalizovaného vegetačního indexu (normalized difference vegetation index – NDVI). Ten porovnává rozdíl v intenzitě záření v pásmu blízkého infračerveného záření a červeného záření podle vzorce 9.4

$$NDVI_{seg} = \frac{IR_{c_m} - R_{c_m}}{IR_{c_m} + R_{c_m}} \quad (9.4)$$

kde c_m je průměrná hodnota hodnot šedi segmentu,

IR hodnota odrazivosti v oblasti blízkého infračerveného záření

a R hodnota odrazivosti v oblasti viditelného červeného záření. Vysoká hodnota NDVI ukazuje na přítomnost zelených částí rostlin v území.

Spektrální příznaky pro každý jednotlivý segment mohou být v Definiens vytvořeny pouze z vypočtených průměrů hodnot šedi jednotlivých segmentů. Proto může být vypočten pouze průměrný NDVI (tzn. nevychází z hodnot šedi jednotlivých pixelů, ale z hodnot šedi segmentů). Protože NDVI není v Definiens implementován standardně, bylo třeba vytvořit tento příznak prostřednictvím kalkulátoru.

V této kapitole se budu dále blíže zabývat pouze popisem tříd představujících budovy a třídou „silnice“. Mezi těmito třídami dochází k nejčastější záměně, protože

některé typy šedě zbarvených střech nejsou od silnic a jiných asfaltových ploch spektrálně odlišitelné. Popis zbývajících tříd je uveden v příloze.

Jednodušeji odlišitelné se ukázaly červené taškové střechy, které vykazují rozdílné spektrální charakteristiky podle stáří střešní krytiny a podle míry osvícení slunečním zářením. Rozdělila jsem je do čtyř tříd podle vykazovaných odrazivých vlastností – „červené střechy“, „světle červené střechy“, „osvícené části střech“ a „šedočervené střechy“.

Základní úvahou při klasifikaci taškových střech byl předpoklad zvýšené odrazivosti v červené části spektra a nižší odrazivosti v modré části spektra. Společnými klasifikačními příznaky pro tyto čtyři třídy se proto staly průměrná hodnota modré vrstvy (Mean B) a poměrný ukazatel červené vrstvy (Ratio R). Tato základní kombinace příznaků se po otestování ukázala jako nejspolehlivější. Prahové hodnoty těchto příznaků jsou uvedeny v tabulce 9.2. Další společnou charakteristikou byl poměr délky a šířky segmentu (Length/Width), toto tvarové kritérium pomáhá odlišit budovy od silnic. Stejné příznaky tvoří také popis třídy „silnice“. Ty se od střech odlišují především protáhlým tvarem segmentů a vyššími hodnotami odrazivosti modré části spektra.

Tab. 9.2: Prahové hodnoty příznaků Mean B a Ratio R pro klasifikaci taškových střech

Příznak/Třída	Mean B	Ratio R
Červené střechy	<215	>0,215
Světle červené střechy	<260	>0,228
Osvícené části střech	<320	>0,250
Šedočervené střechy	<216	>0,200

Příznak „Mean“ byl vysvětlen v předchozím textu (kapitola 9.5). Příznak „Ratio R“ červené vrstvy vyjadřuje množství záření, kterým tato vrstva přispívá k celkovému jasu segmentu. Je vyjádřen vzorcem (9.5):

$$\frac{\bar{c}_k(v)}{\bar{c}(v)} \quad (9.5)$$

kde $c_k(v)$ je průměrná hodnota odrazivosti vrstvy k jednotlivého segmentu v

a $c(v)$ jas.

Třídy „červené střechy“ a „světle červené střechy“ jsou dále charakterizovány maximální prahovou hodnotou příznaku jas (Brightness). Ten je definován jako součet průměrných hodnot vrstev obsahujících spektrální informaci vypočítaných pro každý obrazový objekt. Popisuje ho vzorec 9.6:

$$\bar{c}(v) := \frac{1}{w^B} \sum_{k=1}^K w_k^B \bar{c}_k(v) \quad (9.6)$$

kde w_k^B je váha jasu vrstvy k

a w^B součet jednotlivých w_k^B .

U třídy „světle červené střechy“ docházelo k časté záměně s půdou bez vegetace (hlínu a pálenou tašku tvoří podobný materiál). Částečně se tento problém podařilo vyřešit přidáním příznaku NDVI do popisu třídy. Přestože se půda na snímku jeví jako holá, může se na ní vyskytovat malé množství vegetace a odlišuje se tak od střech. „Osvícené části střech“ se vyznačují posunutím spektrální odrazivosti do vyšších hodnot. U třídy „šedočervené střechy“ dochází k občasným záměnám s třídou silnice. Čím méně červeného záření v poměru k intenzitě odrazivosti ostatních spektrálních pásem střecha odráží, tím obtížnější je ji správně klasifikovat. Šedé střechy pak často není možné klasifikovat vůbec, protože vykazují stejné spektrální i tvarové charakteristiky jako silnice a další zpevněné povrchy jako dvorky, vjezdy, náměstí apod. Ke třídě „silnice“ byl vytvořen popis, jehož nejdůležitějším příznakem je „Length/Width“, který je nastaven tak, aby byly vyhledávány pouze výrazně protáhlé objekty.

Plechové střechy ve třídě „bílé střechy“ se vykazují velkým jasem a může docházet k záměnám s dalšími velmi jasnými objekty (skleníky, některé silnice). Popis této třídy je sestaven z příznaků „Brightness“ a „Mean B“, u nichž jsou definovány jejich minimální hodnoty. Třída „tmavě šedé střechy“ inklinuje k záměnám s asfaltovými plochami, protože povrch je tvořen velmi podobným materiélem a vzhledem k nízké odrazivosti celého spektra dochází i k záměnám s třídou „stín“. Do popisu třídy byl zahrnut příznak „Mean IR“ vypovídající o středních hodnotách blízkého infračerveného záření.

Příznaky popisu tříd střech jsou spojeny logickou spojkou „and (min)“, která vyjadřuje, že výstup se rovná minimu splnění všech jednotlivých pravidel.

Komplikovanější je zápis třídy „bílé střechy“, kde jsou kombinovány logické spojky „and (min)“ a „or (max)“ (viz obrázek 9.7).

Obr. 9.7: Popis třídy „bílé střechy“ s kombinacemi logických spojek „and (min)“ a „or (max)“

- **Contained**
 - and (min)
 - Area**
 - or (max)
 - Brightness**
 - Mean B**
 - Rectangular Fit**

Po provedení klasifikace byly jednotlivé segmenty budov sloučeny a do popisu tříd byly přidány příznaky vypovídající o pravoúhlosti objektu (Rectangular Fit) a o velikosti objektu (Area) a byla znova provedena klasifikace. Příznaku „Area“ byla přiřazena minimální hodnota 25 m^2 , což je polovina minimální velikosti budovy zařazené do ZABAGED. Poloviční hodnotu jsem zvolila z toho důvodu, že někdy dochází ke správné klasifikaci pouze části střechy (např. nezastíněná polovina střechy). Přidáním těchto příznaků se docílilo odstranění chybné klasifikace u některých nesprávně klasifikovaných segmentů.

Obr. 9.8: Ukázka výsledku klasifikace



- | | |
|---|---|
| <input checked="" type="circle"/> střechy | <input type="circle"/> ostatní zpevněné povrchy |
| <input checked="" type="circle"/> zeleně | <input checked="" type="circle"/> pole |
| <input checked="" type="circle"/> stín | <input type="circle"/> silnice |

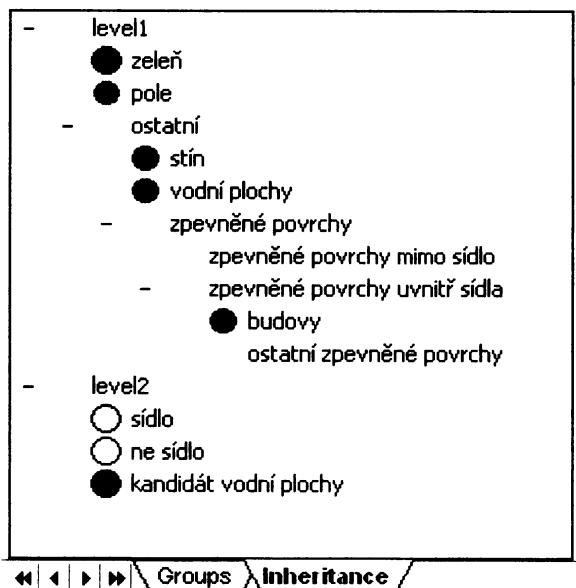
Obrázek 9.8 ukazuje výřez z výsledku klasifikace. Lze na něm vidět, že třídu „silnice“ je možné úspěšně klasifikovat pouze na dlouhých přímých úsecích komunikací, nikoliv však již na ostatních zpevněných plochách jako jsou chodníky a dvorky. Dále lze pozorovat pouze částečně správnou klasifikaci budov v dolní části výřezu (správně klasifikována pouze polovina střechy) a neúplně klasifikované šedé střechy garáží v pravé části výřezu.

9.4 Segmentace a klasifikace s přidáním informace o relativní výšce

Značná složitost a heterogenita objektů tvořících sídlo vede k častým chybám v klasifikaci. Nejčastěji jsou zaměňovány právě budovy se silnicemi. Výsledek klasifikace lze podstatně vylepšit, pokud je k obrazovým datům přidána informace o relativní výšce objektů.

Segmentace probíhala se stejně nastavenými parametry (viz kapitola 9.3) s výjimkou nastavení vah pro jednotlivé spektrální kanály. Do segmentace první úrovně byla přidána i rastrová vrstva digitálního modelu povrchu, které byla přiřazena vyšší váha 1 oproti ostatním spektrálním kanálům, které mají váhu nastavenou na hodnotu 0,5.

Obr. 9.9: Hierarchie tříd pro klasifikace budov s přidáním informace o relativní výšce



V této segmentační úrovni byla jako tematická vrstva použita také vektorová data budov ze ZABAGED. Nastavení parametrů druhé segmentační úrovně je stejné jako v kapitole 9.3.

Jak je vidět z hierarchie tříd na obrázku 9.9, klasifikace probíhala zpočátku podle stejného schématu. Klasifikační pravidla v druhé segmentační úrovni zůstala nezměněna. Stejně nezměněna zůstala i pravidla v první segmentační úrovni až po třídu „zpevněné povrchy uvnitř sídla“. Ta byla rozdělena pomocí digitálního modelu povrchu na třídu „budovy“ a „ostatní zpevněné povrchy“. Obě třídy se vyznačují odlišnou relativní výškou. Vegetace, která má stejně jako budovy vyšší relativní výšku oproti okolnímu terénu, byla stejně jako v minulém případě odlišena pomocí NDVI.

Pro třídu „budovy“ byl použit příznak „Mean výška“, který určuje průměrnou hodnotu relativní výšky pro segment a byla stanovena jeho minimální prahová hodnota. Zbývající plochy byly zařazeny do třídy „ostatní zpevněné povrchy“ představující silnice, chodníky, náměstí a dvorky.

Na výřezu z výsledku klasifikace na obrázku 9.10 je vidět zlepšení výsledku klasifikace, především co se týče tvaru budov. Došlo k odstranění problému se záměnou budov a ostatních zpevněných ploch.

Obr. 9.10: Ukázka výsledku klasifikace s přidáním informace o relativní výšce



- budovy
- ostatní zpevněné povrchy
- pole
- stín
- zeleň

10 Výsledky

10.1 Zhodnocení výsledků klasifikace

Výsledek práce představují polygony budov získané klasifikací snímku Quickbird ve formátu shp, které jsou poté porovnávány se stavem v ZABAGED. V této kapitole bude zhodnocena přesnost klasifikace, otestována přenositelnost metody a zhodnoceny výsledky aktualizace ZABAGED. Výsledky budou nejprve vizuálně interpretovány a poté statisticky zhodnoceny pro obě metody popsané v kapitole 9.

Protože nebyla k dispozici žádná referenční data pro zhodnocení přesnosti, byla na základě zaostřeného panchromatického snímku družice Quickbird vytvořena manuální klasifikaci v software Definiens referenční maska pro výřezy obcí Lubenec a Blatno.

10.1.1 Vizuální interpretace

Při vizuálním porovnání referenční masky a výsledků klasifikace bez použití relativních výšek je zřejmé, že mnoho budov bylo správně klasifikováno. Jedná se především o červené taškové střechy. Nejlepšího výsledku bylo dosaženo zejména u novějších střešních krytin, u nichž výrazně převažuje červená složka odraženého záření.

Dále je patrné, že u některých budov či jejich částí docházelo k záměnám s jinými typy povrchů. Jde hlavně o záměny šedých střech se zpevněnými povrhy, některých červených střech s půdou bez vegetace, problémy způsobují také antukové povrhy (v případě obce Lubenec tenisové hřiště), starší domy zakryté vegetací a různě osvícené části střech.

Je také evidentní, že u mnoha budov nebyl nalezen jejich přesný tvar. To může být způsobeno ne zcela přesnou segmentací anebo zmatením algoritmů způsobujícím záměny popsané výše. Polohové chyby mohou být vyvolány také geometrickou nepřesností snímku.

Pokud byla při klasifikaci použita relativní výška objektů vystupujících nad zemský povrch, je již při vizuální interpretaci patrné, že výsledek klasifikace je možné tímto způsobem podstatně vylepšit. Dochází pouze k málo častým záměnám s vegetací a se

zpevněnými plochami. Tyto záměny nastávají především z důvodu ne zcela správné segmentace nebo je jejich příčinou zarůstání budov vegetací. Výhodu představuje, že je možné spolehlivě rozpoznat i šedé typy střech a podstatně vylepšit tvar budov.

10.1.2 Statistické zhodnocení

Pro statistické zhodnocení byly v programu Definiens vytvořeny kontingenční tabulky porovnáním referenčních dat a výsledků klasifikace. Tyto tabulky udávají pro každou třídu, kolik sledovaných pixelů bylo klasifikováno správně a kolik chybně. Řádky maticy reprezentují rozdělení pixelů podle provedené klasifikace, sloupce ukazují přiřazení pixelů na základě referenčních dat. Z této tabulky je pak možné jednoduše zjistit přesnost každé třídy a lze z ní vypočítat další hodnoty, které vypovídají o přesnosti klasifikace.

Pro porovnání výsledku klasifikace bez použití informace o relativní výšce byla vytvořena kontingenční tabulka 10.1. Třída „budovy“ v tabulce představuje všechny typy střech nalezené během klasifikace, ve třídě „zpevněné povrchy“ v tabulce jsou zahrnutы třída „silnice“ a třída „ostatní zpevněné povrchy“ použité pro klasifikaci.

Tab. 10.1: Kontingenční tabulka pro klasifikaci bez použití informace o relativní výšce

Reference	Zpevněné povrchy	Pole	Zeleň	Vodní plochy	Stín	Celkem
Zpevněné povrchy	325647	19449	62598	379	3430	486699
Pole	16202	1354463	110168	4354	0	1485187
Zeleň	54658	86954	2955378	1516	2722	3107449
Vodní plochy	18	473	821	101193	0	102505
Stín	10479	0	2359	0	26731	43421
Celkem	438837	1461860	3134457	107442	33675	

Z tabulky vyplývá, že u třídy „budovy“ dochází k nejčastějším záměnám s třídou „zpevněné povrchy“. To je způsobeno skutečností, že budovy a silnice společně s dalšími zpevněnými povrhy se liší spektrálně jen velmi málo nebo vůbec a proto se v příznakovém prostoru tvořeném příznaky definovanými v kapitole 9 jejich třídy částečně prolínají. V menší míře dochází k záměně se třídou „zeleň“. To je zapříčiněno ne zcela správnou segmentací, při které nevznikly ve všech případech segmenty odpovídající přesnému tvaru budovy. Další přičinou této záměny jsou budovy, které z části nebo úplně zeleně překrývají.

Celková přesnost klasifikace se vypočítá jako součet všech správně klasifikovaných pixelů dělených celkovým počtem všech pixelů podle vzorce 10.1

$$O_A = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (10.1)$$

kde n_{ii} je počet pixelů v řádce i a sloupci i ,

k je počet tříd

a n je celkový počet pixelů.

Z kontingenční tabulky 10.1 vychází hodnota celkové přesnosti 90,7 %.

Přesnost třídy „budovy“ je možné charakterizovat pomocí vypočtených hodnot přesnosti z hlediska zpracovatele (zpracovatelská přesnost - producer's accuracy) a hodnot přesnosti z hlediska uživatele (uživatelská přesnost - user's accuracy). Zpracovatelská přesnost udává poměr správně klasifikovaných pixelů třídy „budovy“ k celkovému počtu pixelů referenční třídy podle vzorce 10.2

$$P_A = \frac{n_{jj}}{n_{+j}} \quad (10.2)$$

kde n_{jj} je počet správně přiřazených pixelů ke třídě j

a n_{+j} celkový počet pixelů referenční třídy j .

Z kontingenční tabulky 10.1 byla vypočtena hodnota zpracovatelské přesnosti pro třídu „budovy“ 57,4 %.

Uživatelská přesnost udává poměr správně přiřazených pixelů ke třídě „budovy“ a všech pixelů náležejících podle klasifikace třídě „budovy“ podle vzorce 10.3

$$U_{i+} = \frac{n_{ii}}{n_{i+}} \quad (10.3)$$

kde n_{ii} je počet správně přiřazených pixelů ke třídě i
a n_{i+} celkový počet pixelů klasifikovaných jako třída i .

Z kontingenční tabulky 10.1 byla vypočtena hodnota uživatelské přesnosti třídy „budovy“ 76 %.

Další hodnotou, která charakterizuje přesnost klasifikace, je kappa index. Svými hodnotami se pohybuje v rozsahu 0 % až 100 % a vyjadřuje odpovídající omezení chyby získané klasifikací, která byla porovnána s chybou, která by vznikla při zcela náhodném procesu. Je definován vzorcem 10.4

$$K = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k (n_{i+} n_{+i})}{n^2 - \sum_{i=1}^k (n_{i+} n_{+i})} \quad (10.4)$$

kde n_{+i} je celkový počet pixelů referenční třídy i . Hodnota kappa indexu pro třídu „budovy“ je 56,1 %, což odpovídá dobrému výsledku klasifikace podle tabulky 10.2.

Tab. 10.2: Hodnocení kappa indexu

Kappa index	Kvalita klasifikace
0	velmi špatná
0 – 0,2	špatná
0,2 – 0,4	akceptovatelná
0,4 – 0,6	dobrá
0,6 – 0,8	velmi dobrá
0,8 - 1	výborná

Zdroj : Ortiz et al. 1997, cit. v Tomowském et al. 2006, s. 101

Všechny tyto statistické ukazatele založené na kontingenční tabulce však porovnávají jednotlivé pixely. Pro mě bylo ale spíše než přesný tvar budovy důležité, aby na ni bylo klasifikaci upozorněno. Stačilo tedy, aby byla správně nalezena alespoň její část. Proto jsem provedla navíc manuální sečtení všech budov, z nichž byla správně

klasifikována alespoň jejich část. Po provedení klasifikace bez použití informace o relativní výšce bylo upozorněno na 70 % budov.

Pro zhodnocení výsledku klasifikace s použitím informace o relativní výšce byla vytvořena kontingenční tabulka 10.3. Třída „zpevněné povrchy“ v tabulce představuje třídy „zpevněné povrchy mimo sídlo“ a „zpevněné povrchy uvnitř sídla“ v klasifikaci.

Z této tabulky vyplývá, že u třídy „budovy“ dochází k nejčastější záměně se třídou „zpevněné povrchy“. Jedná se o budovy nebo části budov, jejichž výška nedosahovala minimální hodnoty určené při klasifikaci nebo budovy, jejichž tvar nebyl při segmentaci přesně vystížen a průměrná výška segmentu byla určena jako průměr výšky budovy a jejího okolí. Takovýto segment se poté mohl podle své průměrné relativní výšky zařadit buď do třídy „budovy“ nebo do třídy „ostatní zpevněné povrchy“. Další nejčastější záměnou byla záměna se třídou „zeleň“. Sem patří budovy zakryté zelení a také chyby způsobené nepřesnou segmentací.

Celková přesnost klasifikace je 98,9 %. Zpracovatelská přesnost pro třídu „budovy“ je 96,9 %, uživatelská přesnost 99,2 %. Hodnota kappa indexu pro třídu „budovy“ je 96,7 %, což odpovídá výbornému výsledku klasifikace podle tabulky 10.2. Celkem bylo po provedení klasifikace s použitím informace o relativní výšce upozorněno na 97 % budov.

Tab. 10.3: Kontingenční tabulka pro klasifikaci s použitím informace o relativní výšce

Reference	Zpevněné povrchy	Pole	Zeleň	Vodní plochy	Stín	Celkem
Výsledek klasifikace						
Zpevněné povrchy	407128	3809	11055	1061	3176	427810
Pole	28049	1458051	0	1737	0	1487837
Zeleň	2406	0	3122880	0	116	3129547
Vodní plochy	0	0	0	104644	0	104644
Stín	0	0	145	0	30383	31086
Celkem	438837	1461860	3134457	107442	33675	

Porovnání statistických zhodnocení vyjadřujících přesnost obou klasifikací dokazuje, že pokud do klasifikace přidáme informaci o relativní výšce objektů, velmi tím zvýšíme její kvalitu.

10.1.3 Test přenositelnosti metody na výřezu obce Blatno

Na výřezu obce Blatno ze snímku Quickbird byly provedeny oba typy klasifikací se stejným nastavením parametrů jako u výřezu obce Lubenec (viz kapitola 9). Porovnáním výsledků klasifikace je možné zjistit, zda je vyvinutá metoda přenositelná i na jiné oblasti a jaké míry zobecnění ve výběru klasifikačních pravidel bylo dosaženo.

Již při vizuálním porovnání je zřejmé, že získaná klasifikační pravidla je možné s téměř stejným úspěchem aplikovat i na jiné oblasti. Je patrné, že dochází ke stejným problémům, jako u výřezu obce Lubenec. Nejsnáze lze klasifikovat jasně červené taškové střechy. Často se objevuje záměna budov se zpevněnými povrchy, méně často s vegetací. Problém představuje také nalezení přesného tvaru budovy. Je patrné, že větší roli hrají stíny. Častěji než u předchozího výřezu jsou chybně klasifikovány jako budovy nebo jsou zastíněné části střech klasifikovány jako stín.

Pokud je klasifikace provedena s přidáním informace o relativní výšce objektů, je již při vizuální interpretaci zřejmé, že se výrazně zvýšila její přesnost. Dochází stejně jako u předchozího výřezu k občasným záměnám se zpevněnými povrchy, vegetací a stíny ze stejných důvodů jako v kapitole 10.1.1.

Pro porovnání výsledku klasifikace výřezu obce Blatno bez použití informace o relativní výšce byla vytvořena kontingenční tabulka 10.4. Třída „budovy“ v tabulce představuje všechny typy střech nalezené během klasifikace, ve třídě „zpevněné povrchy“ v tabulce jsou zahrnutы třída „silnice“ a třída „ostatní zpevněné povrchy“ použité pro klasifikaci.

Z této tabulky vyplývá, že u třídy „budovy“ dochází k nejčastější záměně se třídou „zpevněné povrchy“. Další nejčastější záměnou budov byla záměna se třídou „stín“ a „zeleň“. Důvody, proč k těmto záměnám dochází, jsou stejné jako u výřezu obce Lubenec v kapitole 10.1.2.

Celková přesnost klasifikace je 91 %. Zpracovatelská přesnost pro třídu „budovy“ je 49,4 %, uživatelská přesnost 77,6 %. Hodnota kappa indexu pro třídu „budovy“ je

48,6 %, což odpovídá dobrému výsledku klasifikace podle tabulky 10.2. Celkem bylo po provedení klasifikace bez použití informace o relativní výšce upozorněno na 63 % budov.

Tab. 10.4: Kontingenční tabulka pro klasifikaci bez použití informace o relativní výšce pro výřez obce Blatno

Reference	Zpevněné povrchy	Pole	Zeleň	Vodní plochy	Stín	Celkem
Výsledek klasifikace						
Zpevněné povrchy	233788	41516	36962	13	919	366100
Pole	30084	2345090	56807	1752	30	2433763
Zeleň	51752	152049	1942688	824	3060	2158448
Vodní plochy	0	2682	286	287890	0	290858
Stín	8432	34	3864	858	20882	41725
Celkem	340175	2542778	2041931	291337	25323	

Pro zhodnocení přesnosti klasifikace výřezu obce Blatno s použitím informace o relativní výšce byla vytvořena kontingenční tabulka 10.5. Třída „zpevněné povrchy“ v tabulce představuje třídy „zpevněné povrchy mimo sídlo“ a „zpevněné povrchy uvnitř sídla“ v klasifikaci.

Z tabulky vyplývá, že u třídy „budovy“ dochází k nejčastější záměně se třídou „zpevněné povrchy“ a se třídou „zeleň“ a to ze stejných důvodů jako u výřezu obce Lubenec.

Celková přesnost klasifikace je 99,2 %. Zpracovatelská přesnost pro třídu „budovy“ je 92 %, uživatelská přesnost 98,5 %. Hodnota kappa indexu pro třídu „budovy“ je 91,8 %, což odpovídá výbornému výsledku klasifikace podle tabulky 10.2. Celkem bylo po provedení klasifikace s použitím informace o relativní výšce upozorněno na 90 % budov.

Z vypočtených statistických ukazatelů vyplývá, že výsledky obou typů klasifikací se u výřezu obce Blatno mírně zhoršily. Přesto je možné považovat přenositelnost metody za velmi dobrou. Především klasifikace s přidáním údajů o relativní výšce objektů vykazuje u obou výřezů stabilní a stejně kvalitní výsledky.

Tab. 10.5: Kontingenční tabulka pro klasifikaci s použitím informace o relativní výšce pro výřez obce Blatno

Reference	Zpevněné povrchy	Pole	Zelen	Vodní plochy	Stín	Celkem
Zpevněné povrchy	317341	0	365	6678	0	327974
Pole	20737	2542778	1889	0	0	2565404
Zeleň	595	0	2039297	0	0	2045813
Vodní plochy	0	0	0	284659	0	284659
Stín	0	0	0	0	25323	26688
Celkem	340175	2542778	2041931	291337	25323	

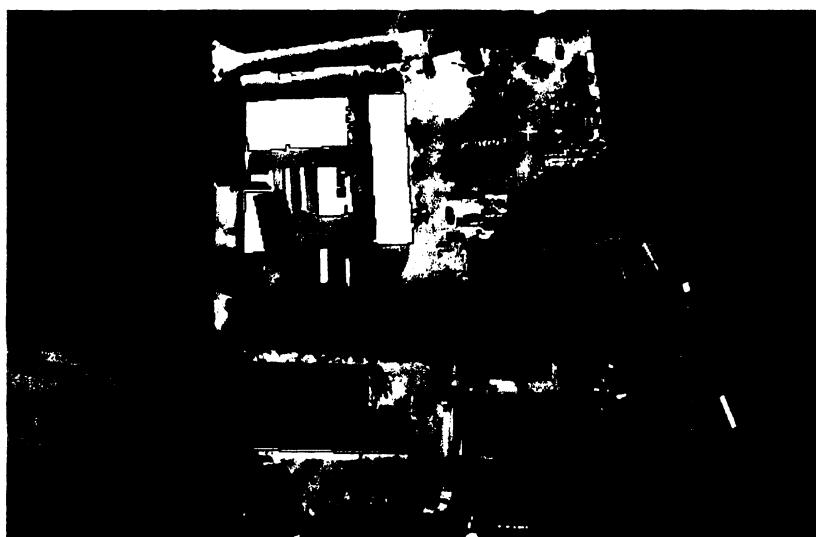
10.2 Výsledky aktualizace ZABAGED

Výsledkem klasifikace jsou polygony budov, které lze vyexportovat v programu Definiens do formátu shp. Získaná data v tomto formátu lze pak porovnávat se stávajícím stavem budov v ZABAGED.

K porovnání jsem použila program ArcGIS 9. Polygonovou vrstvu budov získanou klasifikací jsem přeložila vrstvou budov ze ZABAGED. Na monitoru jsou pak odlišnou barvou označena místa, kde došlo ke vzniku nových budov. Na tato místa je třeba se zaměřit a ZABAGED na podkladu družicového snímku aktualizovat. Při opačném přeložení vrstev je možno vidět budovy, které zanikly.

Na obrázku 10.1 lze vidět polygony původních budov v ZABAGED, polygony budov získané klasifikací družicového snímku a družicový snímek. Aktualizované polygony na obrázku představují nově postavený průmyslový areál.

Obr. 10.1: Nalezený nově vzniklý průmyslový areál



■ stávající stav ZABAGED

klasifikaci získané polygony budov

11 Diskuse použitých dat, metod a výsledků

11.1 Data

V této práci byly přestaveny dvě metody klasifikace družicového snímku. První metoda byla založena pouze na spektrálních vlastnostech objektů a na jejich tvaru. Ve druhé metodě byla do klasifikace zahrnuta i relativní výška objektů. Ukázalo se, že především druhá metoda používající digitální model povrchu (DMP) vykazuje velmi dobré a stabilní výsledky.

Pro tvorbu DMP se standardně používají data laserového skenování (viz např. v Hofmann 2001, Braumann 2006). Datum pořízení DMP by se mělo shodovat s datem pořízení snímku. Pro zvolenou testovací oblast však nebyla takováto data k dispozici. K vytvoření DMP jsem proto použila program SilverEye, jehož prostřednictvím je možné na družicovém snímku Quickbird určit pomocí měření velikosti stínů výšku objektů, které je vrhají. Tento způsob vytváření digitálního modelu povrchu však není automatický a je nutné měřit zvlášť každý objekt. Kvalita výsledného DMP je poté závislá především na operátorovi, který ho vytváří, a na jeho zkušenostech s tímto způsobem vytváření DMP. Naopak nevyskytuje se u něj chyby charakteristické pro jiné způsoby jeho získávání, jako je např. u laserového skenování šum. Použitý manuální způsob není vhodný pro generování DMP většího území a proto se nehodí pro aktualizaci map. Pro použití vytvořené metody klasifikace ke skutečné aktualizaci map bych proto doporučovala zvolit jiný způsob získávání DMP, například z dat laserového skenování.

Mezi daty ZABAGED a snímkem družice Quickbird se vyskytuje velmi málo odlišností. To je způsobeno skutečností, že snímek i data ZABAGED byla pravděpodobně pořízena v přibližně stejném časovém období. Tento údaj však není možné ověřit, protože u dat ZABAGED nebylo ČÚZK sděleno datum poslední aktualizace.

K porovnání výsledku klasifikace se v praxi používají referenční data např. v podobě existující topografické nebo katastrální mapy. K dispozici však nebyla žádná referenční data z období pořízení použitého snímku Quickbird, která by odpovídala tehdejšímu stavu budov na území obou obcí, na nichž byla metoda testována. Referenční maska byla proto vytvořena manuální klasifikací družicového snímku Quickbird s důrazem na správné určení budov a jejich tvar. Menší důraz byl kladen na ostatní třídy například na

odlišení zeleně a sklizeného pole, protože jejich určení nebylo cílem klasifikace a jejich odlišení je v některých případech pouze subjektivní. Z tohoto důvodu je možné, že se celková přesnost klasifikace projevuje nadhodnocenými hodnotami.

11.2 Postup a výsledky

Výhodou navrženého postupu je jeho přenositelnost na druhém výřezu snímku družice Quickbird (viz kapitola 10.1.3). Vzhledem k poskytnutým datům ale metody nebylo možné otestovat na odlišném území ani na různých snímcích. Výsledek klasifikace však může být ovlivněn rozdílnými povětrnostními podmínkami, stavem vegetace nebo intenzitou slunečního záření, které závisí na ročním období a denní době. Doporučovala bych pořizovat snímky v takovém ročním období, kdy je většina zemědělských ploch pokryta vegetací, která je od střech, silnic a jiných zpevněných ploch poměrně dobře odlišitelná pomocí vegetačního indexu. Bylo by tak možné snížit počet chybně klasifikovaných segmentů, které vznikly v důsledku záměny taškových střech s půdou bez vegetace.

Schiewe et al. (2001) vidí hlavní nevýhodu programu Definiens ve velké časové náročnosti nalezení parametrů segmentace a klasifikace snímků. Další nevýhodu spatřuje ve striktním oddělení segmentace a klasifikace, protože použitelnost vygenerovaných segmentů musí být nejprve posouzena lidským interpretem ještě předtím, než se může přistoupit ke klasifikaci. Přitom kvalita výsledku klasifikace velmi závisí na kvalitě segmentace (viz kapitola 10). Nastavení parametrů segmentace je nutné časově náročně testovat, jejich použití však téměř nelze z vědeckého hlediska zdůvodnit. Časově náročné a neautomatizované je také vytvoření klasifikačních pravidel a nalezení prahových hodnot. Pro úspěšnou klasifikaci snímku jsou třeba značné zkušenosti s tímto typem klasifikace a vytvoření mnoha pokusných řad pro nalezení optimálního nastavení všech parametrů. Také možnost vytvářet vlastní algoritmy je omezená. Je sice možné tvořit nové příznaky objektů pomocí kombinace existujících příznaků v kalkulátoru, vytváření nových funkcí však není možné. Například budovu od silnice by bylo možné odlišit pomocí stínu, který se vždy nachází v její severní části a nikdy v její jižní části. Takovýto příznak však není v Definiens implementován a ani ho není možné vytvořit.

11.3 Použití výsledků

Předností použití objektově orientované klasifikace je vytvoření polygonů, které je možno uložit ve vektorovém formátu pro GIS a porovnávat nebo začlenit je do vektorové databáze (např. ZABAGED).

Družicové snímky by bylo vhodné používat pouze jako doplněk a ne jako hlavní zdroj dat. Družice mohou být například použity k opakovanému získávání snímků rychle se měnících oblastí (např. okrajové části měst) v častých intervalech a umožnit tak odhalit změnu rychleji, než je možné jinými metodami.

Domnívám se, že navržená metoda je použitelná právě v okolí velkých měst a jiných řídkých intravilánech, kde dochází k velmi častým změnám. Budovy stojí v takovýchto oblastech samostatně, bývají obklopeny zelení a nevytvářejí kompaktní bloky. To je příhodné pro automatickou klasifikaci, protože nedochází tak často ke zmatení algoritmu v důsledku velkého množství různých povrchů rozdílných tvarů s odlišnou spektrální odrazivostí. Chování vyvinutých klasifikačních algoritmů v kompaktních urbánních oblastech však nebylo možné otestovat a posoudit, je však pravděpodobné, že by došlo ke zhoršení výsledku klasifikace.

Významným limitujícím faktorem, proč uživatelé nezapojují družicová data do větších projektů, je nezaručitelnost dostupnosti dat i v budoucnosti, a to zvláště u družic, které létají po oběžné dráze pouze v jednom exempláři. Tento problém by se vyřešil, pokud by tyto družice byly doplněny dalšími, které by je v případě potřeby mohly nahradit a byly by vytvořeny sestavy takovýchto družic pro dálkový průzkum Země. Pak by mohlo být realizováno i plně funkční využití družicových dat pro topografické mapování.

12 Závěr

V současné době dochází k rychlým a častým změnám v urbánních oblastech, rychle se mění a vyvíjí především zástavba. Uživatelé map a geografických databází však kladou velké požadavky na jejich aktuálnost. Stoupá tedy potřeba tyto změny rychle analyzovat a zaznamenávat. Hlavním cílem této práce bylo proto vyvinutí metody pro zachycení změn zástavby v ZABAGED na podkladu družicového snímku velmi vysokého rozlišení.

Výsledně byla vyvinuta metoda klasifikace, která ve snímku pořízeném družicí Quickbird detekuje budovy. K vývoji této metody byl použit software Definiens, který ke klasifikaci obrazových dat používá metodu objektově orientované klasifikace. Byl sestaven soubor klasifikačních pravidel, která využívají nejen spektrální příznaky objektů, ale také jejich tvar, texturu a vztahy k sousedním objektům.

Dalšími dílčími cíli práce bylo otestování navržené metodiky a zhodnocení výsledků, porovnání výsledků se ZABAGED a její aktualizace a podání přehledu současných metod a zdrojů dat pro aktualizaci topografických map.

Lze konstatovat, že záměry vytyčené v úvodu práce byly splněny. Již při vizuálním posouzení výsledků bylo zřejmé, že na podkladu družicového snímku lze budovy s úspěchem klasifikovat. Docházelo ale k poměrně častým změnám se silnicemi a ostatními zpevněnými plochami uvnitř sídel. Testováním bylo zjištěno, že výsledek klasifikace lze výrazně vylepšit použitím informace o relativní výšce objektů. Přenositelnost metody se po otestování na druhém výřezu snímku Quickbird ukázala jako velmi dobrá.

Metodu aktualizace je možné považovat za metodu semiautomatickou. Výsledkem klasifikace snímku je vektorová vrstva budov. Tento klasifikací získaný aktuální stav budov je nutné porovnat se stavem zástavby v ZABAGED a provést manuální aktualizaci. Budovy označené při klasifikaci slouží jako upozornění pro lidského operátora, že v území nastala změna.

Představenou metodu je možné využít jako doplněk současné metody aktualizace ZABAGED pro oblasti, v nichž dochází k nejčastějším změnám zástavby, což jsou dnes především okrajové části velkých měst. Zde se projeví výhoda použití družicových snímků. Mohou být pořizovány v častých intervalech a změna tak může být odhalena rychleji, než umožňují jiné metody.

Perspektivu využití představené metody v praxi by mohla zvýšit obzvláště záruka dostupnosti družicových dat i do budoucnosti. Bylo by příliš riskantním krokem založit projekt aktualizace na jediném fungujícím exempláři družice a tato skutečnost dnes představuje podstatný limitující faktor zapojení družicových dat do větších a dlouhodobějších projektů.

13 Abstrakt

Dostatečně častá aktualizace topografických map a geodatabází je úkolem mnoha mapovacích úřadů a organizací. V dnešní době převážně využívaná manuální aktualizace je však časově i finančně náročná. Tato práce se proto zaměřila na zautomatizování tohoto procesu a prezentuje semiautomatickou metodu detekce změn budov založenou na klasifikaci družicového snímku Quickbird.

Klasifikace byla provedena v programu Definiens 5 Professional, který používá metodu objektově orientované klasifikace. Její hlavní výhoda oproti metodám per pixel spočívá v tom, že kromě spektrálních příznaků mohou být při klasifikaci vyžity i další příznaky objektů jako např. tvar, textura nebo vztahy k sousedním objektům.

Ze statistického zhodnocení výsledků vyplývá, že na podkladu družicového snímku lze budovy s úspěchem klasifikovat. Testováním bylo zjištěno, že výsledek klasifikace lze výrazně vylepšit použitím informace o relativní výšce objektů. Přenositelnost metody se po otestování na druhém výřezu snímku Quickbird ukázala jako velmi dobrá.

Výsledkem klasifikace jsou polygony budov ve vektorovém formátu. Tyto polygony byly porovnány s vrstvou budov v ZABAGED a na modelovém území byla provedena její aktualizace.

Tato metoda je využitelná zejména pro aktualizace řídkých intravilánů a rychle se měnících oblastí. Družicové snímky mohou být pořizovány v častých intervalech a změna tak může být odhalena rychleji, než umožňují jiné metody.

Abstract

A task for organizations that create and maintain cartographic databases is the need to update those databases sufficiently frequently. Nowadays geospatial data are usually updated manually, however it is very time-consuming and expensive. In this thesis, a semiautomatic change detection approach based on classification of Quickbird imagery is introduced. The main aim was to develop a classification procedure to support the update of buildings in the geospatial database ZABAGED.

The image analysis was evaluated through the Definiens 5 Professional software that uses an object-oriented approach. Classification is based on features calculated for segments. These features not only draw on spectral values but may also be related to e.g. shape, texture or neighbourhood relations.

The evaluation of the results shows that it is possible to classify buildings successfully using satellite imagery. The tests demonstrate that using the relative high of objects as an additional information can help to detect buildings more accurately. The transferability of the presented method from one data set to another proved satisfactory results.

The products of classification are polygons of buildings in vector format. These were compared with the layer of buildings in ZABAGED and the update was performed in the test site.

The potential of using this method to support the update of cartographic databases can be considered very high, especially in rapidly changing urban fringe areas. The satellite can be used to obtain frequent snapshots of rapidly changing areas, enabling change to be detected more readily than is possible by other methods.

14 Seznam literatury

14.1 Prameny

1. ARCDATA PRAHA [online]. 2007 [cit. 12.3.2007]. Dostupný z WWW: <<http://www.arcdata.cz/data/druzicova/quickbird>>.
2. Český úřad zeměměřický a katastrální [online]. 2007 [cit. 7.2.2007]. Dostupný z WWW: <<http://www.cuzk.cz>>.
3. Definice objektů ZABAGED (2000): interní dokument ČÚZK.
4. DigitalGlobe [online]. 2007 [cit. 12.3.2007]. Dostupný z WWW: <<http://www.digitalglobe.com>>.
5. European Space Imaging (2003): Flanders Chooses Ikonos, tisková zpráva [online]. 2003 [cit. 15.2.2007]. Dostupná z WWW: <<http://www.Euspaceimaging.com/content/Downloads/news/15-july-2003.pdf>>.
6. GeoTango [online]. 2005 [cit. 10.3.2007]. Dostupný z WWW: <<http://www.geotango.com>>.
7. HOLLAND, D., MARSHALL, P. (2003): Using High-resolution Imagery in a Well-mapped Country. ISPRS/EARSEL International Workshop “High Resolution Mapping from Space”, Hannover, Germany [online]. 2003 [cit. 12.2.2007]. Dostupný z WWW: <<http://www.ipi.uni-hannover.de/html/publikationen/2003/workshop/holland.pdf>>.
8. Ordnance Survey [online]. 2007 [cit. 10.2.2007]. Dostupný z WWW: <<http://www.ordnancesurvey.co.uk>>.

9. SCHIEWE, J. (2006): Segmentierungsverfahren in der Fernerkundung [online]. 2006 [cit. 6.2.2007]. Dostupný z WWW: <<http://www.fergi.unisnabueck.de/module/seg/deutsch/>>.

10. TOMPKINSON, T. et al. (2005): A 'primitive' view of image interpretation for automated mapping [online]. 2005 [cit. 17.2.2007]. Dostupný z WWW: <<http://www.ordnancesurvey.co.uk/oswebsite/partnerships/research/publications/remotesensing.html>>.

14.2 Literatura

1. ANDERSON, J. M., MIKHAIL, E. M. (1998): Surveying : Theory and practice. New York, McGraw-Hill, 1167 s.

2. BENZ, U. C. et al. (2004): Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. ISPRS Journal of Photogrammetry and Remote Sensing, 58, č. 3 - 4, s. 239 - 258.

3. BLASCHKE, T. (2005): Towards a framework for change detection based on image objects. In: Erasmi, S., Cyffka, B., Kappas, M. (Eds.): Göttinger Geographische Abhandlungen, Vol. 113, Göttingen.

4. BLASCHKE, T., STROBL, J. (2001): What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. GeoBIT/GIS, č. 6, s. 12-17.

5. BRAUMANN, B. (2006): Objektorientierte Gebäudedetektion in Laserscannerdaten und multispektralen Bildern. Institut für Photogrammetrie und Fernerkundung der Technischen Universität Wien, 87 s.

6. DEFINIENS AG (2006a): Definiens Professional 5 - Userguide. München, 249 s.

7. DEFINIENS AG (2006b): Definiens Professional 5 – Reference Book. München, 122 s.
8. HALOUNOVÁ, L. (2002): Zkušenosti s programem eCognition pro klasifikaci urbanizovaného území z leteckých černobílých snímků a snímků (TM). In: Proceedings of Devátý ročník konference GIS...Ostrava. Ostrava, 27. - 30. ledna 2002.
9. HALOUNOVÁ, L., PAVELKA, K. (2005): Dálkový průzkum Země. Praha, Vydavatelství ČVUT, 192 s.
10. HANUŠ, J. (2002): Možnosti aktualizace databáze ZABAGED z družicových dat vysokého rozlišení. Diplomová práce, Katedra geodézie a kartografie ČVUT, Praha.
11. HNOJIL, J., ZAORALOVÁ, J. (2003): Řešení vybraných problémů spojených s aktualizací ZABAGED, Zdiby, VÚGTK, 25 s.
12. HOFFMANN, A., VAN DER VEGT, J. W., LEHMANN, F. (2000): Die automatisierte Aktualisierung von Karten: Neue Methoden mit Daten der digitalen Kamera HRSC-A. Kartographische Nachrichten, 50, č. 5, s. 211 – 217.
13. HOFMANN, P. (2001): Detecting buildings and roads from IKONOS data using additional elevation information. GIS, 2001, č. 6, s. 28-33.
14. HOLLAND, D. A., BOYD, D. S., MARSHALL, P. (2006): Updating topographic mapping in Great Britain using imagery from high-resolution satellite sensors. ISPRS Journal of Photogrammetry and Remote Sensing, 60, č. 3, s. 212 - 223.
15. HOLLAND, D., GUILFORD, B., MURRAY, K. (2002): Oeepe-Project on Topographic Mapping from High Resolution Space Sensors. October Oeepe Official Publication No 44.

16. HOLLAND, D., MARSHALL, P. (2004): Updating maps in a well-mapped country using high resolution satellite imagery. In: Proceedings of the 20th ISPRS Congress, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Part B2, 12-23 July 2004, Istanbul, Turkey, s. 747-751.
17. JODOUIN, S. et al. (2003): Spatial database updating using active contours for multispectral images: application with Landsat 7. *ISPRS Journal of Photogrammetry and Remote Sensing*, 57, č. 5 - 6, s. 346 – 355.
18. JUNG, F. (2004): Detecting building changes from multitemporal aerial stereopairs. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58, č. 3 - 4, s. 187 - 201.
19. KAMAGATA, N. et al. (2005): Comparison of pixel-based and object-based classifications of high resolution satellite data in urban fringe areas. In: Proceedings of the 26th Asian Conference on Remote Sensing. Hanoi, Vietnam. 7 - 11 November 2005.
20. KETTIG, R. L., LANDGREBE, D. A. (1976): Classification of Multispectral Image Data by Extraction and Classification of Homogeneous Objects. *IEEE Transactions on Geoscience Electronics*, 14, č. 1, s. 19 – 26.
21. Koncepce 2. etapy vývoje Základní báze geografických dat (1999): Zpravodaj ČÚZK.
22. KRESSLER, F. P., STEINNOCHER, K., FRANZEN, M. (2005): Object-Oriented Classification of Orthophotos to support update of Spatial Databases. In: Proceedings of the IGARSS 2005 Symposium. Seoul, Korea. 25 – 29 July 2005.
23. KRESSLER, F. P., STEINNOCHER, K., KIM, Y. S. (2005): Enhanced Semi-Automatic Image Classification of High-Resolution Data. In: Proceedings of the IGARSS 2005 Symposium. Seoul, Korea, 25 – 29 July 2005.

24. KUMAR, M., CASTRO, O. T. (2001): Practical aspects of IKONOS imagery for mapping. In: Proceedings of the ACRS 2001 - 22nd Asian Conference on Remote Sensing. Singapore, 5 - 9 November 2001, s. 1181-1185.
25. LANG, S., SCHÖPFER, E., BLASCHKE, T. (2003): Object-specific change detection based on assisted feature extraction: A case study of an expanding suburban area. In: Proceedings of the ISPRS WG VII/4 Symposium. Regensburg, Germany, 27 – 29 June 2003, s. 93 – 97.
26. LEE, D. S., SHAN, J., BETHEL, J. S. (2003): Class-Guided Building Extraction from Ikonos Imagery. Photogrammetric Engineering and Remote Sensing, 69, č. 2, s. 143 - 150.
27. LEMP, D., WEIDNER, U. (2005): Segment-Based Characterization of Roof Surfaces Using Hyperspectral and Laser Scanning Data. In: Proceedings of the IGARSS 2005 Symposium. Seoul, Korea, July 25-29, 2005.
28. LHOMME, S., HE, D., MORIN, D. (2003): Errors analysis of IKONOS imagery over an urban environment. In: Proceedings of the ISPRS WG VII/4 Symposium. Regensburg, Germany, 27 – 29 June 2003, s. 245 - 247.
29. LI, R. (1998): Potential of High-Resolution Satellite Imagery for National Mapping Products. Photogrammetric Engineering and Remote Sensing, 64, č. 12, s. 1165 – 1170.
30. LIČEV, L. (2001): Fotogrammetrické systémy a rozpoznávání zájmových bodů. In: Proceedings of Osmý ročník konference GIS...Ostrava. Ostrava, 21. – 24. ledna 2001.
31. LIN, CH., NEVATIA, R. (1998): Building Detection and Description from a Single Intensity Image. Computer Vision and Image Understanding, 72, č. 2, s. 101 – 121.

32. LIU, Z. J., WANG, J., LIU, W. P. (2005): Building Extraction from High Resolution Imagery based on Multi-scale Object Oriented Classification and Probabilistic Hough Transform. In: Proceedings of the IGARSS 2005 Symposium. Seoul, Korea. 25 - 29 July 2005.
33. MARANGOZ et al. (2004): Comparison of pixel-based and object-oriented classification using Ikonos imagery for automatic building extraction – Safranbolu testfield. In: Proceedings of the XXth ISPRS Congress. Istanbul, Turkey, 12 – 23 July 2004.
34. MARANGOZ, A. M., ORUC, M., BUYUKSALIH, G. (2004): Object-oriented image analysis and semantic network for extracting the roads and buildings from IKONOS pan-sharpened images. In: Proceedings of the ISRPS 2004 Annual Conference. Istanbul, Turkey, 19 – 23 July 2004.
35. MIKŠOVSKÝ, M., ŠÍDLO, B. (2001): Topografické mapování území České republiky ve 20. století. Geodetický a kartografický obzor, 47/89, č. 8-9, s. 216 – 223.
36. NEUBERT, M., MEINEL, G. (2003): Evaluation of segmentation programs for high resolution remote sensing applications. In: Schroeder, Jacobsen, Heipke (Eds.): Proceedings of the Joint ISPRS/EARSeL Workshop "High Resolution Mapping from Space 2003", Hannover, Germany, 6-8 October 2003.
37. ORUC, M. et al. (2004): Comparison of pixel-based and object-oriented classification approaches using Landsat-7 ETM spectral bands. In: Proceedings of the ISRPS 2004 Annual Conference, Istanbul, Turkey, July 19 – 23 2004.
38. OWINGS, R. (2005): GPS mapping: make your own maps. Fort Bragg, Ten Mile Press, 374 s.
39. PAVELKA, K. (2003): Fotogrammetrie 10. Praha, Vydavatelství ČVUT, 194 s.

40. RIDLEY, H. M. et al. (1997): Evaluating the Potential of the Forthcoming Commercial U.S. High-Resolution Satellite Sensor Imagery at the Ordnance Survey. *Photogrammetric Engineering and Remote Sensing*, 63, č. 8, s. 997 – 1005.
41. ROSSI, L. (2003): Satellite high resolution new applications: Quickbird. In: Proceedings of the EFITA 2003 Conference. Debrecen, Hungary, 5 – 9 July 2003, s. 388 – 392.
42. SCHIEWE, J., TUFTE, L., EHLERS, M. (2001): Potential and Problems of Multi-Scale Segmentation Methods in Remote Sensing. *Geo-Informations-Systeme*, č. 6, s. 34-39.
43. SCHNEIDER, W. (2002): „Knowledge based methods of Analysis of Remotely Sensed Images for Landscape Ecology. In: Pillmann, Tochtermann (Eds.), EnviroInfo, 25-27 Sept. 2002, Vienna, 1, s. 538– 545; IGU/ISEP, International Society for Environmental Protection, Vienna.
44. STEILEN, G. (2002): Klassifikation hochauflösender Satellitendaten mit Hilfe der Segmentierungssoftware eCognition. Göttingen, Universität, Geograph. Inst., Diplomarbeit
45. TOMOWSKI, D. et al. (2006): Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten. Osnabrück, Institut für Geoinformatik und Fernerkundung, 129 s.
46. TOMPKINSON, T. (2005): Image primitives: automating image interpretation procedures in topographic map production. VIE 2005, IEE International Conference on Visual Information Engineering. Glasgow, 4-6 April 2005, s. 165-172.
47. ÜNSALAN, C., BOYER, K. L. (2005): A system to detect houses and residential street networks in multispectral satellite images. *Computer Vision and Image Understanding*, 98, č. 3, s. 423 - 461.

48. VEVERKA, B. (2001): Topografická a tematická kartografie 10. Praha, Vydatelství ČVUT, 220 s.
49. WALTER, V. (2004): Object-based classification of remote sensing data for change detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58, č. 3 - 4, s. 225 – 238.
50. WHITESIDE, T., AHMAD, W. (2005): A comparison of object-oriented and pixel-based classification methods for mapping land cover in northern Australia. In: Proceedings of SSC2005 Spatial intelligence, innovation and praxis: The national biennial Conference of the Spatial Sciences Institute. Melbourne, Astralia, September 2005.
51. WILLHAUCK, G. (2000): Comparison of object oriented classification techniques and standard image analysis for the use of change detection between SPOT multispectral satellite images and aerial photos. In: ISPRS, Vol. XXXIII, Amsterdam, 2000.
52. ZHANG, Q. et al. (2005): Detection of Recently Constructed Multi-storey Buildings Using SPOT Panchromatic and Landsat TM/ETM+ Data. *Geocarto International*, 20, č. 1, s. 3 – 13.
53. ZHANG, Y. (1999): Optimization of building detection in satellite images by combining multispectral classification and texture filtering. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, č. 1, s. 50 - 60.
54. ZHANG, Y., MAXWELL T. (2006): A fuzzy logic approach to supervised segmentation for object-oriented classification. In: Proceedings of ASPRS 2006 Annual Conference, Reno, Nevada, 1-5 May 2006.

15 Seznam obrázků

Obr. 6.1: Porovnání výsledku klasifikace per pixel, která způsobila vznik málo spolu souvisejících tříd (vlevo), a objektově orientované klasifikace (vpravo).....	27
Obr. 7.1: Vytváření hierarchické sítě v Definiens	32
Obr. 8.1: Výřez z multispektrálního snímku družice Quickbird, vlevo zobrazení v přirozených barvách, vpravo kombinace s infračerveným pásmem	37
Obr. 8.2: Klad listů ZAGAGED.....	38
Obr 8.3: Znázornění relativních výšek vytvořené programem SilverEye (vlevo) a totéž území v přirozených barvách (vpravo)	40
Obr. 8.4: Perspektivní pohled na část území obce Blatno vytvořený programem SilverEye z družicového snímku QuickBird	41
Obr. 9.1: Schéma průběhu objektově orientované klasifikace dat dálkového průzkumu Země.....	42
Obr. 9.2: Ukázka segmentace s rozdílným nastavením parametrů pro spektrální kritérium – vlevo 0,2, vpravo 0,8.....	44
Obr. 9.3: První zkušební klasifikace třídy budov.....	45
Obr. 9.4: Hierarchie tříd v Definiens pro klasifikaci budov.....	46
Obr. 9.5: Klasifikační pravidla třídy „sídlo“	47
Obr. 9.6: Klasifikační pravidla třídy „ne sídlo“	48
Obr. 9.7: Popis třídy „bílé střechy“ s kombinacemi logických spojek „and (min)“ a „or (max)“	52
Obr. 9.8: Ukázka výsledku klasifikace	52
Obr. 9.9: Hierarchie tříd pro klasifikace budov s přidáním informace o relativní výšce	53
Obr. 9.10: Ukázka výsledku klasifikace s přidáním informace o relativní výšce.....	54
Obr. 10.1: Nalezený nově vzniklý průmyslový areál.....	63

16 Seznam tabulek

Tab. 2.1: Analýza typů objektů, které mohou být získány ze snímků družice QuickBird v měřítkách mapování 1 : 2 500, 1 : 10 000 a 1: 25 000.....	11
Tab. 9.1: Nastavení segmentačních parametrů v Definiens	45
Tab. 9.2: Prahové hodnoty příznaků Mean B a Ratio R pro klasifikaci taškových střech.....	50
Tab. 10.1: Kontingenční tabulka pro klasifikaci bez použití informace o relativní výšce	56
Tab. 10.2: Hodnocení kappa indexu	58
Tab. 10.3: Kontingenční tabulka pro klasifikaci s použitím informace o relativní výšce	59
Tab. 10.4: Kontingenční tabulka pro klasifikaci bez použití informace o relativní výšce pro výřez obce Blatno.....	61
Tab. 10.5: Kontingenční tabulka pro klasifikaci s použitím informace o relativní výšce pro výřez obce Blatno.....	62

17 Seznam příloh

Příloha I: Popis tříd, klasifikačních příznaků, prahových hodnot a funkcí příslušnosti

Příloha II: Výsledek klasifikace výřezu snímku obce Lubenec bez použití informace o relativní výšce

Příloha III: Výsledek klasifikace výřezu snímku obce Lubenec s použitím informace o relativní výšce

Příloha IV: Výsledek klasifikace výřezu snímku obce Blatno bez použití informace o relativní výšce

Příloha V: Výsledek klasifikace výřezu snímku obce Blatno s použitím informace o relativní výšce

Příloha VI: Referenční data výřezu snímku obce Lubenec

Příloha VII: Referenční data výřezu snímku obce Blatno

Příloha I: Popis tříd, klasifikačních příznaků, prahových hodnot a funkcí příslušnosti

V příloze se nalézá detailní popis všech tříd, klasifikačních příznaků, prahových hodnot a funkcí příslušnosti použitých v metodě představené v této práci.

1 Klasifikace bez použití relativní výšky

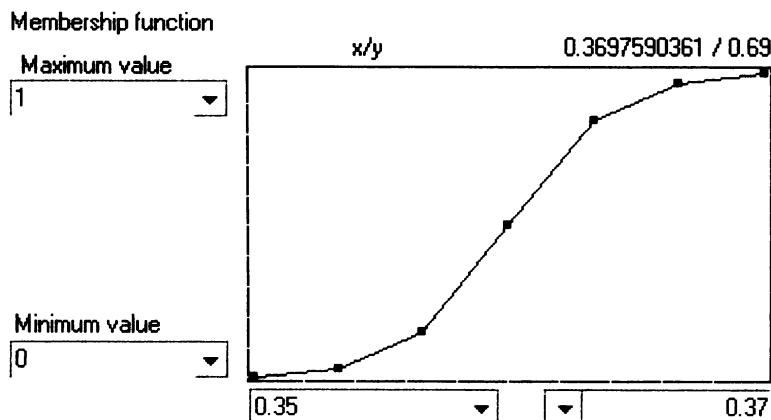
1.1 První segmentační úroveň

Třída „zeleně“

Popis třídy

- • Contained
- and (min)
└─ NDVI
- ⚡ Inherited
 - ○ and (min) (level1)
└─ Level

Funkce příslušnosti NDVI

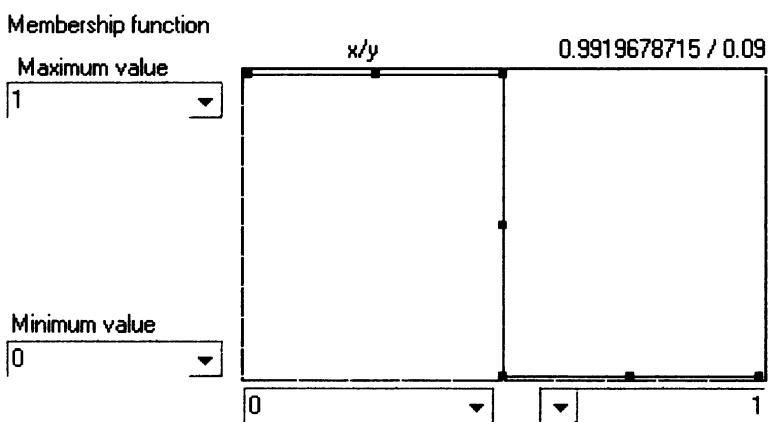


Třída „pole“

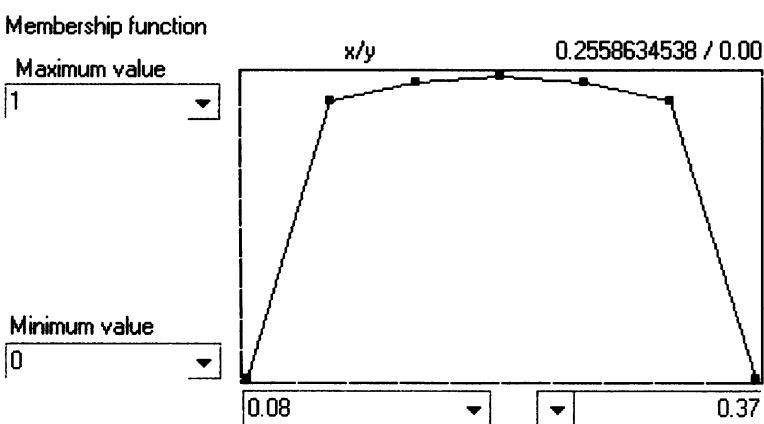
Popis třídy

- • Contained
 - and (min)
 - ↳ Existence of super objects sídlo (1)
 - △ NDVI
- • Inherited
 - ○ and (min) (level1)
 - △ Level

Funkce příslušnosti Existence of super objects sídlo



Funkce příslušnosti NDVI

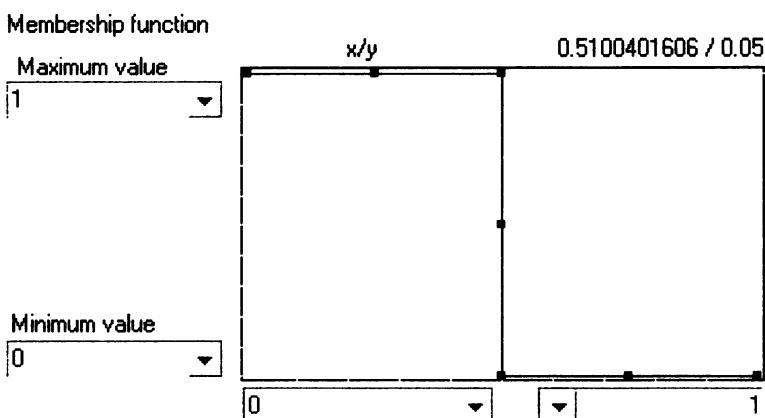


Třída „ostatní“

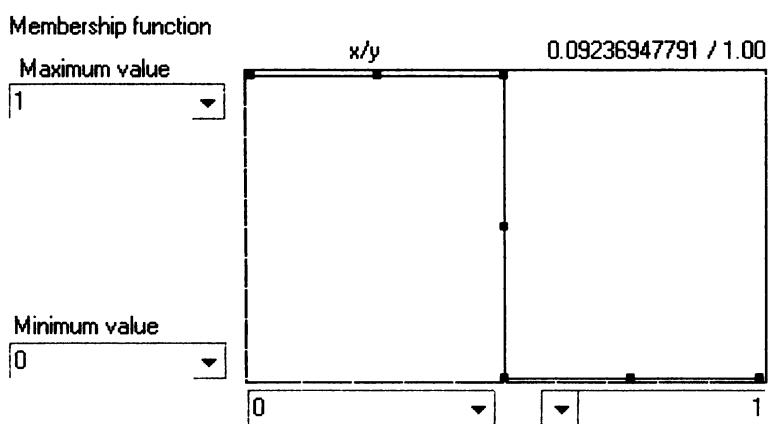
Popis třídy

- • Contained
 - and (min)
 - └─ Classified as pole
 - └─ Classified as zelen
- • Inherited
 - and (min) (level1)
 - └─ Level

Funkce příslušnosti Classified as pole



Funkce příslušnosti Classified as zelen

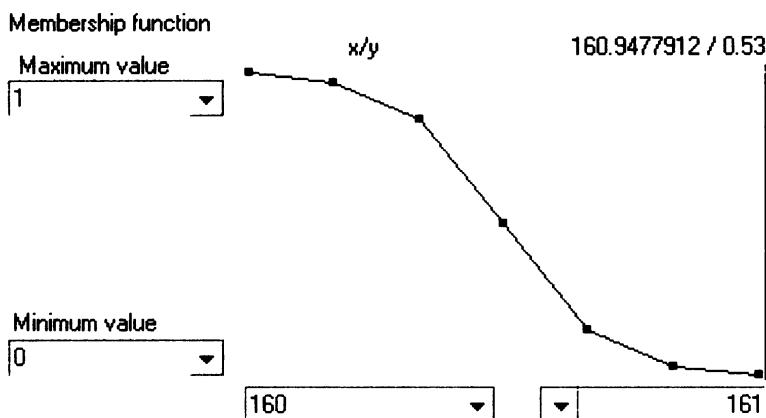


Třída „stín“

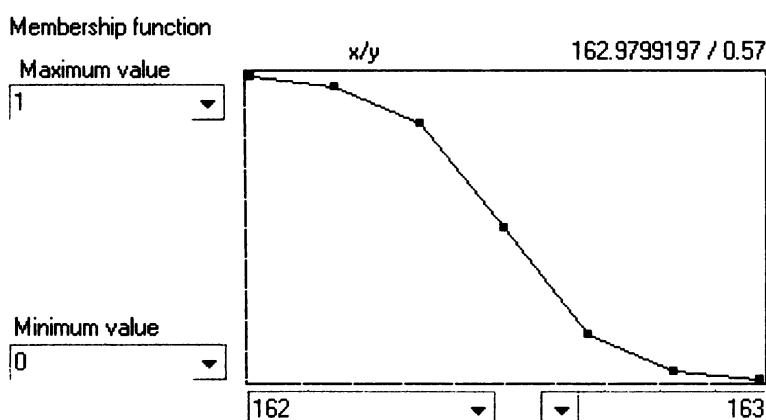
Popis třídy

- • Contained
 - and (min)
 - ↳ Brightness
 - ↳ Mean B
- • Inherited
 - ○ and (min) (level1)
 - ↳ Level
 - ○ and (min) (ostatní)
 - ↳ Classified as pole
 - ↳ Classified as zelen

Funkce příslušnosti Brightness



Funkce příslušnosti Mean B

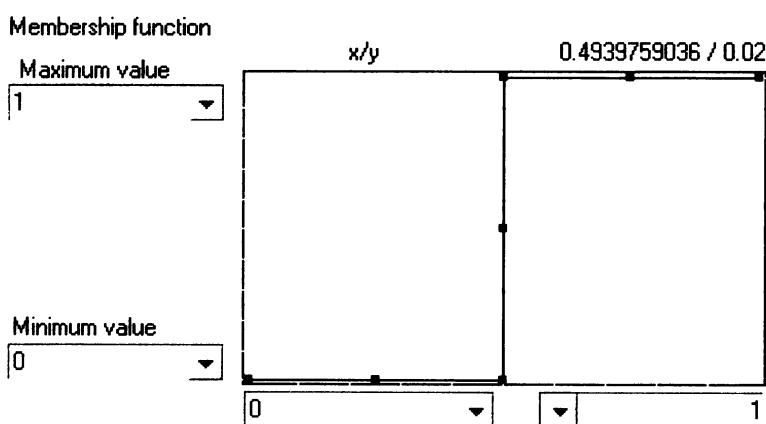


Třída „vodní plochy“

Popis třídy

- • Contained
 - and (min)
 - ✓ Existence of super objects kandidát vodní plochy (1)
- • Inherited
 - ○ and (min) (level1)
 - △ Level
 - ○ and (min) (ostatní)
 - ✗ Classified as pole
 - ✗ Classified as zelen

Funkce příslušnosti Existence of super objects kandidát vodní plochy



Třída „zpevněné povrchy“

Popis třídy

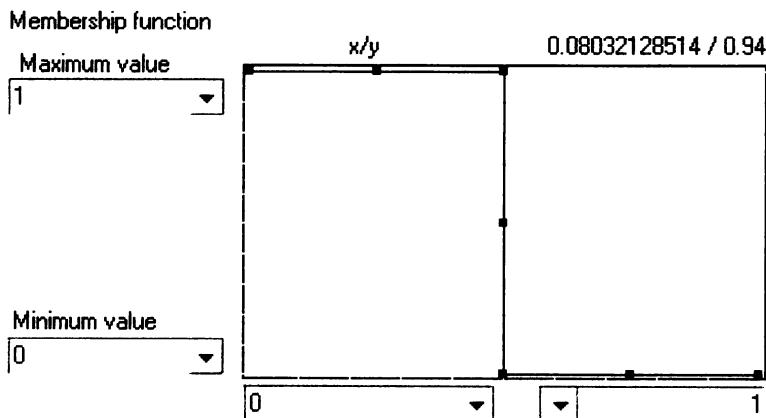
- • Contained
 - and (min)
 - ↔ not stín
 - ↔ not vodní plochy
- • Inherited
 - ○ and (min) (level1)
 - △ Level
 - ○ and (min) (ostatní)
 - ✗ Classified as pole
 - ✗ Classified as zelen

Třída „zpevněné povrchy mimo sídlo“

Popis třídy

- • Contained
 - and (min)
 - ↳ Existence of super objects sídlo (1)
- ↳ Inherited
 - ○ and (min) (level1)
 - ↳ Level
 - ○ and (min) (ostatní)
 - ↳ Classified as pole
 - ↳ Classified as zeleň
 - ○ and (min) (zpevněné povrchy)
 - ↔ not stín
 - ↔ not vodní plochy

Funkce příslušnosti Existence of super objects sídlo

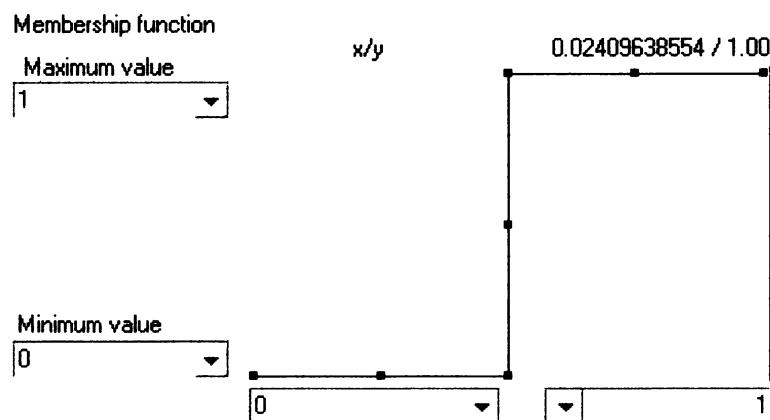


Třída „zpevněné povrchy uvnitř sídla“

Popis třídy

- • Contained
 - and (min)
 - ↳ Existence of super objects sídlo (1)
- ↳ Inherited
 - ○ and (min) (level1)
 - ↳ Level
 - ○ and (min) (ostatní)
 - ↳ Classified as pole
 - ↳ Classified as zeleň
 - ○ and (min) (zpevněné povrchy)
 - ↔ not stín
 - ↔ not vodní plochy

Funkce příslušnosti Existence of super objects sídlo

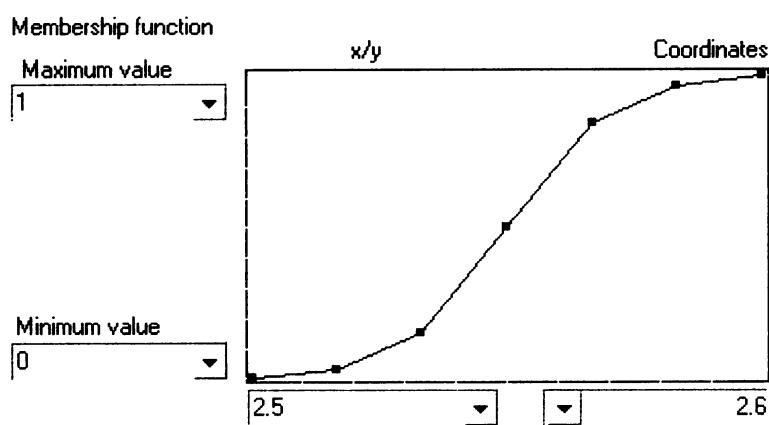


Třída „silnice“

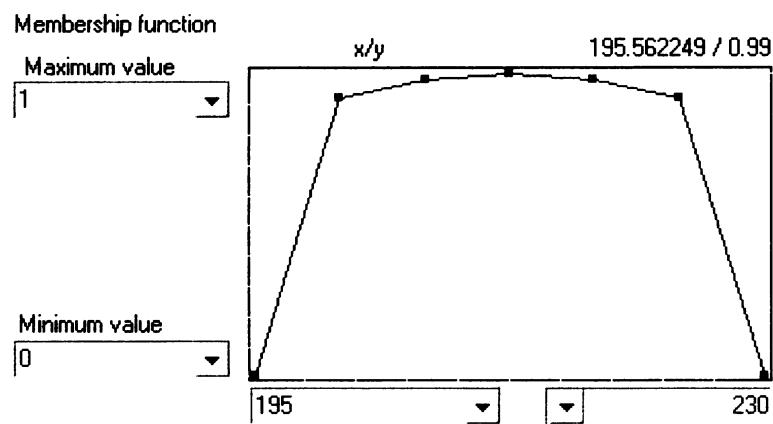
Popis třídy

- • Contained
 - and (min)
 - LengthWidth
 - Mean B
 - Ratio R
 - Inherited
 - ○ and (min) (level1)
 - Level
 - ○ and (min) (ostatní)
 - Classified as pole
 - Classified as zelen
 - ○ and (min) (zpevněné povrchy uvnitř sídla)
 - Existence of super objects sídlo (1)
 - ○ and (min) (zpevněné povrchy)
 - not vodní plochy
 - not stín

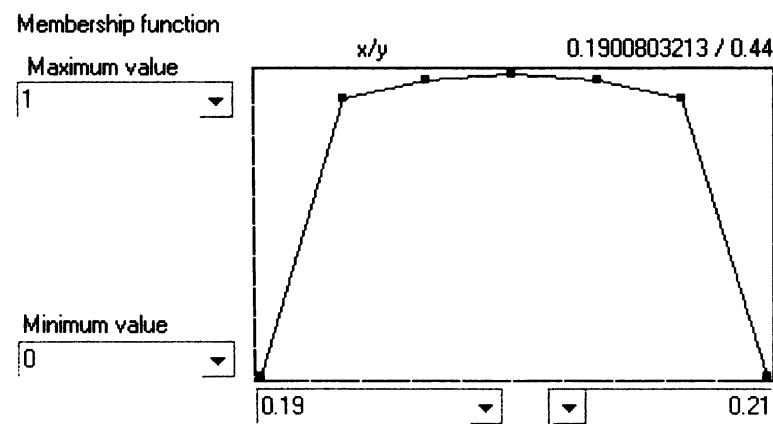
Funkce příslušnosti Length/Width



Funkce příslušnosti Mean B



Funkce příslušnosti Ratio R

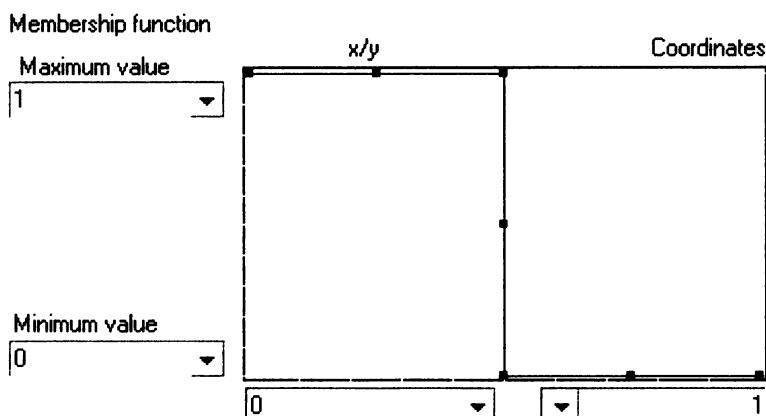


Třída „ostatní zpevněné povrchy I“

Popis třídy

- • Contained
 - and (min)
 - ↳ **Classified as silnice**
- • Inherited
 - ○ and (min) (level1)
 - ↳ **Level**
 - ○ and (min) (ostatní)
 - ↳ **Classified as pole**
 - ↳ **Classified as zeleň**
 - ○ and (min) (zpevněné povrchy uvnitř sídla)
 - ✓ **Existence of super objects sídlo (1)**
 - ○ and (min) (zpevněné povrchy)
 - **not stín**
 - **not vodní plochy**

Funkce příslušnosti Classified as silnice

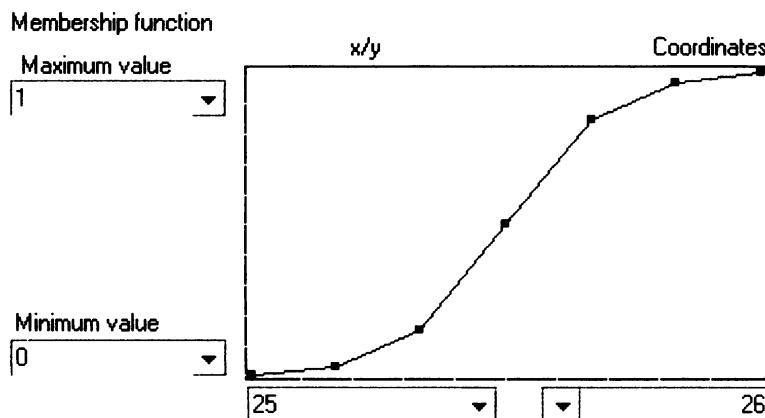


Třída „červené střechy“

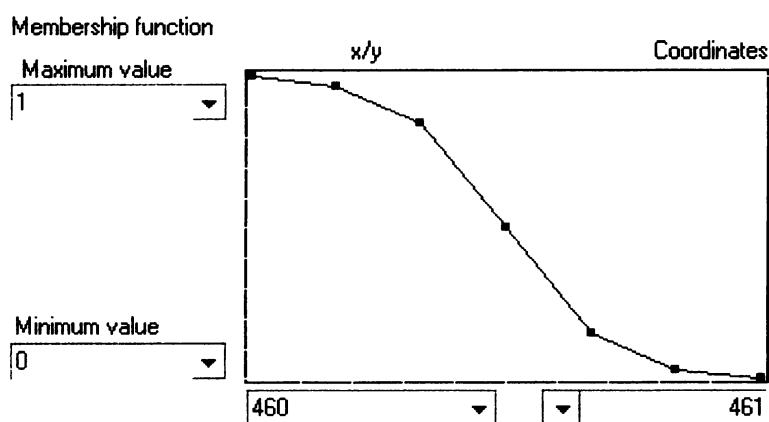
Popis třídy

- • Contained
 - and (min)
 - Area**
 - Brightness**
 - Length/Width**
 - Mean B**
 - Ratio R**
 - Rectangular Fit**
 - Inherited
 - ○ and (min) (level1)
 - Level**
 - ○ and (min) (ostatní zpevněné povrchy1)
 - Classified as silnice**
 - ○ and (min) (ostatní)
 - Classified as pole**
 - Classified as zeleň**
 - ○ and (min) (zpevněné povrchy uvnitř sídla)
 - Existence of super objects sídlo (1)**
 - ○ and (min) (zpevněné povrchy)
 - not stín**
 - not vodní plochy**

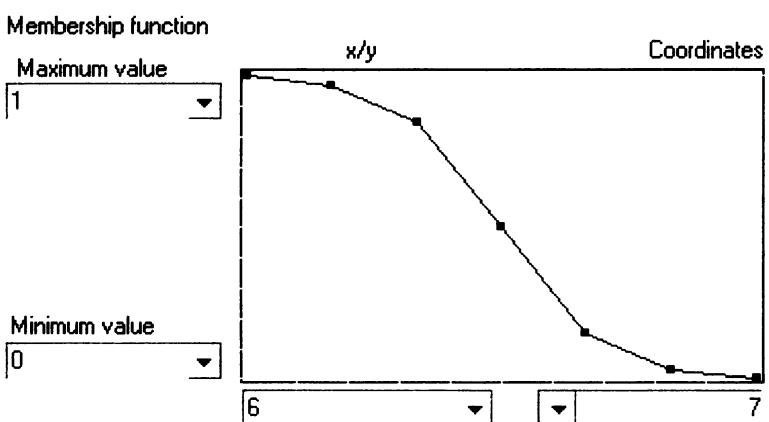
Funkce příslušnosti Area



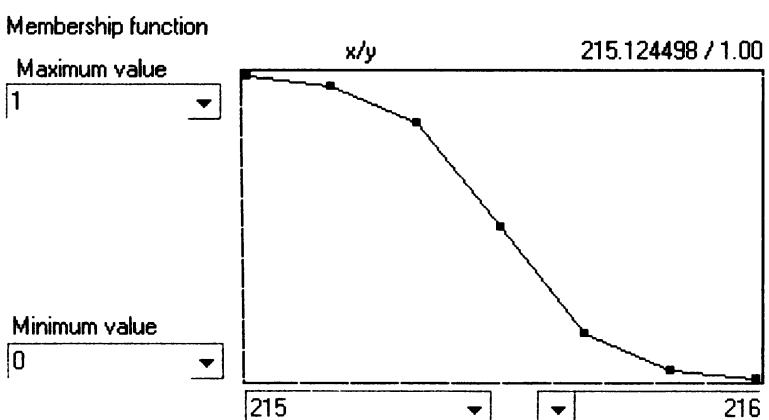
Funkce příslušnosti Brightness



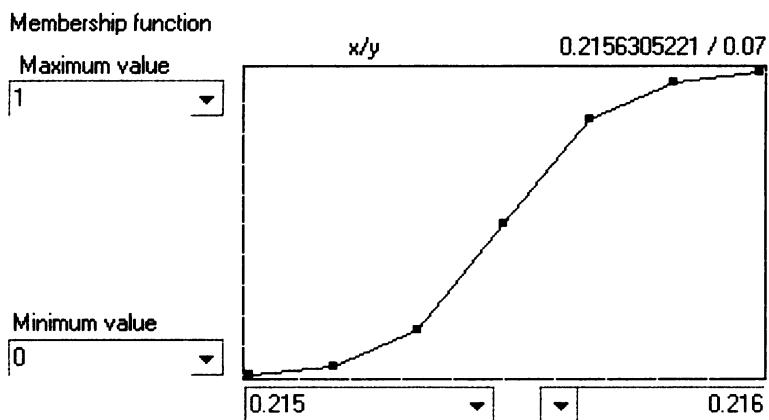
Funkce příslušnosti Length/Width



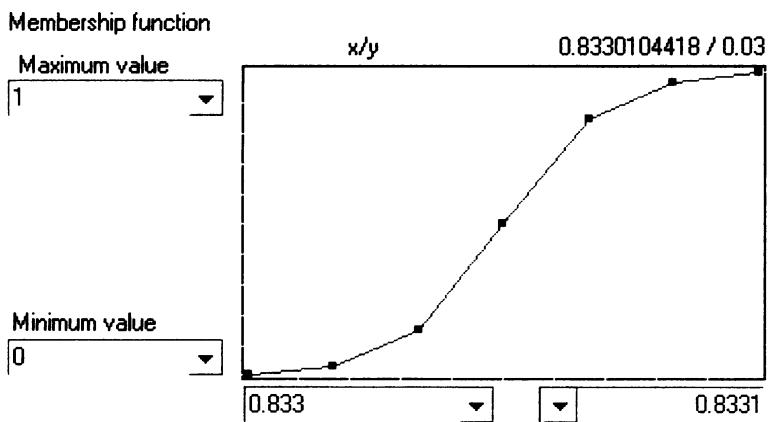
Funkce příslušnosti Mean B



Funkce příslušnosti Ratio R



Funkce příslušnosti Rectangular Fit

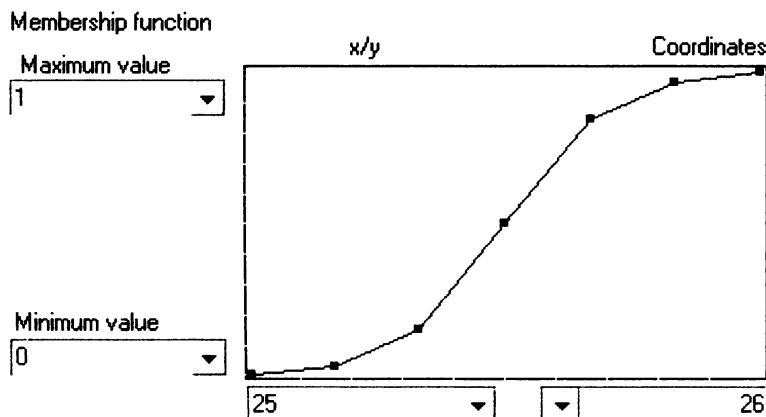


Třída „světle červené střechy“

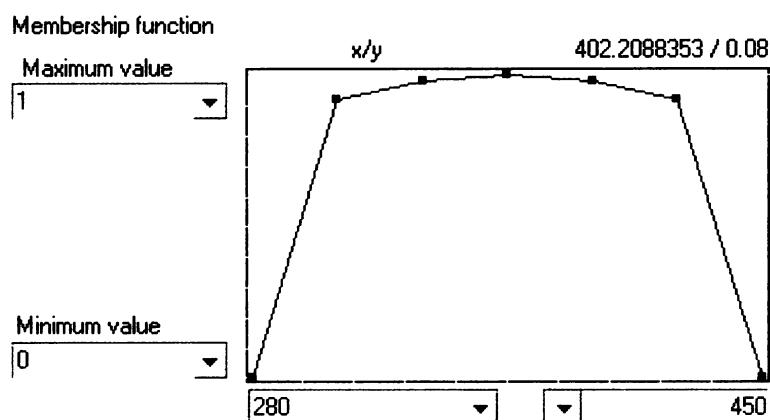
Popis třídy

- • Contained
 - and (min)
 - Area**
 - Brightness**
 - Length/Width**
 - Mean B**
 - NDVI**
 - Ratio R**
 - Rectangular Fit**
- Inherited
 - ○ and (min) (level1)
 - Level**
 - ○ and (min) (ostatní zpevněné povrchy1)
 - Classified as silnice**
 - ○ and (min) (ostatní)
 - Classified as pole**
 - Classified as zelen**
 - ○ and (min) (zpevněné povrchy uvnitř sídla)
 - Existence of super objects sídlo (1)**
 - ○ and (min) (zpevněné povrchy)
 - not stín**
 - not vodní plochy**

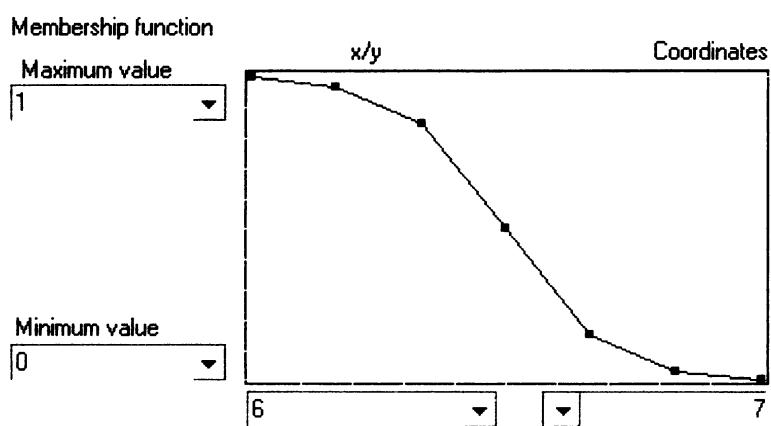
Funkce příslušnosti Area



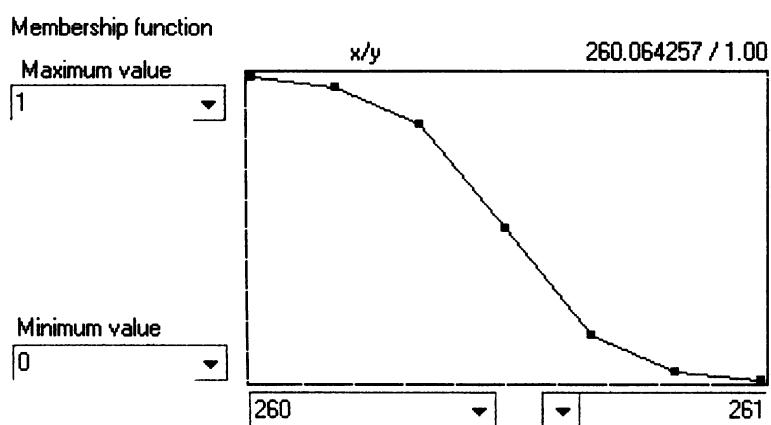
Funkce příslušnosti Brightness



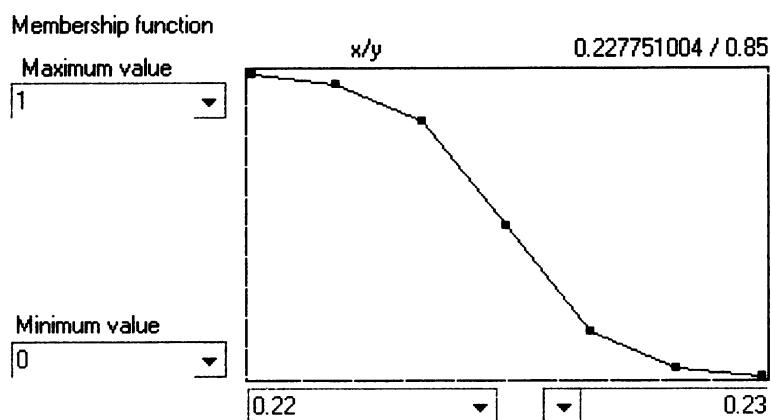
Funkce příslušnosti Length/Width



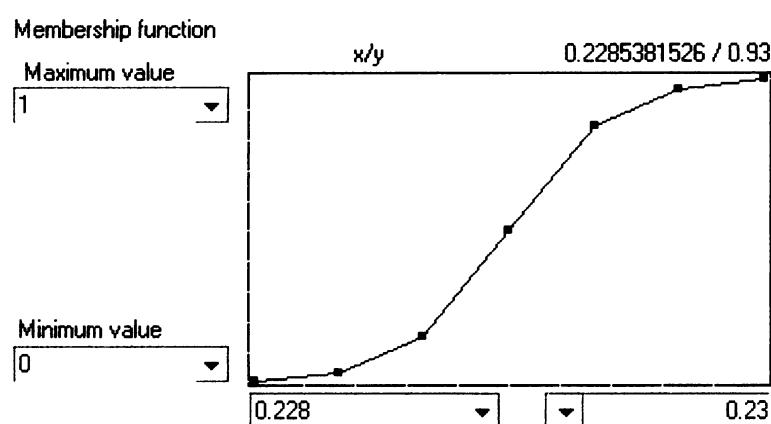
Funkce příslušnosti Mean B



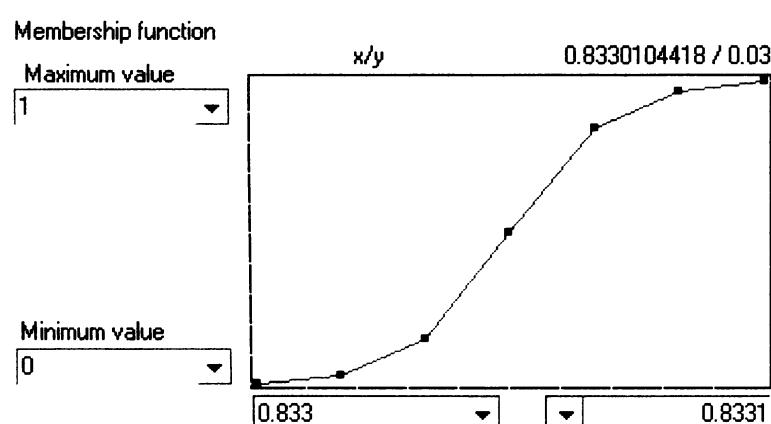
Funkce příslušnosti NDVI



Funkce příslušnosti Ratio R



Funkce příslušnosti Rectangular Fit

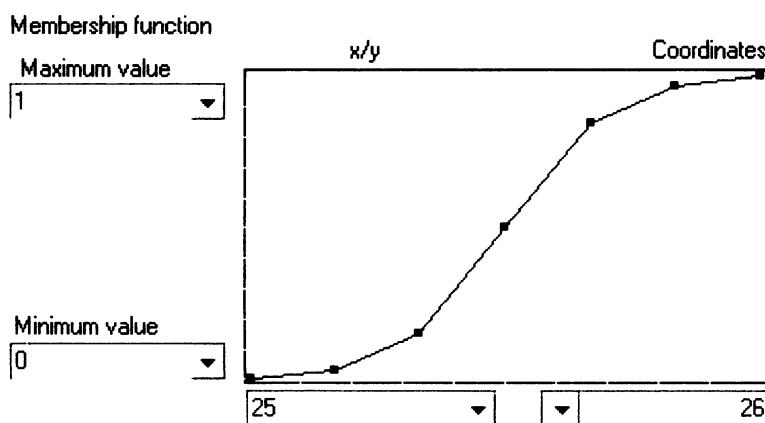


Třída „osvícené části střech“

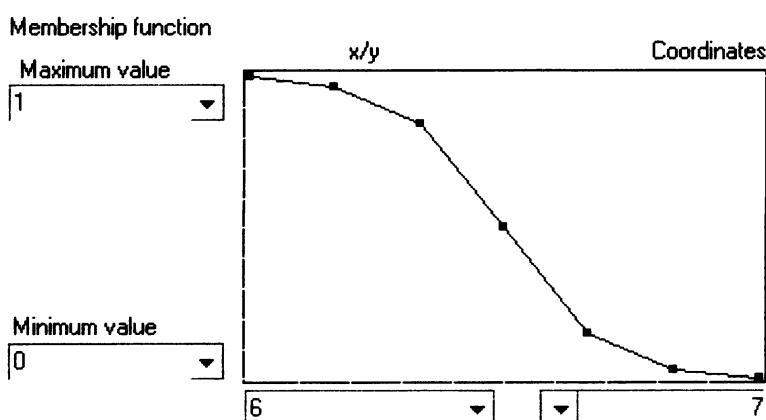
Popis třídy

- • Contained
 - **and (min)**
 - Area**
 - Length/Width**
 - Mean B**
 - Mean R**
 - Rectangular Fit**
 - Inherited
 - and (min) (level1)
 - Level**
 - and (min) (ostatní zpevněné povrchy1)
 - Classified as silnice**
 - and (min) (ostatní)
 - Classified as pole**
 - Classified as zeleň**
 - and (min) (zpevněné povrchy uvnitř sídla)
 - Existence of super objects sídlo (1)**
 - and (min) (zpevněné povrchy)
 - not stín**
 - not vodní plochy**

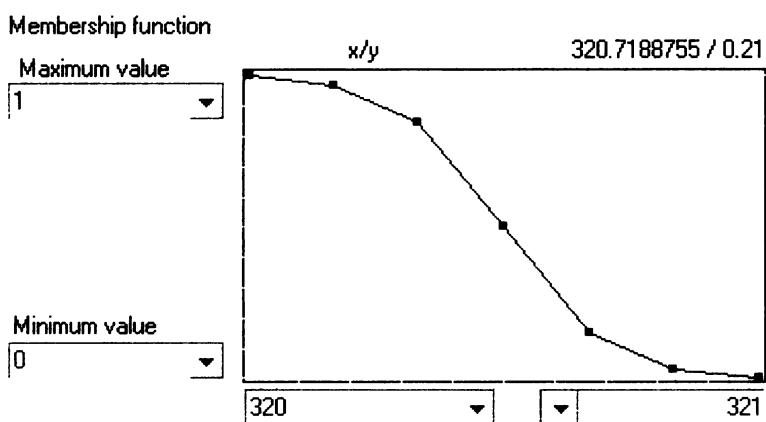
Funkce příslušnosti Area



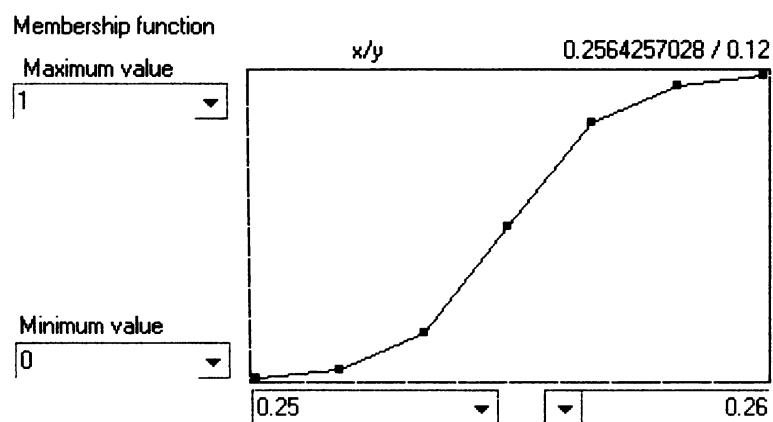
Funkce příslušnosti Length/Width



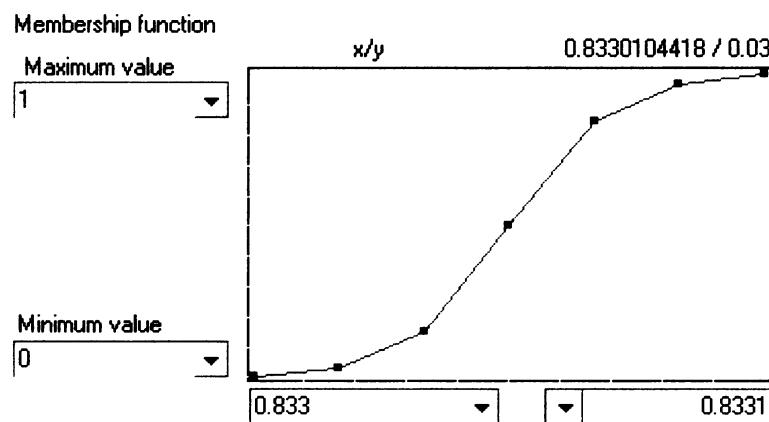
Funkce příslušnosti Mean B



Funkce příslušnosti Ratio R



Funkce příslušnosti Rectangular Fit

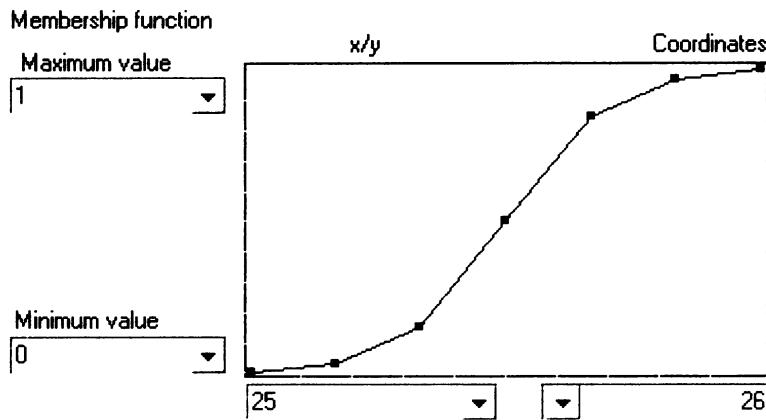


Třída „šedočervené střechy“

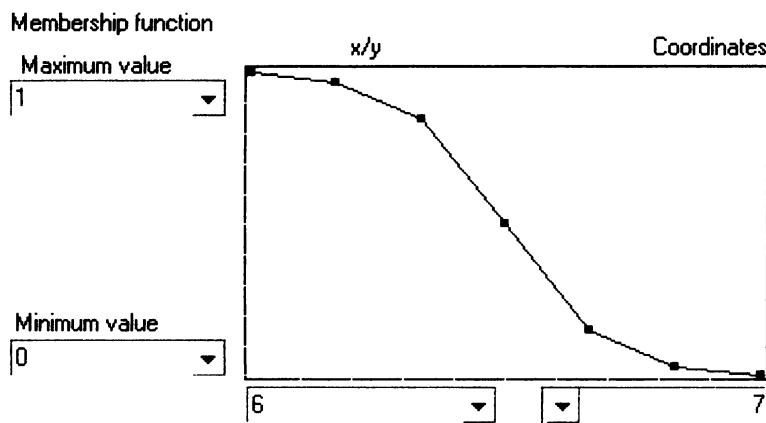
Popis třídy

- • Contained
 - and (min)
 - Area**
 - Length/Width**
 - Mean B**
 - Ratio R**
 - Rectangular Fit**
 - Inherited
 - ○ and (min) (level1)
 - Level**
 - ○ and (min) (ostatní zpevněné povrchy1)
 - Classified as silnice**
 - ○ and (min) (ostatní)
 - Classified as pole**
 - Classified as zelen**
 - ○ and (min) (zpevněné povrchy uvnitř sídla)
 - Existence of super objects sídlo (1)**
 - ○ and (min) (zpevněné povrchy)
 - not stín**
 - not vodní plochy**

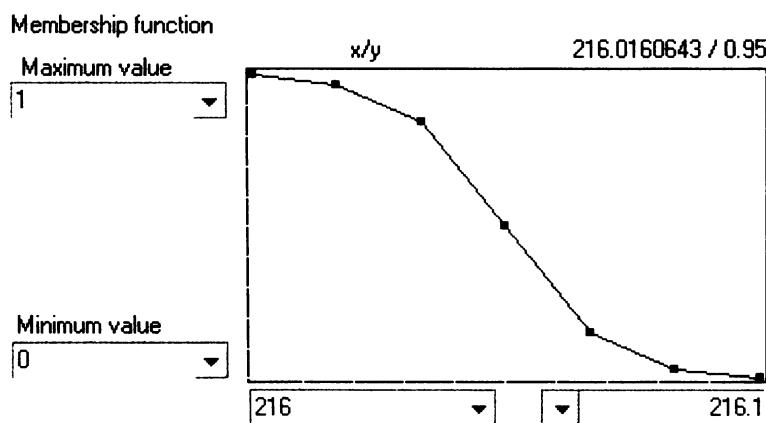
Funkce příslušnosti Area



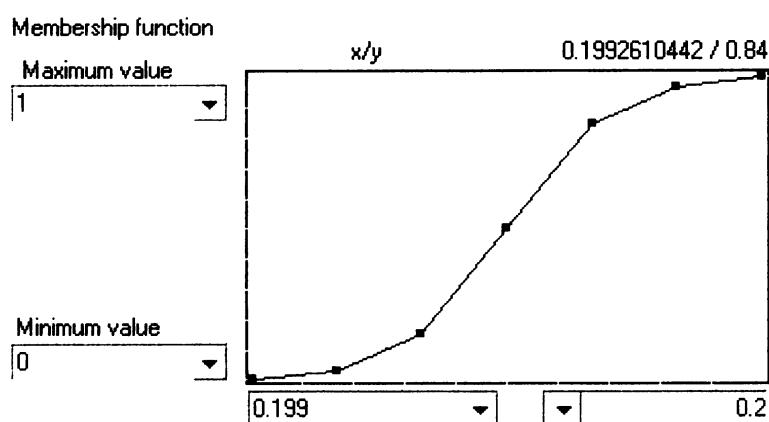
Funkce příslušnosti Length/Width



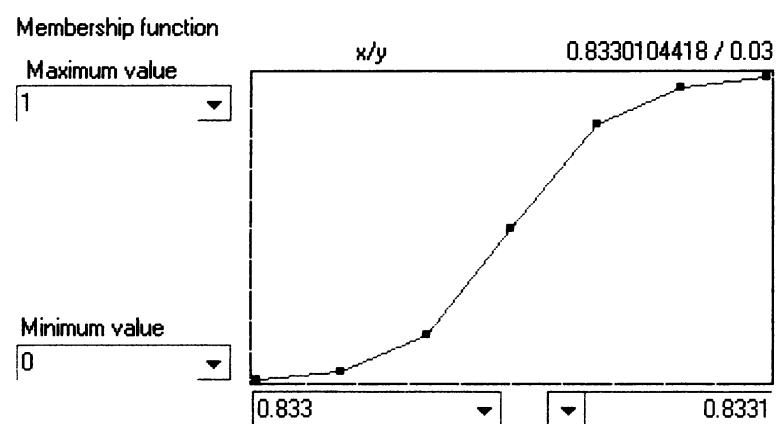
Funkce příslušnosti Mean B



Funkce příslušnosti Ratio R



Funkce příslušnosti Rectangular Fit

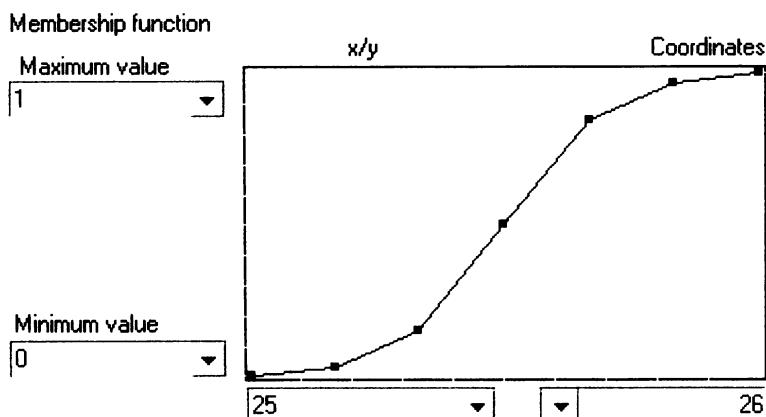


Třída „bílé střechy“

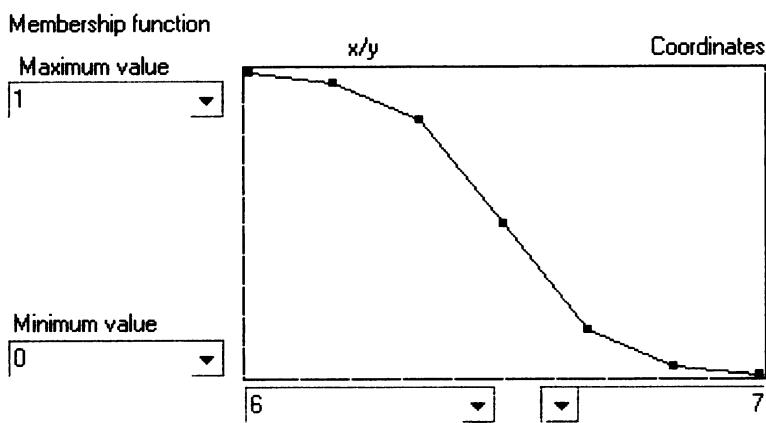
Popis třídy

- • Contained
- and (min)
 - Area
 - Length/Width
 - or (max)
 - Brightness
 - Mean B
 - Rectangular Fit
- Inherited
 - and (min) (level1)
 - Level
 - and (min) (ostatní zpevněné povrchy1)
 - Classified as silnice
 - and (min) (ostatní)
 - Classified as pole
 - Classified as zeleň
 - and (min) (zpevněné povrchy uvnitř sídla)
 - Existence of super objects sídlo (1)
 - and (min) (zpevněné povrchy)
 - not stín
 - not vodní plochy

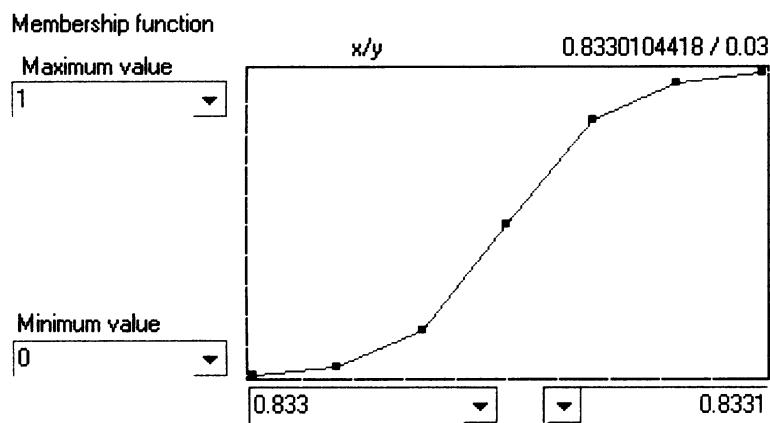
Funkce příslušnosti Area



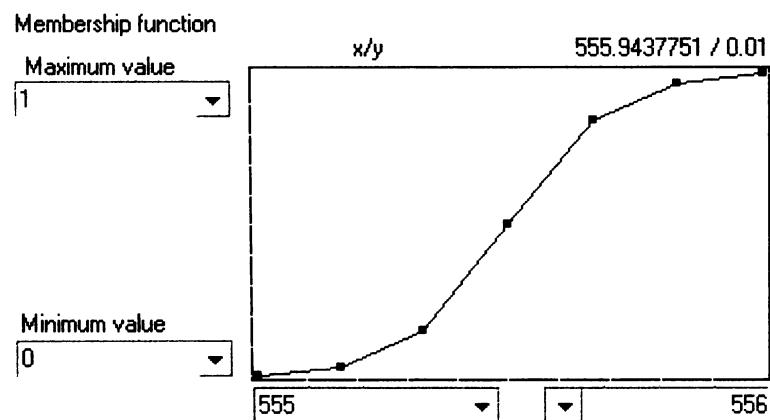
Funkce příslušnosti Length/Width



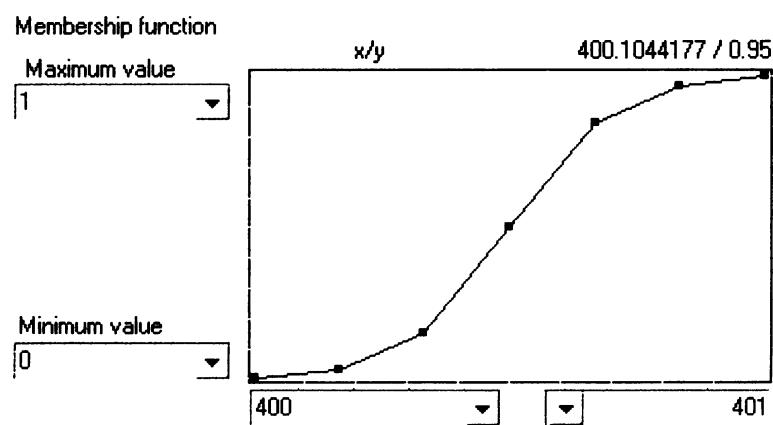
Funkce příslušnosti Rectangular Fit



Funkce příslušnosti Brightness



Funkce příslušnosti Mean B

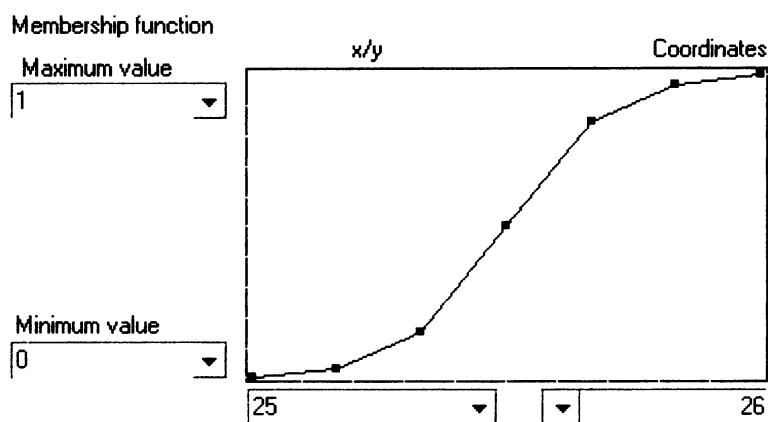


Třída „tmavě šedé střechy“

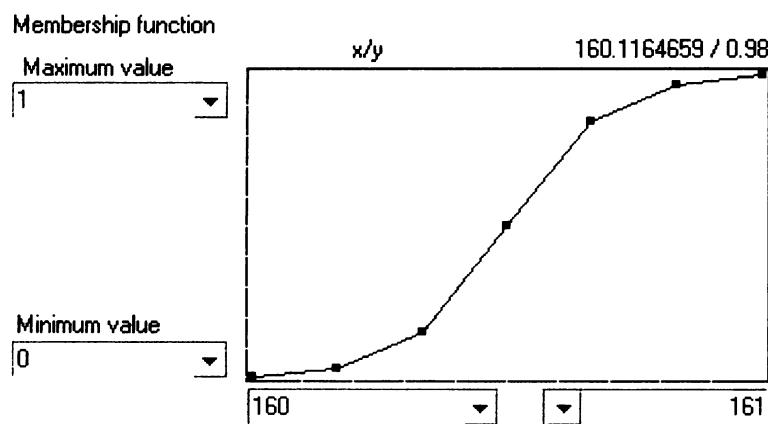
Popis třídy

- • Contained
 - and (min)
 - Area
 - Brightness
 - Length/Width
 - Mean B
 - Mean IR
 - Rectangular Fit
 - Inherited
 - and (min) (level1)
 - Level
 - and (min) (ostatní zpevněné povrchy)
 - Classified as silnice
 - and (min) (ostatní)
 - Classified as pole
 - Classified as zelen
 - and (min) (zpevněné povrchy uvnitř sídla)
 - Existence of super objects sídlo (1)
 - and (min) (zpevněné povrchy)
 - not stín
 - not vodní plochy

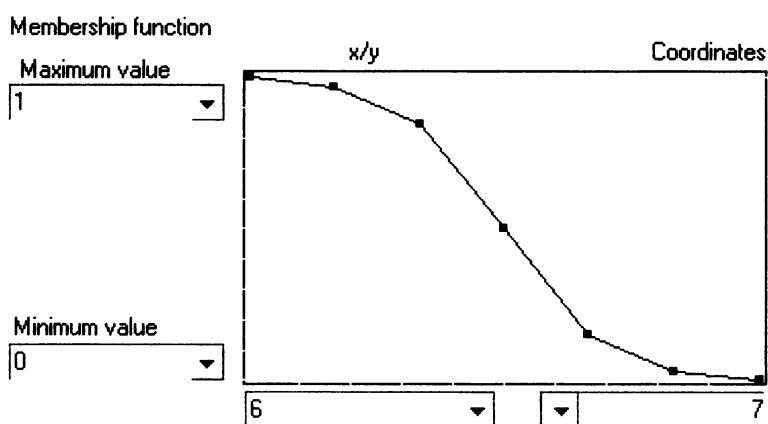
Funkce příslušnosti Area



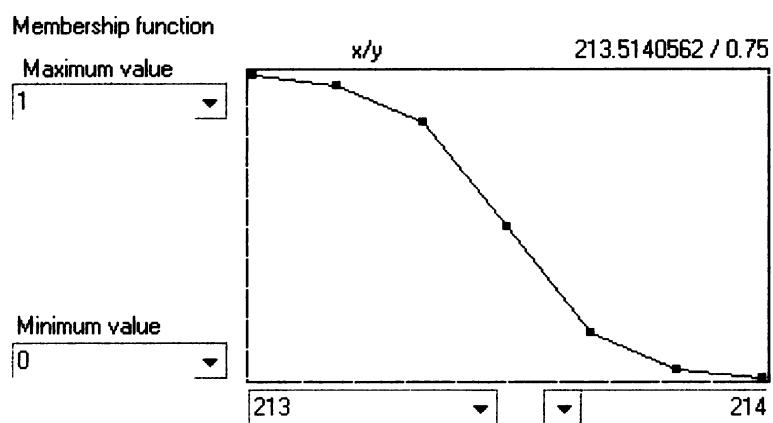
Funkce příslušnosti Brightness



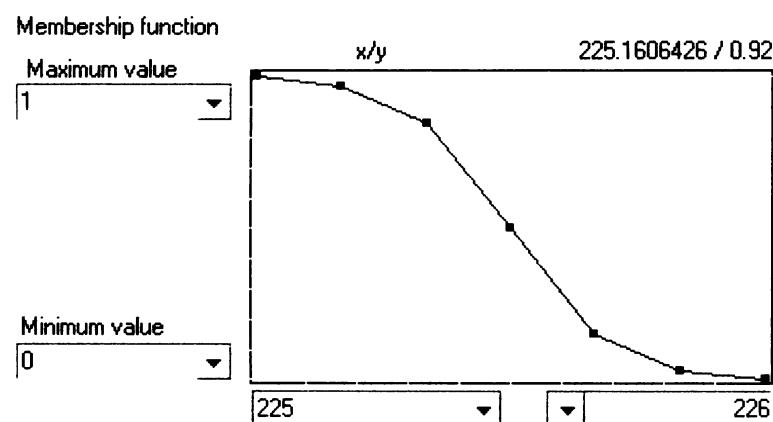
Funkce příslušnosti Length/Width



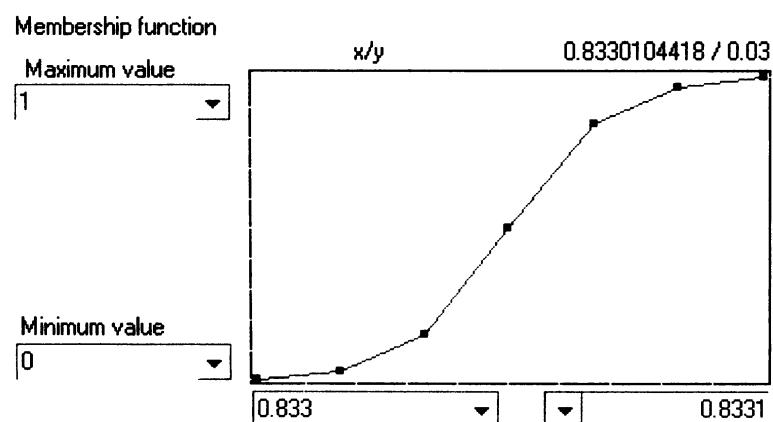
Funkce příslušnosti Mean B



Funkce příslušnosti Mean IR



Funkce příslušnosti Rectangular Fit

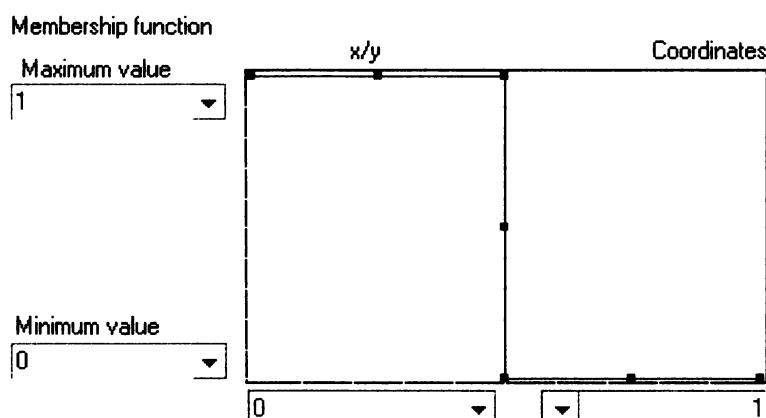


Třída „ostatní zpevněné povrchy“

Popis třídy

- • Contained
 - and (min)
 - ↳ Classified as bílé střechy
 - ↳ Classified as červené střechy
 - ↳ Classified as osvícené části střech
 - ↳ Classified as světle červené střechy
 - ↳ Classified as šedočervené střechy
 - ↳ Classified as tmavě šedé střechy
 - Inherited
 - ○ and (min) (level1)
 - ↳ Level
 - ○ and (min) (ostatní zpevněné povrchy1)
 - ↳ Classified as silnice
 - ○ and (min) (ostatní)
 - ↳ Classified as pole
 - ↳ Classified as zeleň
 - ○ and (min) (zpevněné povrchy uvnitř sídla)
 - ↳ Existence of super objects sídlo (1)
 - ○ and (min) (zpevněné povrchy)
 - *** not stín
 - *** not vodní plochy

Funkce příslušnosti Classified as bílé střechy, červené střechy, osvícené části střech, světle červené střechy, šedočervené střechy, tmavě šedé střechy



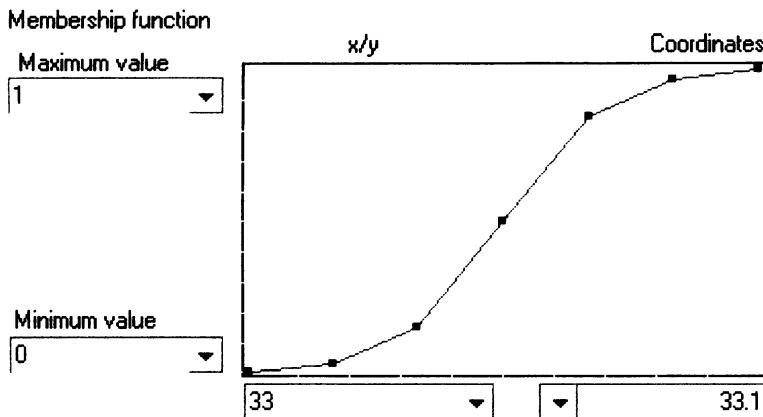
1.2 Druhá segmentační úroveň

Třída „ sídlo“

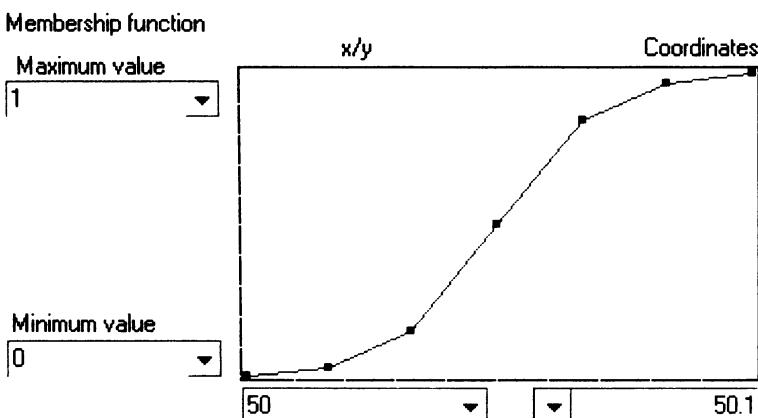
Popis třídy

- • Contained
- and (min)
 - ✓ Avg. mean diff to neighbors of sub-objects B (1)
 - ✓ Mean of sub-objects: stddev B (1)
- Inherited
 - and (min) (level2)
 - ↳ Level

Funkce příslušnosti Avrg. mean diff to neighbors of sub-objects B



Funkce příslušnosti Mean of sub-objects: stddev B



Třída „ne sídlo“

Popis třídy

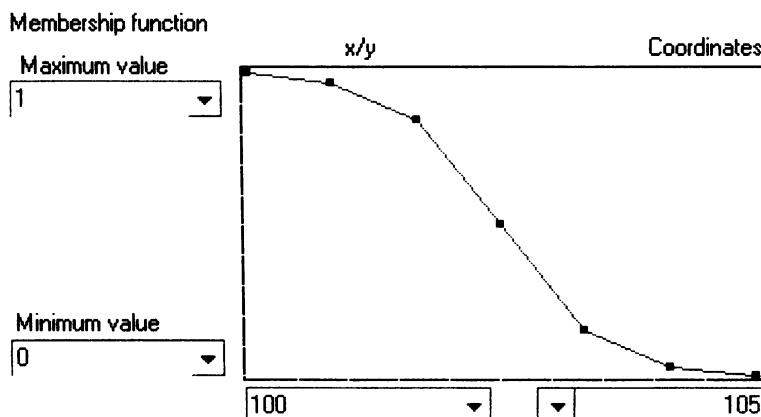
- • Contained
 - and (min)
 - ↔ not sídlo
- ↗ Inherited
 - ○ and (min) (level2)
 - △ Level

Třída „kandidát vodní plochy“

Popis třídy

- • Contained
 - and (min)
 - ↗ Mean IR
- ↗ Inherited
 - ○ and (min) (level2)
 - △ Level

Funkce příslušnosti Mean IR



2 Klasifikace s použitím relativní výšky

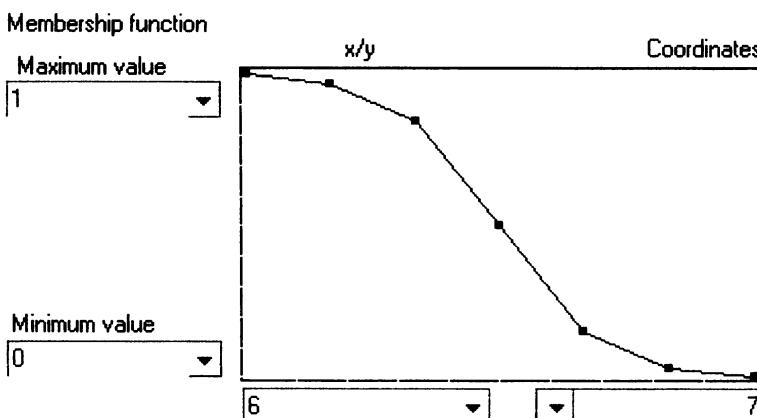
V klasifikaci s použitím relativní výšky jsou použity stejné popisy tříd, klasifikačních příznaků, prahových hodnot a funkcí příslušnosti jako v klasifikaci bez použití relativní výšky (viz příloha 1). Stejně je také nastavení všech parametrů v druhé klasifikační úrovni. Změna nastává až u třídy „budovy“ a „ostatní zpevněné povrchy“, jejichž popis je podán níže.

Třída „budovy“

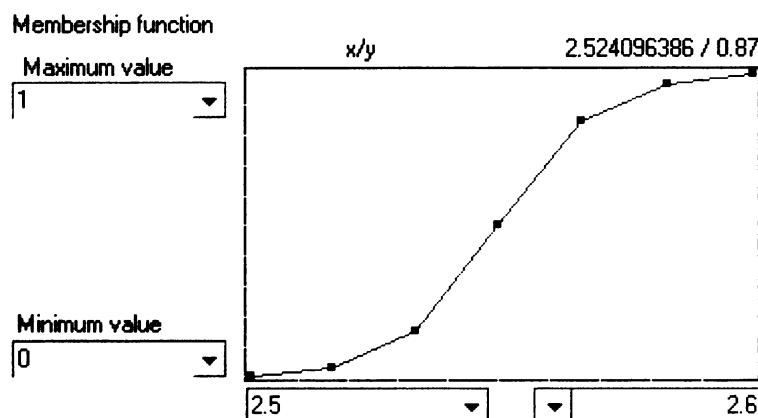
Popis třídy

- • Contained
 - and (min)
 - ↳ Length/Width
 - ↳ Mean výška
 - ↳ Inherited
 - ○ and (min) (level1)
 - ↳ Level
 - ○ and (min) (ostatní)
 - ↳ Classified as pole
 - ↳ Classified as zeleň
 - ○ and (min) (zpevněné povrchy sídlo)
 - ↳ Existence of super objects sídlo (1)
 - ○ and (min) (zpevněné povrchy)
 - ↔ not stín
 - ↔ not vodní plochy

Funkce příslušnosti Length/Width



Funkce příslušnosti Mean výška

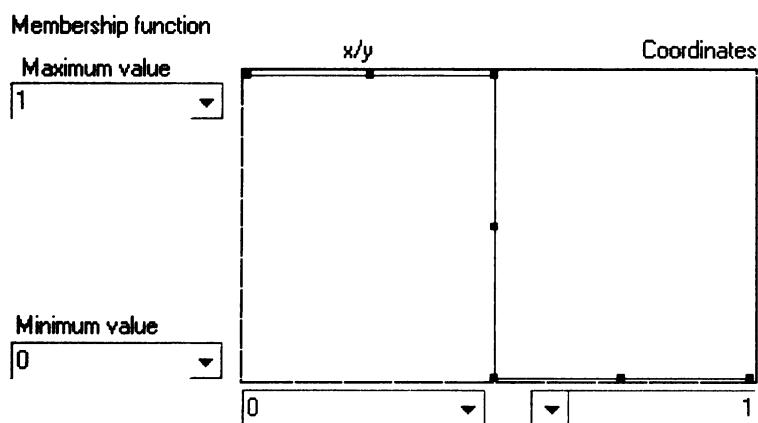


Třída „ostatní zpevněné povrchy“

Popis třídy

- • Contained
 - and (min)
 - ↳ Classified as budovy
- Inherited
 - and (min) (level1)
 - ↳ Level
 - and (min) (ostatni)
 - ↳ Classified as pole
 - ↳ Classified as zeleň
 - and (min) (zpevněné povrchy sídlo)
 - Existence of super objects sídlo (1)
 - and (min) (zpevněné povrchy)
 - ↔ not stín
 - ↔ not vodni plochy

Funkce příslušnosti Classified as budovy



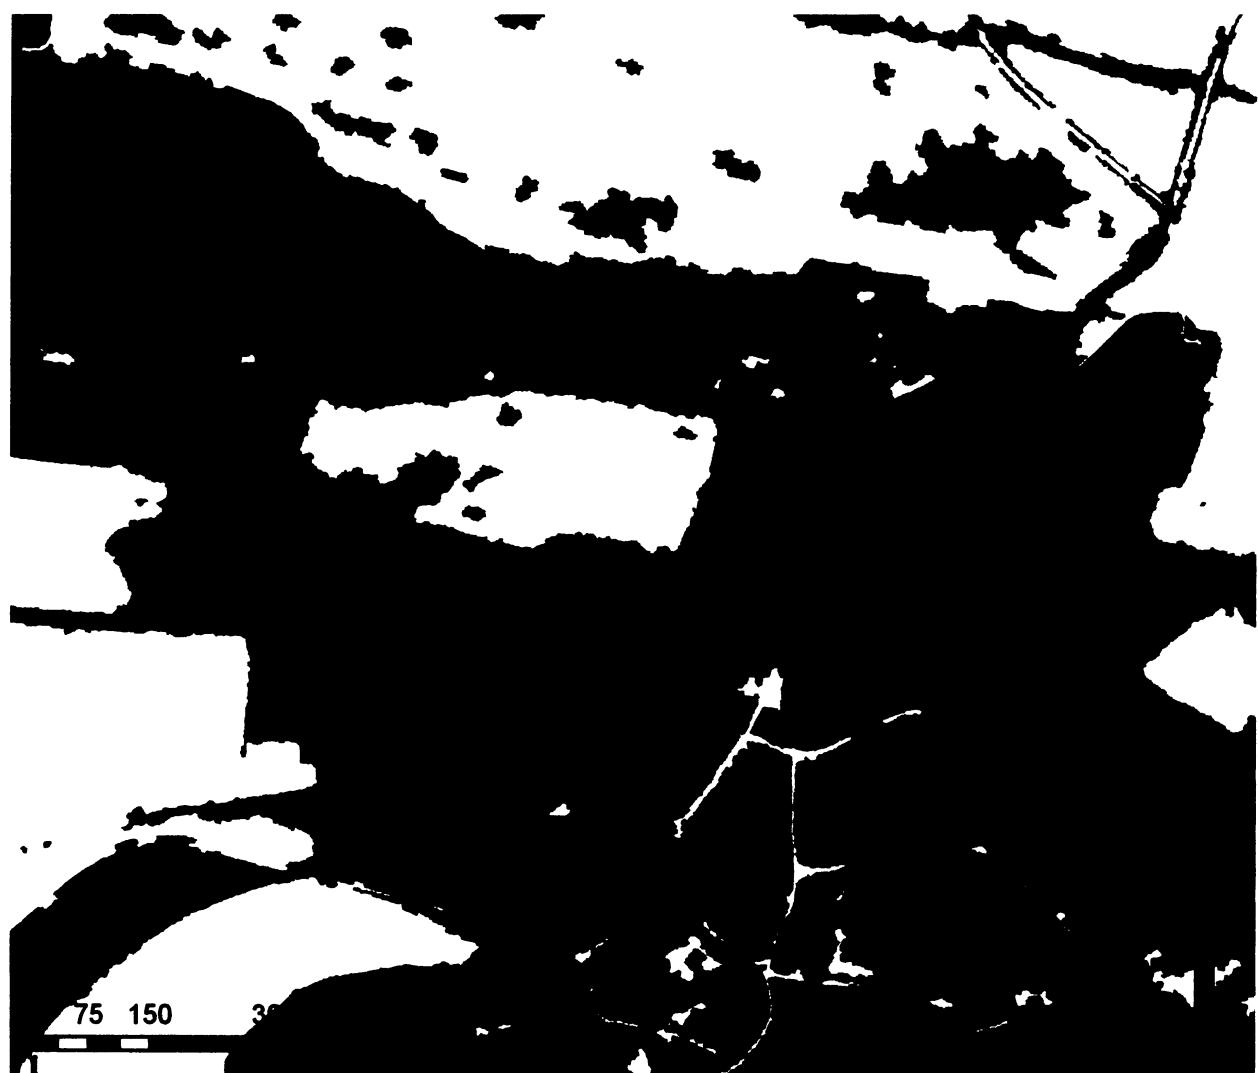
**Příloha II: Výsledek klasifikace výřezu snímku obce Lubenec
bez použití informace o relativní výšce**



Legenda

- [white square] pole
- [dark gray square] zeleň
- [black square] vodní plochy
- [black square] stín
- [black square] budovy
- [black square] ostatní zpevněné povrchy

**Příloha III: Výsledek klasifikace výřezu snímku obce Lubenec
s použitím informace o relativní výšce**



Legenda

- pole
- zeleň
- vodní plochy
- stín
- budovy
- ostatní zpevněné povrchy

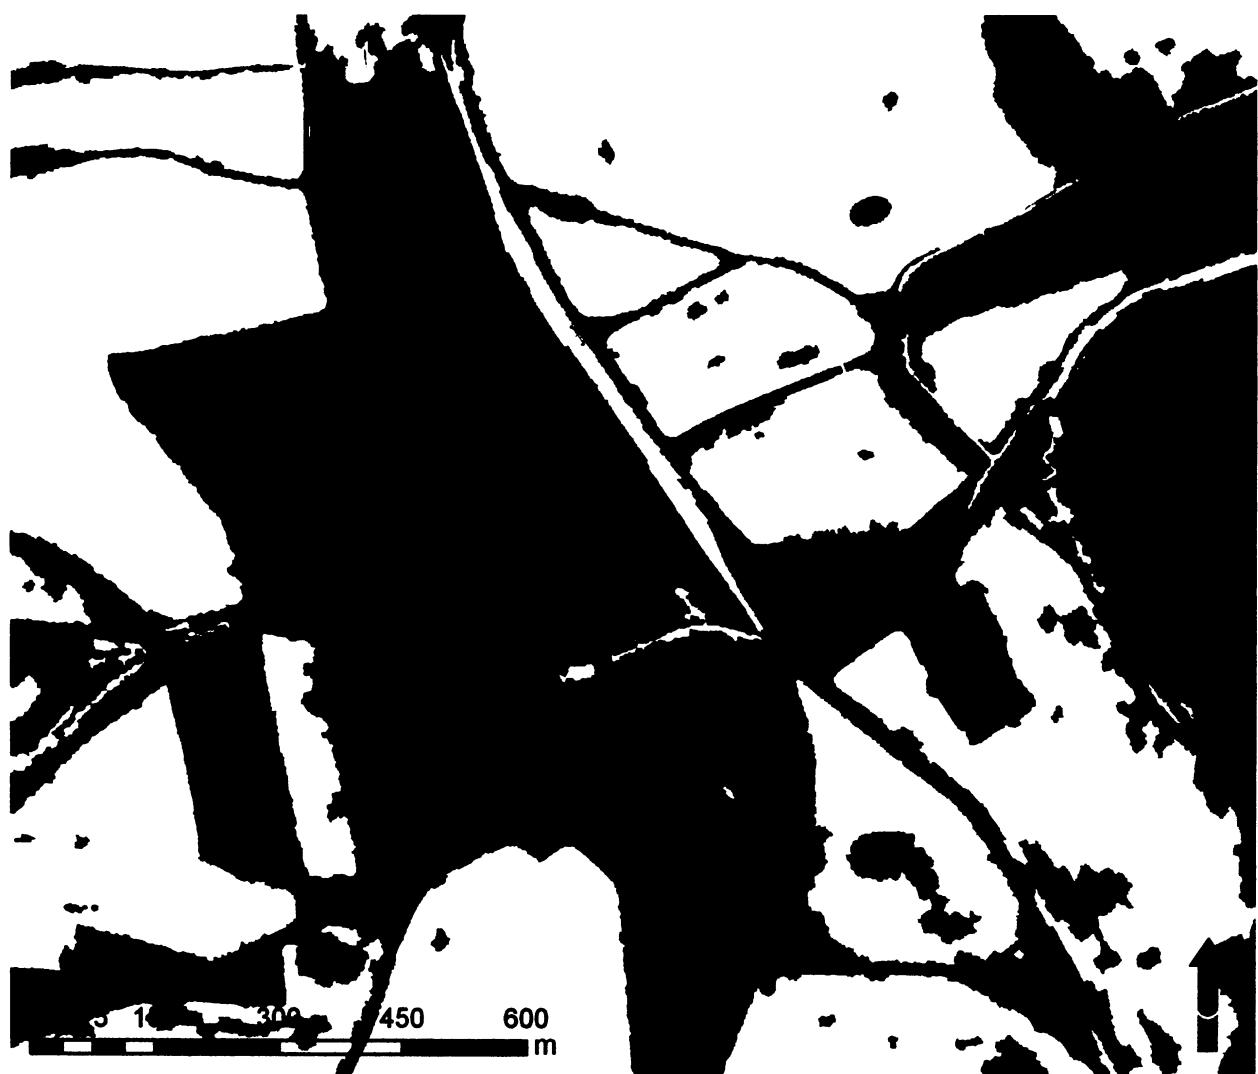
**Příloha IV: Výsledek klasifikace výřezu snímku obce Blatno
bez použití informace o relativní výšce**



Legenda

- [white square] pole
- [black square] zeleně
- [black square] vodní plochy
- [black square] stín
- [black square] budovy
- [black square] ostatní zpevněné povrchy

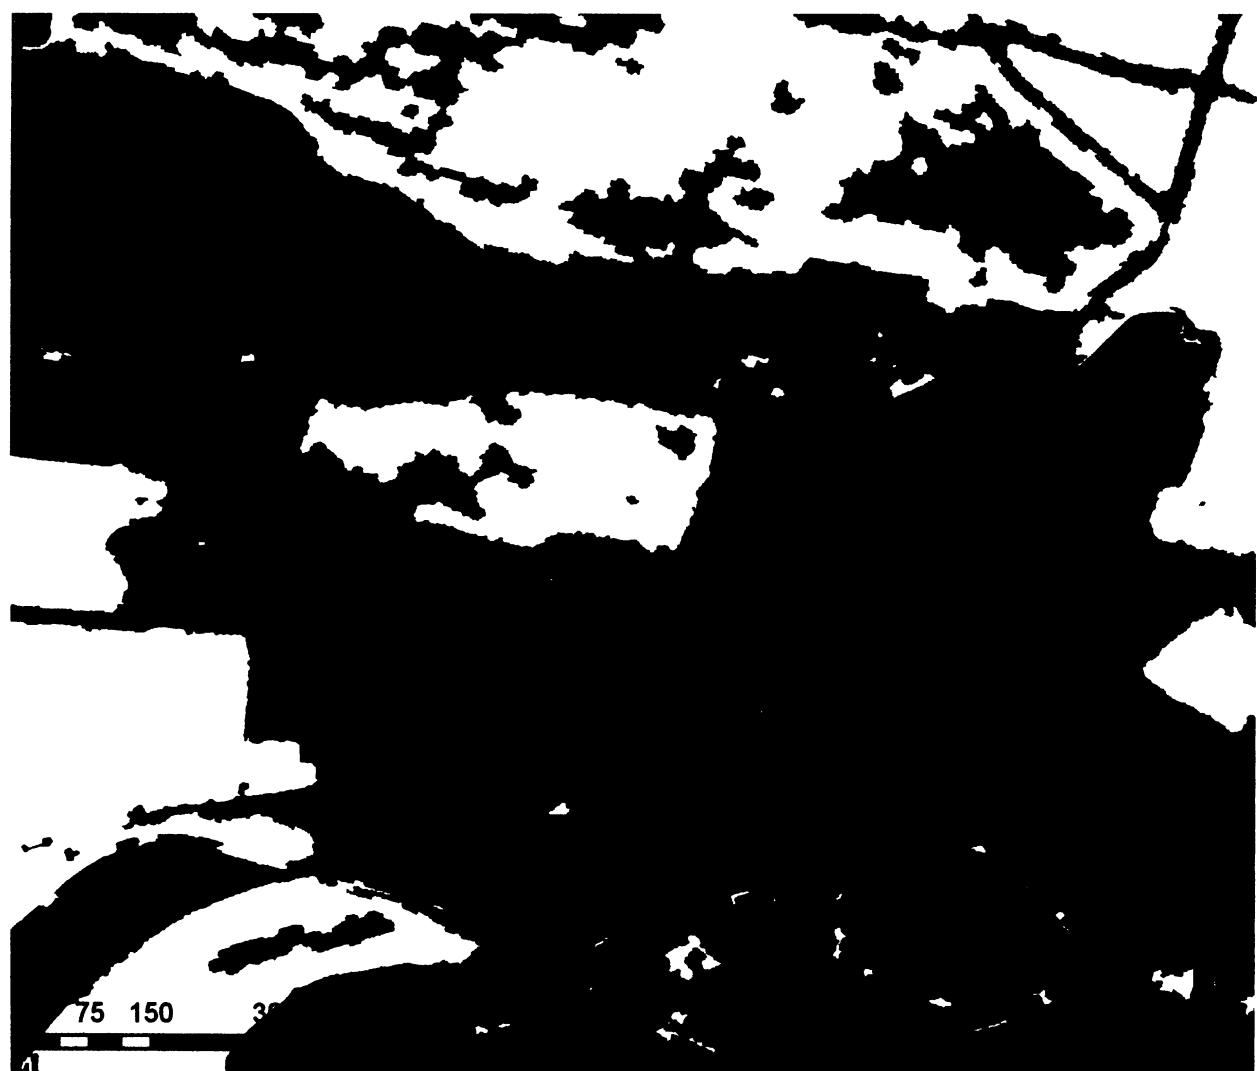
**Příloha V: Výsledek klasifikace výřezu snímku obce Blatno
s použitím informace o relativní výšce**



Legenda

- pole
- zeleň
- vodní plochy
- stín
- budovy
- ostatní zpevněné povrchy

Příloha VI: Referenční data výřezu snímku obce Lubenec



Legenda

- pole
- zeleň
- vodní plochy
- stín
- budovy
- ostatní zpevněné povrchy

Příloha VII: Referenční data výřezu snímku obce Blatno



Legenda

- pole
- zeleň
- vodní plochy
- stín
- budovy
- ostatní zpevněné povrchy