

Univerzita Karlova v Praze
Přírodovědecká fakulta
katedra aplikované geoinformatiky a kartografie



**POLOAUTOMATICKÉ URČENÍ PARAMETRŮ
KLASIFIKAČNÍHO MODELU OBJEKTOVĚ
ORIENTOVANÉ KLASIFIKACE**

Diplomová práce

Josef Goder

Vedoucí diplomové práce: Doc. Ing. Jan Kolář, CSc.

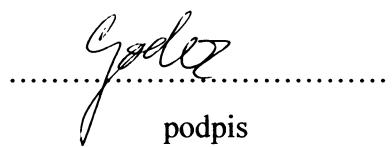
Praha 2007

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně, pod vedením školitele Doc. Ing. Jana Koláře, CSc., a že jsem všechny použité prameny řádně citoval.

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

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

V Praze dne 3.9. 2007


.....
podpis

Poděkování:

Rád bych poděkoval vedoucímu mojí diplomové práce Doc. Ing. Janu Kolářovi, CSc. za odborné vedení práce a cenné rady a připomínky. Také bych rád poděkoval Ing. Lukáši Brodskému, PhD. za četné rady a konzultace. Za ochotné poskytnutí dat a možnost využití software Definiens děkuji pracovníkům firmy GISAT. Nakonec bych rád poděkoval rodičům za trpělivost a podporu během celé doby studia a přátelům za psychickou podporu při dokončování práce.

Abstrakt

Předložená magisterská práce se zabývá využitím objektově orientované analýzy obrazu (OBIA) pro účely monitorování územního rozvoje sídel. Cílem práce je vytvoření nebo nalezení poloautomatického způsobu určování parametrů přenositelného klasifikačního modelu. V teoretické části jsou naznačeny hlavní světové urbanizační procesy současnosti a popsány funkce a zákonné povinnosti územního plánování v ČR. Dále jsou zde charakterizovány a diskutovány základní principy obrazové analýzy.

V praktické části jsou metody OBIA aplikovány v prostředí Definiens Professional na pansharpovalaná data družice IKONOS. Hlavní analýza objektových příznaků byla provedena ve statistickém software SPSS. Navržená metoda založená na analýze rozptylu příznaků tréninkových objektů umožnila výběr vhodných příznaků pro klasifikaci a určení přenositelných klasifikačních pravidel. Vytvořený způsob lze ve srovnání s tradiční manuální cestou určování parametrů klasifikačního modelu charakterizovat jako přehlednější a poloautomatický. Výsledky provedené klasifikace poukazují na problémy při detekci extrémně rozptylené zástavby. Použitý klasifikační postup je vhodný pro monitorování plošného rozvoje sídel.

Klíčová slova: *land cover, OBIA, objektové příznaky, urban sprawl, územní plánování*

Abstract

This diploma thesis deals with application of object-oriented image analysis (OBIA) for urban development monitoring. The aim of the thesis is to find semiautomatic way of determining of transferable classification rule-base. Recent world urbanisation processes and the responsibilities of Czech urban planning are described in the theoretical part. Also basic principles of image analysis are characterized and discussed in the first part of the thesis.

Pansharpened IKONOS images were analyzed in Definiens Professional during the practical part. The main analysis of object features was performed in statistic software SPSS. Proposed method based on analysis of variance (ANOVA) allowed to choose optimal object features for transferable classification rules determination and following object oriented classification. In comparison to common manual way of classification parameters determination the presented method can be described as more transparent and automatical. The results of the classification have shown problems with detection of extremely discontinuous residential areas. Though the applied hierarchical object-oriented approach is suitable for urban development monitoring.

Keywords: *land cover, OBIA, object features, urban sprawl, urban planning, spatial planning*

Obsah

SEZNAM POUŽITÝCH ZKRATEK	8
SEZNAM GRAFŮ	9
SEZNAM OBRÁZKŮ	9
SEZNAM TABULEK	9
1 ÚVOD.....	10
2 SOUČASNÁ PROBLEMATIKA SÍDEL	12
2.1 Vývoj populace a sídel.....	12
2.2 Urban sprawl a územní plánování	15
2.3 Monitorování sídel pomocí nástrojů dálkového průzkumu Země	19
3 OBJEKTOVĚ ORIENTOVANÁ ANALÝZA OBRAZU	22
3.1 Segmentace	22
3.2 Příznakový prostor a operace s příznaky	25
3.2.1 Spektrální příznaky	27
3.2.2 Texturální příznaky	29
3.2.3 Geometrické a texturální příznaky	30
3.2.4 Optimalizace příznakového prostoru	30
3.3 Objektově orientovaná klasifikace.....	32
4 DATA A ZÁJMOVÉ ÚZEMÍ.....	34
4.1 Modelové území	34
4.2 Družicová data IKONOS a charakteristika platformy	35
4.3 Pomocná data.....	37
5 METODIKA.....	38
5.1 Odborná příprava	38
5.2 Přípravné práce	40
5.2.1 Definice tříd land cover.....	40

5.2.2	Výběr testovacích území	41
5.2.3	Předzpracování dat	41
5.2.4	Pre-segmentace a výběr příznaků	43
5.3	Analýza příznaků	45
5.3.1	Normální rozložení	45
5.3.2	Analýza rozptylu (ANOVA)	46
5.4	Klasifikační strategie	48
5.4.1	Hierarchická segmentace	48
5.4.2	Fuzzy klasifikace	50
6	VÝSLEDKY	55
6.1	Zhodnocení výsledků analýzy příznaků	55
6.2	Zhodnocení tématické přesnosti klasifikace a přenositelnosti klasifikačního modelu	61
7	DISKUSE POUŽITÝCH METOD, DAT, VÝSLEDKŮ A JEJICH UPLATNĚNÍ	65
7.1	Použitá data	67
8	ZÁVĚR	69
	POUŽITÉ ZDROJE	71
	SEZNAM PŘÍLOH	80

Seznam použitých zkratek

ANOVA.....	Analýza rozptylu (Analysis of Variance)
CCA	Canonical Component Analysis
ČÚZK	Český Úřad Zeměměřický a Katastrální
DBF	dBase file
DPZ	Dálkový průzkum Země
ETM+	Enhanced Thematic Mapper
FNEA	Fractal Net Evolution Approach
GIS	Geografický Informační Systém
GLCM	Grey-Level Co-occurrence Matrix
IURS	Institut pro udržitelný rozvoj sídel
LU/LC	Land use/land cover
MF	Membership Function (funkce příslušnosti)
(e)NDGI.....	(Enhanced) Green Normalized Difference Vegetation Index
NDVI	Normalized Difference Vegetation Index
NIR	Near InfraRed
OBIA	Object-Oriented Image Analysis (Objektově orientovaná obrazová analýza)
PAN	Panchromatický kanál
PCA	Principal Component Analysis (Analýza hlavních komponent)
PVI	Perpendicular Vegetation Index
RFI	Ratio Vegetation Index
SHP	Shapefile
S-JTSK	Systém Jednotné Sítě Trigonometrické a Katastrální
(e)TCT	(enhanced) Tasseled Cap Transformation
TIFF	Tagged Image File
TM	Thematic Mapper
ÚAP	Územně analytické podklady
ÚPD	Územně plánovací dokumentace
VHR	Very High Resolution (Velmi vysoké prostorové rozlišení)
ZABAGED	Základní Báze Geografických Dat
ZPF	Zemědělský Půdní Fond
ŽP	Životní Prostředí

Seznam grafů

Graf 2.1 Městská a venkovská populace, Svět 1950 - 2030	13
Graf 5.1 Normalizovaná hustota pravděpodobnosti Gaussova rozložení- příznak <i>R/STD</i> ..	52
Graf 5.2 Normalizovaná hustota pravděpodobnosti Gaussova rozložení- příznak <i>eNDGI</i> ..	53
Graf 6.1 Hustota pravděpodobnosti normálního rozložení tréninkových objektů - - příznak <i>GLCM Homogeneity all dir. NIR</i>	56
Graf 6.2 Hustota pravděpodobnosti normálního rozložení tréninkových objektů - - příznak <i>Ratio Red</i>	57

Seznam obrázků

Obr. 3.1 Efekt parametrů <i>shape</i> a <i>scale</i> na segmentaci dat družice QuickBird	25
Obr. 3.2 Vztah mezi obrazem a příznakovým prostorem	26
Obr. 4.1 Poloha modelového území v rámci ČR	34
Obr. 4.2 Spektrální rozsah a odezva družice IKONOS	37
Obr. 5.1 Schéma pracovního postupu	39
Obr. 5.2 Klasifikační schéma	40
Obr. 5.3 Princip tvorby prvků <i>Border</i> a <i>Frame</i>	42
Obr. 5.4 Funkce hustoty pravděpodobnosti Gaussova normálního rozložení	45
Obr. 5.5 Funkce příslušnosti tvaru S	51
Obr. 5.6 Lineární funkce příslušnosti	53
Obr. 7.1 Relativní odezva WorldView-2	68

Seznam tabulek

Tab. 4.1 Přehled parametrů družice IKONOS	36
Tab. 5.1 Spektrální a texturální příznaky vybrané pro hodnocení přenositelnosti ..	44
Tab. 5.2 Segmentační parametry	49
Tab. 6.1 Vybrané příznaky tříd vodní plochy a stíny	57
Tab. 6.2 Vybrané příznaky tříd lesy, stromy, vegetace a trávníky	59
Tab. 6.3 Vybrané příznaky tříd holá půda, světlé a červené střechy a zpevněné povrchy	60
Tab. 6.4 Chybová matice klasifikace land cover – lokalita 1	62
Tab. 6.5 Chybová matice klasifikace land cover – lokalita 2	63
Tab. 6.6 Chybová matice klasifikace land cover – lokalita 3	64

Kapitola 1

Úvod

Sísla jsou již několik tisíc let významným a zároveň velmi dynamickým prvkem kulturní krajiny. Výrazné změny v jejich prostorovém uspořádání, ke kterým dochází především v posledních sto letech zásadně ovlivňují nejen prostředí uvnitř, ale i okolí. Vývoj struktury sídel a v první řadě měst probíhá různým tempem v odlišných částech světa v závislosti na jejich průmyslové vyspělosti. Usměrňování územního rozvoje se věnují instituce na různých úrovních státní správy a samosprávy. Společným postupem při tvorbě územně plánovací politiky je analýza aktuální informace o využití sledovaného území. Její sběr se velmi často provádí rozsáhlým terénním šetřením. Dílčím úkolem této práce bude hodnocení využití objektově orientované klasifikace pro plošné monitorování sídel.

Pro sledování změn v krajinném krytu (tedy i sídel) jsou dlouhodobě úspěšně aplikovány metody dálkového průzkumu Země. S běžnou dostupností družicových dat s velmi vysokým prostorovým rozlišením se rozšířilo i využití objektově orientovaného přístupu. Jako hlavní zaměření této práce bylo zvoleno téma monitorování sídel metodou objektově orientované klasifikace. Za podkladová obrazová data byla vybrána družicová scéna IKONOS. Družicová data s velmi vysokým prostorovým rozlišením jsou v zahraničních projektech poměrně často používána pro různé aplikace, včetně monitorování urbanizovaných území pro účely územního plánování. V České republice je jejich použití prozatím omezeno na několik případových studií v jiných aplikacích (Hájek, 2005; Jupová, 2007). Aplikace zaměřené na studium sídel využívají buď tradiční vizuální interpretace leteckých snímků nebo časově náročného terénního šetření (Pátíková, 2000).

V této práci použity objektově orientovaný způsob klasifikace na rozdíl od tradičních *per pixel* přístupů zařazuje do tříd celé shluky pixelů, které je možné charakterizovat vedle spektrálních také texturálními, kontextuálními a geometrickými vlastnostmi (příznaky). Rozšířený příznakový prostor s sebou přináší problém v podobě výběru vhodných příznaků pro vytvoření klasifikačního modelu. Hledání optimálních parametrů klasifikace je časově velmi náročné a vyžaduje spoustu manuálního úsilí pro

získání expertní znalosti (Schiewe et al., 2001). Jako problém nejběžnějšího softwaru Definiens je často označována neautomatizovanost a nepřehlednost hledání prahových hodnot a sestavení klasifikačních pravidel (Kopalová, 2007).

Hlavním cílem této práce je vytvoření takové metody, která umožní méně časově náročný a maximálně automatizovaný výběr objektových příznaků vhodných pro klasifikaci land cover. Klasifikace se bude podrobněji zaměřovat na vymezení a strukturu zastavěných území. Pozornost při výběru objektových příznaků bude věnována hlavně prostorové stabilitě příznaků. Přenositelnost klasifikačního modelu bude hodnocena standardními statistickými metodami.

Text této magisterské práce je strukturován podle této osnovy. Po tomto úvodu následuje teoretický rámec zaměřený na současné problémy vývoje sídel. Druhá část kapitoly je věnována řešení problematiky sídel pomocí dálkového průzkumu Země. Třetí kapitola poskytuje základní přehled o objektově orientované analýze obrazu. Následuje detailní popis praktické části a dosažených výsledků. V posledních dvou kapitolách jsou diskutovány limity dosažených výsledků a hodnoceny splněné cíle.

Kapitola 2

Současná problematika sídel

Podobně jako všechny krajinné prvky i města, resp. sídla prodělávají změny v čase. Studium vývoje sídel je předmětem výzkumu sociální geografie, demografie, ekologie, sociologie i jiných disciplín. Především geografický přístup se zabývá prostorovým uspořádáním sídel a organizací společnosti a jejich změnami v čase. Geoinformatickému pohledu je právě geografické pojetí nejbližší. I přesto, že se tato práce nezabývá hodnocením vývoje sídel jako takového, ale pouze metodikou vhodné pro pořízení aktuální a objektivní informace, je důležité pochopit principy změn a potřeby aplikací zabývajících se sídly. Cílem této kapitoly je zvýraznění nejzávažnějších a nejčastěji diskutovaných témat (problémů) v dostupné odborné literatuře. Druhá část oddílu je věnována rešerši v současnosti používaných nástrojů dálkového průzkumu Země pro sledování sídel. Smyslem celé kapitoly je také vysvětlení klíčových pojmu.

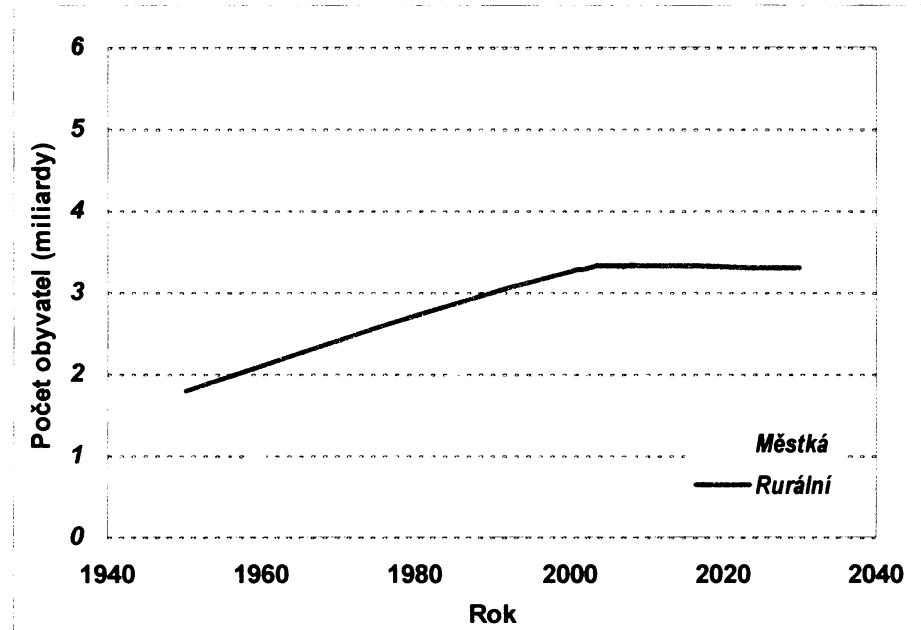
2.1 Vývoj populace a sídel

Pod pojmem sídlo si lze představit souhrně vesnice, malé obce a města. S přesnou definicí města oddělující ho od skupiny ostatních obcí se lze setkat jen zřídka. Velmi časté je však funkční rozdělení, kdy vesnice je chápána ve spojení s převažující zemědělskou činností (Kučera, 2007). Naopak město je centrem pracovních, obytných, politických, administrativních, kulturních a různých socioekonomických aktivit nebo služeb (Slepíčka, 1981). V dalším textu je pozornost někdy věnována obecně sídlům pokud je možné danou problematiku generalizovat nebo odděleně obcím a městům, pokud se charakter popisovaných jevů vyskytuje jen u jedné skupiny sídelních typů.

O významu studia měst svědčí rostoucí míra koncentrace většiny světové populace (viz graf 2.1). Na začátku 19. století žilo pouze 10 procent světové populace v městských oblastech. V roce 1950 podíl vzrostl na 30 procent a dnes je to 45 procent. Kolem roku 2020 se očekává, že tři pětiny obyvatel naší planety budou žít ve městech (Population Reference Bureau, 2006; United Nations, 2006).

S měnícím se rozmístěním obyvatel dochází i ke změnám v uspořádání a využití prostoru uvnitř sídel. Moderní města procházejí urbanizačními fázemi, které jsou charakterizovány odlišnými změnami vnitřní struktury (van den Berg et al., 1982). Pohyby v jednotlivých etapách jsou převážně motivovány ekonomickými a sociálními činiteli (Clark, 1996).

Graf. 2.1 Městská a venkovská populace, Svět 1950 – 2030



Zdroj: Population Reference Bureau (2006)

Jako obecný vývojový model měst je v současné době přijímána teorie stádií vývoje měst (Ouředníček, 2007). Van den Berg et al. (1982) uvádí čtyři vývojová stádia, která jsou charakterizována různými směry pohybu obyvatel. První vývojovou fází je proces *urbanizace*. V dostupných zdrojích existuje spousta definic. Šimon (2006) uvádí definici podle Johnstona et al. (2000): „*Urbanizace představuje proces, kdy dochází k relativní koncentraci obyvatelstva (a tím i jeho aktivit) v území do měst*“. Musil (2005) chápe urbanizaci jako komplexní proces úzce provázaných morfologických, kulturních, sociálních, politických a behaviourálních změn. V podstatě jde o stěhování obyvatel z venkovských oblastí do center města přejímání městského způsobu života. Urbanizace je úzce spojena s industrializací a proběhla ve všech rozvinutých zemích v minulém století. V současné době lze nejmasivnější projevy

urbanizace zaznamenat v rozvojových a méně rozvinutých zemích Afriky a Asie (United Nations, 2006; Clark, 1996).

Při urbanizaci dochází k absolutně největšímu růstu center. V přelidněných a po technické stránce nepřipravených centrech měst však následně může docházet ke zhoršování kvality životních podmínek obyvatelstva a začíná docházet k opačnému pohybu přesunu směrem k okraji měst. Populační rozvoj vnějšího okruhu dominuje. Tento proces je nazýván *suburbanizace*. Město prostorově expanduje do okolí, ale i do vzdálenějších míst a zabírá nové přilehlé pozemky. Rozlišují se dvě formy suburbanizace, rezidenční a komerční. První znamená osídlení periferních oblastí města, realizované výstavbou rodinných domů a nízkopodlažní zástavbou. Komerční suburbanizace zahrnuje vznik nových obchodních, výrobních, skladovacích a logistických aktivit. Výsledkem je přesun průmyslových aktivit do méně závadných míst a vznik příjemnějších lokalit k bydlení. Buduje se nová dopravní infrastruktura a zlepšuje dostupnost zázemí do centra. Současně se také zvyšuje pracovní mobilita a individuální dojížďka do zaměstnání do center měst Ouředníček (2007). Reakcí na neúnosné dopravní zatížení center a tlakem terciérního sektoru na obytné funkce je vznik nových obchodních a kancelářských objektů na úkor ubytka populace v jádrovém regionu, tzv. *desurbanizace* (Ouředníček, 2007). Roste počet obyvatel malých center za hranicemi města. Územní plánování (2005) charakterizuje desurbanizaci jako úpadek měst v důsledku restrukturalizace společnosti, suburbanizace, vznik ghett a opuštěných území („*brownfields*“). Poměrně vyčerpávající charakteristiku *brownfields* poskytuje IURS (2007): „*Brownfields jsou pozemky a budovy v urbanizovaném území, které ztratily svoje původní využití nebo jsou málo využité. Často mají - nebo se předpokládá, že mají - ekologické poškození a zdevastované výrobní i jiné budovy. Z mnoha důvodů brownfields představují rozsáhlou část zastavěného území v mnoha českých městech (od 3-20% jejich zastavěného území). Mají nejen negativní ekonomické účinky, ale také neblahý fyzický vliv na své širší okolí. Složitost jejich řešení, nejistoty, zvýšená rizika a náklady spojené s jejich renovací a znovuvyužitím - to vše odrazuje soukromý kapitál od aktivní ekonomicke intervence. Brownfields pak obvykle vyžadují různé formy veřejné intervence k tomu, aby se odbouraly bariéry bránící jejich rozvoji a nastartoval se tak proces jejich nového využití. Je nutné si ale uvědomit, že budou i brownfields, která z různých důvodů dlouhodobě své nové využití vůbec nenajdou.*“ Důležitým postřehem je nutnost řešit problémy *brownfieldu* co nejdříve. S plynoucím časem se jejich

revitalizace stává ekonomicky náročnější a investice směřující do výstavby nových budov směřují především do oblastí rozvoje na zelené louce („*greenfields*“). Prioritou územního plánování by měla být snaha o oživení brownfields na místo zabírání často kvalitních zemědělských a přírodních ploch.

Čtvrtým vývojovým stádiem, které proběhlo v některých západoevropských městech (van den Berg et al., 1982) je reurbanizace. V této fázi lze zanaměnit snahu o aplikaci principů trvale udržitelného rozvoje, o zlepšení podmínek v „opuštěných“ centrech, o zvyšování atraktivity města a o znovuoživení center velkých měst. Reurbanizace představuje zvýšení kvality bydlení, protože se k sobě přiblíží to, co je na sobě navzájem závislé (bydlení, obchod, služby, práce, kultura, rekreace). Reurbanizace představuje rozumnější využití území, hranice současných měst zůstávají zachovány, Rozvoj je směřován dovnitř měst modernizací, přestavbami a zhušťováním objektů. Ochrana kvalitních parkových, rekreačních a přírodních ploch uvnitř měst je samozřejmostí. (Územní plánování, 2005).

2.2 Urban sprawl a územní plánování

Nejčastěji v amerických zdrojích se můžeme setkat s detailními studiemi analyzujícími tamní fenomén posledních několika desítek let, tzv. *urban sprawl*. V posledních letech se tento jev přesunul i do Evropy a představuje potenciální nebezpečí i pro Českou republiku (Jackson, 2002).

Územní plánování (2005) charakterizuje urban sprawl jako neřízený a živelný rozvoj území. Podle The Sierra Club (2001) je urban sprawl nezodpovědný, často špatně plánovaný rozvoj, který zabírá zelené prostory („*greenfields*“), zvyšuje dopravní zátěž a znečištění ovzduší a zvyšuje daně. Také je nazýván rozptylováním městských sídel v rurální krajině (Harvey & Clark, 1971) nebo nespojitý rozvoj (Weitz & Moore, 1998). Sprawl však není považován jen za nárůst plochy urbanizovaného území. USEPA (2001) ho vnímá v časoprostorovém kontextu. Sprawl se tak vyskytuje pouze tehdy, kdy je rychlosť přeměny půdy na půdu s nezemědělským nebo nepřírodním využitím rychlejší než růst počtu obyvatel. Z uvedených definic je patrné, že urban sprawl je převážně chápán jako negativní projev suburbanizace. Přesto je nutné podotknout, že je velmi těžké určit kdy se jedná o pozitivní územní rozvoj a kdy o negativní urban sprawl (Jackson, 2003).

Efekt urban sprawlu je patrný především v zázemí velkých měst. V ČR lze zaznamenat několik příkladů, například v okolí Prahy. Obecným rysem urban sprawlu je nárůst zastavěných jednoúčelových ploch mimo jádrová území měst. Může se jednat jak o čistě obytné areály tak o centra komerčních aktivit. Společným rysem je výstavba na zelené louce bez návaznosti na jakoukoliv stávající infrastrukturu. Vysoké investice do nové vybavenosti jsou v konečném výsledku velmi neefektivní. Nízká hustota osídlení nových ploch znamená mnohem větší náklady na jednoho obyvatele než je průměr celého města (Územní plánování, 2005). I přesto je výstavba na zelené louce levnější než revitalizace brownfields uvnitř měst (Jackson, 2003). Dalšími důvody jsou trendy v oblasti bydlení. Spousta rodin si přeje bydlet v zelenějším a zdravějším prostředí. Následkem tohoto procesu jsou zvýšené náklady na energii, materiály, na dopravní obslužnost, na infrastrukturu v nových zastavěných územích. Zatímco finance plynou do nově rozvíjených oblastí, v centrech se nedostává kapitálu na obnovu starých opuštěných průmyslových areálů a opravu podvyužité infrastruktury. Vznikají zde brownfields. Zmíněné rysy lze souhrně zařadit do kategorie socioekonomických důsledků. Neméně důležitou roli však hrají i dopady na životní prostředí a přírodní zdroje. Jako hlavní dopady na životní prostředí lze zmínit kvalitu vody, ovzduší nebo omezení životního prostoru divoké zvěře. Úbytek plochy zemědělské půdy, lesů jako plochy pro produkci dřeva a ovlivňování vodních toků znamenají vesměs negativní manipulaci s obnovitelnými přírodními zdroji (Barnes et al., 2001).

Kvalita života a prostředí je odrazem ekonomické stability a projevem udržitelného rozvoje, který je nutný pro neustálý růst životní úrovně. Takový rozvoj lze považovat za žádoucí. K úspěšnému řízení rozvoje území je nezbytné stanovení priorit pro budoucí směřování. V ČR existuje několik institucionálních nástrojů pro usměrnění vývoje sídel. Jackson (2002) je rozděluje do tří skupin z hlediska pozice řídících orgánů. Nejvyšší, role státu je spatřována především v jasné deklaraci přístupu k ochraně nezastavěných území a principu udržitelného rozvoje. Vhodný legislativní rámec by měl zajistit dodržování stanovených zásad na nižších úrovních. V pravomoci státu, prostřednictvím ministerstev jsou strategické, průmyslové, komerční a dopravní projekty nadregionálního významu. Velmi významnou roli hraje v úrovni regionu krajský úřad. Krajský úřad je podle stavebního zákona č. 183/2006 Sb. (dále jen stavebního zákona) zodpovědný za územní rozvoj. Kraj má pro usměrnění urban sprawlu k dispozici tři implementační dokumenty: strategický plán, rozvojový plán a

územní plán. Kraj sice nemůže výrazně zasahovat do růstu místních sídel, ale vytvořením zásad územního rozvoje získává celou řadu protisprálových nástrojů. Hierarchicky nejnižší úroveň reprezentují obce. Územní plán (ÚP) obce respektuje majetkové poměry a je patrné úsilí o nalezení ploch vhodných pro přilákání investic do svého území. Často dochází k soutěžení jednotlivých obcí a nabízení pozemků (Územní plánování, 2005).

Územním plánováním se zabývá část třetí Územní plánování stavebního zákona, který je v platnosti od 1.ledna 2007. § 18 odst. 1 a 2 definují hlavní cíle územního plánování: „*Cílem územního plánování je vytvářet předpoklady pro výstavbu a pro udržitelný rozvoj území, spočívající ve vyváženém vztahu podmínek pro příznivé životní prostředí, pro hospodářský rozvoj a pro soudržnost společenství obyvatel území, a který uspokojuje potřeby současné generace, aniž by ohrožoval podmínky života generací budoucích. Územní plánování zajišťuje předpoklady pro udržitelný rozvoj území soustavným a komplexním řešením účelného využití a prostorového uspořádání území s cílem dosažení obecně prospěšného souladu veřejných a soukromých zájmů na rozvoji území. Za tímto účelem sleduje společenský a hospodářský potenciál rozvoje.*“ Orgány územního plánování dále koordinují změny v území a chrání krajinu jakožto významnou složku životního prostředí člověka. Mezi úkoly územního plánování patří zjištění a posouzení stavu a využití území. Určování koncepce rozvoje území s ohledem na veřejný zájem a životní prostředí. Dalšími úkoly jsou podle stavebního zákona stanovování urbanistických, architektonických a estetických požadavků na využívání a prostorové uspořádání území a stanovování a vytváření podmínek pro provádění změn v území v záležitostech hospodářských, ekologických (asanační, rekultivační zásahy, ochrana přírodních zdrojů) a kvality bydlení. Mezi poslání územního plánování patří i analýza a vyhodnocení územně plánovací politiky. Pořizovatelem územního plánu (ÚP) je zpravidla kraj nebo obec.

Součástí územního plánu je podle § 59 stavebního zákona i vymezení zastavěného území. § 58 odstavec 2 definuje zastavěné území: „*Do zastavěného území se zahrnují pozemky v intravilánu, s vyjímkou vinic, chmelnic, pozemků zemědělské půdy určených pro zajišťování speciální zemědělské výroby (zahradnictví) nebo pozemků přiléhajících k hranici intravilánu navrácených do orné půdy nebo do lesních pozemků, a dále pozemky vně intravilánu, a to*



-
- a) zastavěné stavební pozemky,
 - b) stavební proluky,
 - c) pozemní komunikace nebo jejich části, ze kterých jsou vjezdy na ostatní pozemky zastavěného území,
 - d) ostatní veřejná prostranství
 - e) další pozemky, které jsou obklopeny ostatními pozemky zastavěného území, s vyjímkou pozemků vinic, chmelnic a zahradnictví.”

Význam územního plánování spočívá v souboru nástrojů využitelných ke směrování územního rozvoje. První fází tvorby nového územního plánu je souhrn dosavadních informací týkajících se sledovaného území. Jedná se o již obcí zpracované projekty, sousední či nadřazené územně plánovací dokumentace (ÚPD), informace od správců sítí technické infrastruktury, informace o ŽP, ze sčítání lidu a jiné. Pro stanovení územně plánovací politiky a jako podklad pro vyhotovení ÚPD slouží územně plánovací podklady. Jejich součástí jsou územně analytické podklady (ÚAP) a územní studie. Podle paragrafu 26 stavebního zákona ÚAP zjišťují a vyhodnocují stav a vývoj území a obsahují zjištění o omezeních vyplývajících z právních předpisů a určení problémů k řešení v územně plánovací dokumentaci. ÚAP jsou pořizovány na základě terénního průzkumu a na základě údajů o území (stav, práva, povinnosti a omezení vztahujících se k ploše či parcele. Platnost ÚP je zpravidla v delším časovém horizontu, např. 10 let. Na rozdíl od ÚP musí být ÚAP podle paragrafu 28 stavebního zákona kompletně aktualizovány pomocí průzkumu každé dva roky. Druhým podkladovým dokumentem je územní studie. Podle stavebního zákona, s. 2237: „*územní studie navrhuje, prověřuje a posuzuje možná řešení vybraných problémů, případně úprav nebo rozvoj některých funkčních systémů v území, například veřejné infrastruktury, územního systému ekologické stability.*“

Z výše uvedených souvislostí vyplývá, že změny v prostředí sídel nejsou jen socioekonomické povahy, ale lze je popsat i jako prostorový jev. Zřejmě jsou i důvody pro jejich plošné sledování. Snaha o předcházení negativním změnám a dopadům na kvalitu životního prostředí si vyžadují racionální politiku územního plánování. Z těchto

důvodů, ale i ze zákonné povinnosti pravidelné aktualizace územně analytických podkladů se jeví jako praktická metoda monitorování sídel dálkový průzkum Země.

2.3 Monitorování sídel pomocí nástrojů dálkového průzkumu Země

Jedním z hlavních úkolů dálkového průzkumu Země je získávání informace o land cover a land use. Pojem land cover se vztahuje k materiálu vyskytujícímu se na zemském povrchu. Typickým příkladem je voda nebo holá půda. Naproti tomu land use vyjadřuje způsob funkčního využití plochy a je spojen s různými aktivitami (např. orná půda, obytné plochy). Obytná plocha nebo park jsou typickými kategoriemi land use, které jsou vyžadovány aplikacemi jako je územní plánování (Bauer & Steinhöcher, 2001). Aplikací vyžadující tématickou informaci o land coveru je např. mapování nepropustných povrchů (De Kok, 2003; Barnes, 2000; Yuan & Bauer, 2006).

Největším problémem mapování sídel z družicových dat bylo donedávna prostorové rozlišení. Hojně využívaná jsou velmi dobře dostupná data s vysokým prostorovým rozlišením družic Landsat, Spot či IRS s velikostí pixelu 10 až 30 metrů. Přítomnost více spektrálních pásem dovoluje určení základních typů LC/LU. Tato data jsou však nevhodná pro detailnější mapování a pro detekci změn vnitřní urbánní struktury města, která je heterogenní z hlediska spektrálního chování, a značná část obrazových elementů představuje "smíšené" povrchy, které snižují přesnost výsledné klasifikace (Sedlák, 2004; Matuška & Petrová, 2001; Donnay et al., 2001; Blaschke & Strobl, 2001).

Velká pozornost je v současnosti věnována klasifikaci zastavěných území s využitím snímků velmi vysokého rozlišení (Lizarazo, 2006; Bauer & Steinhöcher, 2001; Chunfang, Kai, Chonlong, 2006; Gu, Chen, & Zhou, 2005 aj.). Lepší prostorové rozlišení vede obecně k většímu detailu klasifikace, ale pokud je pixel menší než sledované objekty může zvýšená spektrální variabilita uvnitř tříd vést ke snížení přesnosti tradičních per-pixel metod (Tuominen & Pekkarinen, 2005; Addink et al., 2006). Ve snaze o vylepšení přesnosti klasifikace je možné zaznamenat časté využití textury jako jedné z klasifikačních vrstev (Halounová, 2002; Puissant, Hirsch & Weber, 2005; Zhang, 2001; Narasimha Rao et al., 2002).

Vedle družicových dat jsou k získávání detailní informace o objektech v zástavbě používána i letecká data. Až donedávna byla hlavní metodou jejich vyhodnocení vizuální interpretace (Dobrovolný & Goláň, 2000; Pátíková, 2000). Pohled zkušeného operátora umožňuje vymezení nebo zařazení skutečných objektů podle několika kritérií (Kerle et al., 2004):

- barva (odstín)
- tvar
- velikost
- struktura
- textura
- poloha
- kontext (asociativita).

Operátor tak nevyhodnocuje jednotlivé pixely, ale celé skutečné objekty a bere v úvahu i vzájemné vztahy jednotlivých objektů. Tomuto pojetí je velmi blízká objektově orientovaná klasifikace. Objektově orientovaný přístup je založen na segmentaci obrazu na homogenní segmenty, které jsou následně s využitím spektrálních, kontextuálních nebo texturálních příznaků zařazovány do tříd. Objektová klasifikace dosahuje nejlepších výsledků ve srovnání s konvenčními metodami při klasifikaci dat s velmi vysokým prostorovým rozlišením (Mori et al., 2004).

Hlavně v počátcích objektově orientované klasifikace bylo velmi frekventované téma porovnání konvenčních per-pixel metod s novým objektově orientovaným přístupem. Na nedostatečnost tradičních per-pixel metod upozornili Blaschke & Strobl (2001). Výsledky porovnání tří klasifikačních metod pro účely sledování sídel prezentují Kamagata et al. (2005). Na datech IKONOS byly konfrontovány metoda řízené klasifikace maximum likelihood, neřízené klasifikace ISODATA a objektově orientovaná klasifikace metodu nejbližšího souseda. Závěrem konstatují problémy *per-pixel* metod způsobené vnitřní heterogenitou jednotlivých objektů. Podobné výsledky prezentují Whiteside & Ahmad (2005) při obecné klasifikaci land cover nebo Oruc et al. (2004).

Tématu vhodného rozlišení pro mapování zastavěných území se věnují v závěrech svých prací Kressler, Kim, Steinhöcher (2003) a Gu, Chen, Zhou (2005).

Jako optimální pro studium sídel shodně označují data s prostorovým rozlišením pod 5 metrů. Potenciálum VHR dat pro topografické mapování, především urbanizovaných ploch se věnovali už Ridley et al. (1997). Budoucí aplikaci VHR radarových dat se zabývají Esch, Roth, Dech (2005). Ve své práci využívají experimentálních radarových snímků k detekci zastavěných území.

Kombinace různých metod dálkového průzkumu a typů dat prokázala svoji užitečnost pro monitorování sídel v mnoha případech. Jednou skupinou mohou být projekty zaměřené na obecné mapování LC/LU v jejichž rámci jsou určovány hranice zastavěných území (Kressler, Kim, Steinhocher, 2005; Esch, Roth, Dech, 2005; Gu, Chen, Zhou, 2005; Herold et al., 2002; Hofmann et al., 2001). Účelem takových prací je zejména sledování změn v krajině, příp. mapování hranice rozvoje zástavby. Druhá část výzkumů se zabývá detailní strukturou LC/LU sídel (De Kok et. al, 2003; Lizarazo, 2006; Yuan & Bauer, 2006; Taubenböck et al., 2006) nebo extrakcí jednotlivých prvků prvků v zástavbě, např. městské zeleně (Zhang, 2001). Mapování struktury LC/LC v okrajových částech měst je důležitým nástrojem při monitorování urban sprawlu (Barnes et al., 2001).

Kapitola 3

Objektově orientovaná analýza obrazu

Objektově orientovaná analýza obrazu („*object image analysis – OBIA*“) je někdy definována jako dílčí disciplína oboru geografických informačních systémů (GIS) věnující se rozdělení obrazového prostoru na smysluplné objekty a hodnocení jejich vlastností v prostorovém, spektrálním a temporálním měřítku (Hay, Castilla, 2006). Smysluplné objekty a jejich vzájemné relace pak obsahují důležitou sémantickou informaci, nutnou k správné interpretaci obrazu (Baatz, Schäpe, 2000). Na rozdíl od tradičních *per pixel* přístupů se interpretace jednotlivých objektů a jejich vztahů mnohem více podobá pohledu operátora. Při tvorbě pravidel klasifikačního modelu lze využít stejných interpretačních znaků objektů jako při vizuální interpretaci snímku: barva, tvar, velikost, struktura, poloha, textura a kontextuální souvislost (Kerle et al., 2004).

Základním krokem *OBIA* předcházejícím objektové klasifikaci je obrazová segmentace. V následující podkapitole jsou stručně shrnutý princip a nejčastěji používané segmentační algoritmy.

3.1 Segmentace

Vytvoření objektů je primární podmínkou pro provedení objektově orientované analýzy. Obrazové segmenty jsou shluky sousedních pixelů vytvořené na základě splnění určeného kritéria homogenity. Termín homogenita je dále používán jako ekvivalent výrazu minimální heterogenita. Význam obrazových objektů spočívá v možnosti přiřazení sémantického významu reálných objektů nebo jejich částí celému shluku pixelů. Výhodou segmentovaného obrazu je také redukce velikosti klasifikovaných dat dosahujících u VHR snímků až řádů GB (Baatz, Shäpe, 2000).

Schiewe (2002) a Van der Sande (2003) rozlišují tři obecné kategorie segmentačních metod:

- založené na detekci hran („edge-based“)

-
- založené na detekci regionů („region-based“)
 - s využitím prahování („point-based“)

Detailnější popis segmentačních technik podává ve své magisterské práci Kopalová (2007). Při klasifikaci VHR dat doznávají většího využití metody založené na detekci regionů. Principem je rozdelení celého obrazového prostoru do homogenních regionů. Tvorba regionů může probíhat dvěma způsoby. Přístup zdola-nahoru („bottom-up“) začíná základním pixelem („seed pixel“) a postupně shluk pixelů roste dokud nepřekročí stanovené kritérium homogeneity. Druhý přístup shora-dolů („top-down“) je založen na dělení celé scény na homogenní regiony. Zmíněné techniky jsou často označovány jako „region-growing“, resp. „region splitting“. Někdy je udávána i metoda „split and merge“ kombinující růst a dělení regionů (Kopalová, 2007).

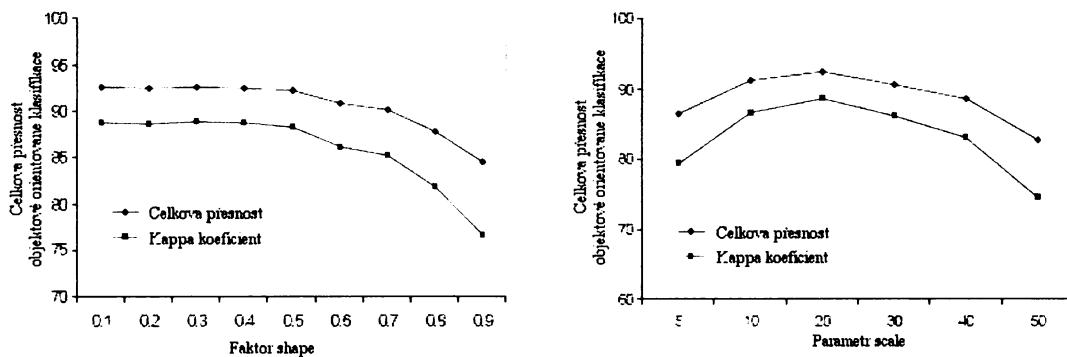
Kvalitativním porovnáním různých segmentačních algoritmů implementovaných v sedmi dostupných softwarech se zabývají Meinel & Neubert (2004). Srovnání byly podrobeny jak komerční tak volně dostupné programy využívající různé segmentační algoritmy. Hodnocení kvality segmentace bylo provedeno dvěma metodami, vizuální kontrolou a konfrontací geometrických charakteristik segmentů s referenčními objekty. Jak autoři konstatují výsledky srovnání jsou vzhledem k původu segmentačních modulů značně nevyrovnané. Nejlepších výsledků dosáhly komerční řešení InfoPack a eCognition využívající metodu „region-growing“. Výsledky ostatních metod byly shledány jako nevhodující. V současnosti existují další programy pro zpracování obrazu umožňující rozdelení obrazového prostoru na homogenní regiony. Příkladem může být software HALCON nebo čistě segmentační nástroj ITK („*Insight Segmentation & Registration Toolkit*“) disponující několika algoritmy.

Objektová analýza v této práci je prováděna v současnosti nejdostupnějším programu Definiens Professional 5 (dříve eCognition). Hlavní segmentační metodou implementovanou v software Definiens je multiúrovňová segmentace („*multiresolution segmentation*“). Použitý algoritmus FNEA („*Fractal Net Evolution Approach*“) je typu *bottom-up*. Proces začíná jedním *seed pixel*, který je vždy v levém dolním rohu snímku. Následnými iterativními kroky jsou malé shluky pixelu slučovány, dokud platí předem nastavené parametry. Proces končí tehdy, kdy by nejmenší růst regionu překročil prahovou hodnotu vyjádřenou parametrem „*scale*“ (Benz et al., 2004).

Segmentace v Definiens je závislá na několika nastaveních. První z nich je velikost objektů („*scale*“). Tento parametr určuje maximální změnu heterogeneity, která může nastat při sloučení dvou sousedních regionů. Změna heterogeneity je určena dvěma kritérii, barvou („*color*“) a tvarom („*shape*“). Oba parametry jsou vzájemně vyváženy do 1. Tzn., že hodnota tvaru je přímo určena barvou. *Color* vyjadřuje změnu ve spektrální heterogenitě a je určen jako změna standardních odchylek spektrálních hodnot objektů během sloučení. *Shape* znamená změnu tvaru po sloučení regionů a je dále popsán dvěma složkami, mírou kompaktnosti („*Compactness*“) a mírou vyhlazenosti („*Smoothness*“). *Compactness* je založena na poměru délky hranice objektu a počtu pixelů, zatímco *smoothness* na poměru obvodu objektu a obvodu pravoúhelníku o délce a šířce objektu (Definiens AG, 2006b).

Problém nastavení segmentačních parametrů řeší každý projekt zabývající se objektovou analýzou. Přímo testováním segmentací dat družice IKONOS, resp. QuickBird se ve svých pracech zabývají například Jupová (2007) nebo Yuan & Bauer (2006). Yuan & Bauer (2006) při mapování zpevněných povrchů testovali efekt parametrů *scale* a *shape* na přesnost určení pěti LU/LC tříd a na celkovou přesnost klasifikace. Vliv parametrů na celkovou přesnost dokumentuje obrázek 3.1. Jupová (2007) se nastavení segmentace věnovala při detekci prvků rozptýlené zeleně. Na rozdíl od Yuan & Bauer (2006) však testovala pouze čtyři hodnoty *scale* parametru a čtyři hodnoty faktoru *shape*. Navíc však sleduje podíl kompaktnosti na výsledku segmentace. V závěrech se shodují na tvrzení, že hlavní podíl na výsledku segmentace mají parametry *scale* a *shape*. Výhodou *multiresolution segmentation* je možnost vytvoření hierarchické struktury segmentů, která by měla odpovídat struktuře reálných objektů. Sídla jsou takovým prostředím, kde se vyskytuje množství objektů různých velikostí, od malých domů až po velké tvary průmyslových ploch nebo prostor městské zeleně. Využití více úrovní objektů je zde proto na místě (Taubenböck, et al., 2006). Např. van der Sande et al. (2003) použili čtyř objektových úrovní (*scale* - 100, 30, 10 a 5) při interpretaci dat družice IKONOS. V první úrovni byla interpretována zemědělská pole, vodní plochy, velké budovy a silnice, v druhé menší silnice, ve třetí budovy a ve čtvrté vše ostatní.

Obr. 3.1 Efekt parametrů shape a scale na segmentaci dat družice QuickBird



Zdroj: Zdroj: Bauer & Yuan (2006)

Vedle algoritmu *multiresolution segmentation* jsou v Definiens dostupné i další tři jednodušší metody. „*Chessboard segmentation*“ rozdělí prostor na čtvercové objekty o zadané velikosti. „*Quad tree based segmentation*“ každý čtvercový objekt dále rozděluje na 2×2 čtverce tak dlouho dokud spektrální heterogenita uvnitř čtverce přesahuje určený *scale* parametr. „*Spectral difference segmentation*“ je určena pro úpravu výsledků předchozích segmentací. Sloučeny jsou ty objekty, jejichž rozdíl středních hodnot je menší než stanovená mez (Definiens AG, 2006a).

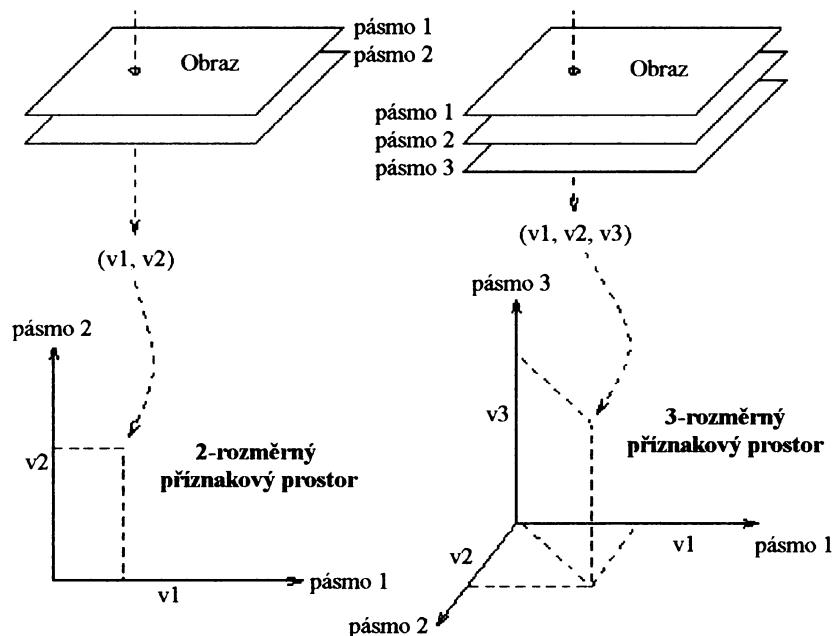
3.2 Příznakový prostor a operace s příznaky

Po vytvoření obrazových objektů následuje hledání vhodných objektových vlastností pro sestavení klasifikačních pravidel. Používaným termínem pro objektovou vlastnost je pojem „*příznak*“. Vyhodnocení pravidel probíhá v příznakovém prostoru. Pro jeden interpretovaný objekt lze považovat jeho hodnotu dvou různých příznaků za *příznakový vektor*. Pokud tento vektor vykreslíme do grafu získáme 2-rozměrný *příznakový prostor*. V závislosti na počtu uvažovaných příznaků hovoříme o n-rozměrném příznakovém prostoru (Kerle et al., 2004). Vztah mezi obrazem a příznakovým prostorem znázorňuje obrázek 3.2.

Při interpretaci snímku s vysokým prostorovým rozlišením jsou vedle spektrálních prvků využívány i další dva základní druhy příznaků, texturální a kontextuální. Objektová analýza přidává ještě skupinu geometrických příznaků

popisujících tvarové vlastnosti objektu. Spektrální prvky popisují průměrnou proměnlivost tónu (barvy) v různých pásmech viditelné anebo infračervené části elektromagnetického spektra, zatímco texturální prvky obsahují informaci o prostorovém rozložení tonálních proměn v pásmu. Kontextuální prvky obsahují informaci odvozenou z bloku obrazových pixelů sousedících s pozorovaným regionem. Všechny tři prvky jsou přítomny v každém pořízeném snímku. V mnoha případech dominuje jen jedna z vlastností. V minulosti byly pro automatické zpracování obrazu nejdůležitější textura a tón (Haralick et al., 1979). Současný software (např. Definiens Professional) umožňuje i širší využití kontextuální informace. Zmíněný software obsahuje celou řadu již předdefinovaných prvků, ale umožnuje také jednoduchý výpočet vlastních uživatelských příznaků („*customized features*“). V následujícím oddílu je proto uveden přehled vybraných objektových příznaků, které byly použity v praktické části. Pro úplnost jsou naznačeny běžné metody optimalizace příznakového prostoru.

Obr. 3.2 Vztah mezi obrazem a příznakovým prostorem



Zdroj: Kerle et al. (2004)

3.2.1 Spektrální příznaky

Základní vlastnosti chování objektů v jednotlivých pásmech popisují prvky přímo reprezentující absolutní naměřené elektromagnetické veličiny. Mezi tyto primární prvky se řadí střední hodnota všech pixelů jednoho objektu v konkrétním pásmu (např. Mean Blue). Pro odlišení jednotlivých objektů je informace obsažená v primárních kanálech někdy nedostatečná, a proto se často používají metody pro zvýraznění obrazové informace. Nejčastěji používanými jsou spektrální indexy. (Dobrovolný, 2007) dělí indexy na poměrové a ortogonální. Poměrové indexy jsou nelinární kombinací a vznikají jednoduchým podílem hodnot několika původních příznaků. Výsledkem je obvykle jeden nový příznak zvýrazňující určitou obrazovou informaci. Podle Lillesand & Kiefer (2004) je výhodou poměrových příznaků, že zachovávají spektrální charakteristiky bez ohledu na měnící se podmínky osvětlení. Mezi jednoduché poměrové indexy patří například *RVI* („*Ratio vegetation index*“). Podílem DN hodnoty v červeném a blízkém infračerveném pásmu lze poměrně jednoduše odlišit vegetační a nevegetační složku obrazu. Nevýhodou jsou hodnoty, které index nabývá. Z matematického hlediska může hodnota indexu dosahovat až k nekonečnu pokud odrazivost v červeném pásmu je nula.

Mnohem širšího použití dosahuje index *NDVI* („*Normalized difference vegetation index*“), který je definován následovně:

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}.$$

Normalizovaný index nabývá hodnot od -1 do 1 a lze ho využít i pro srovnání dat různých scén (Rees, 2001). Index *NDVI* je používán téměř ve všech aplikacích vyžadujících odlišení vegetace od ostatních povrchů. *NDVI* odpovídá změnám zelené biomasy, obsahu chlorofylu a obsahu vody ve vegetaci.

Na stejném principu výpočtu je založen index *NDGI* („*Green normalized difference vegetation index*“). Zhan (2003) ho používá při klasifikaci městského land cover. Kvůli lepšímu odlišení vodních ploch používá i jeho upravenou variantu *eNDGI* s využitím všech spektrálních kanálů. Vzorec pro výpočet *NDGI*, resp. *eNDGI* je:

$$NDGI = \frac{(NIR - Green)}{(NIR + Green)}$$

$$eNDGI = \frac{(NIR - Green)}{(Blue + Green + Red + NIR)}.$$

Mezi normalizované příznaky lze zařadit i prvky přímo implementované v software Definiens Professional. Jas („*brightness*“) a odvozené příznaky tzv. poměry („*Ratia*“). Příznak *brightness* vyjadřuje podíl součtu všech kladných středních spektrálních hodnot objektu a počtu spektrálních pásem. Pomocí jasu lze odlišit extrémně světlé nebo tmavé objekty, například střechy budov s vysokou odrazivostí. Ratia jsou určeny jako podíl konkrétního pásma na celkovém jasu objektu.

Druhou velmi častou skupinou jsou ortogonální indexy založené na lineární kombinaci originálních spektrálních příznaků. Podobně jako analýza hlavních komponent („*Principal Component Analysis*“ - *PCA*) jsou založeny na rotaci os příznakového prostoru. Dobrovolný (2007) uvádí jako příklad *PVI* („*Perpendicular vegetation index*“) umožňující odlišení odrazivosti vegetace a půdního substrátu.

Významější transformaci však představuje „*Tasseled Cap*“ transformace (*TCT*). Koncept *TCT* byl původně odvozen pro 4 pásmá senzoru Landsat MSS (Kauth & Thomas, 1976) a dále byl rozšířen pro zařízení Landsat TM (Crist & Cicone, 1984). Huang et al. (2002) navrhli koeficienty *TCT* pro ETM+ družice Landsat 7. Využití transformovaných pásem družice Landsat je při klasifikaci poměrně běžné. Pro snímky IKONOS byly koeficienty odvozeny institucí SpaceImaging. Závěry výzkumu celého týmu prezentuje Horne (2003). Výsledkem analýzy 195 snímků jsou lineární rovnice pro čtyři nová pásmá:

$$TCT1 = 0,326 \times Blue + 0,509 \times Green + 0,560 \times Red + 0,567 \times NIR$$

$$TCT2 = -0,311 \times Blue - 0,356 \times Green - 0,325 \times Red + 0,819 \times NIR$$

$$TCT3 = -0,612 \times Blue - 0,312 \times Green + 0,722 \times Red - 0,081 \times NIR$$

$$TCT4 = -0,650 \times Blue + 0,719 \times Green - 0,243 \times Red - 0,031 \times NIR.$$

TCT1 vznikne jako součet DN hodnot všech 4 originálních pásem. Výsledkem je obraz velice podobný panchromatickému. Výhodou *TCT1* oproti panchromatickému snímků je absence přesvícených objektů. *TCT* vzniká kombinací multispektrálních pásem, které na rozdíl od panchra tímto efektem netrpí. *TCT2* má podobné charakteristiky jako *NDVI*. Díky vysoké váze NIR se vegetace projevuje světlými tóny zatímco umělé povrchy mají tendenci tmavého vzhledu. Vedle rozlišení vegetace je *tasseled cap* transformace vhodná také jako nástroj k redukci počtu spektrálních pásem a soustředění informace do méně kanálů (Lillesand & Kiefer, 2004). *TCT1* a *TCT2* obsahují většinu (95 %) variability z MS kanálů, proto se k odlišení různých druhů povrchů *TCT3* a *TCT4* používají zřídka (Horne, 2003). Mori et al. (2004) využili *TCT2* jako jednoduchý indikátor různých typů vegetace při mapování land use v Japonsku.

3.2.2 Texturální příznaky

Textura je přirozenou vlastností všech objektů a vyjadřuje prostorovou variabilitu spektrálních hodnot. Pro automatické zpracování texturovaných obrazových dat existuje mnoho způsobů popisujících prostorovou proměnlivost spektrálních hodnot Haralick (1979). Nejjednodušší jsou statistické míry získané filtrováním okolí pixelů (Dobrovský, 2007). Jiným způsobem může být výpočet Fourierových transformací pro blízké okolí pixelu a zisk koeficientu pro konkrétní frekvenci (Rees, 2001). Velmi časté jsou také míry textury s využitím detekce hran (Zhang, 2001).

Nejobvyklejšími jsou však míry textury odvozené z matice prostorové závislosti *GLCM* („Grey-level co-occurrence matrix“ nebo „Grey-level dependency matrix“). Princip prostorové závislosti je založen na pravděpodobnosti vzájemného výskytu úrovní šedi. Ve filtračním okně je vypočtena četnost kombinací DN hodnot středového pixelu s DN hodnotami všech ostatních pixelů. Normalizovaná matice *GLCM* pak vyjadřuje pravděpodobnosti výskytu určitých kombinací DN hodnot pixelů. Prvky na diagonále matice reprezentují pixely s nulovou změnou úrovně šedi. Prvky *GLCM* vzdálené jednu pozici od hlavní diagonály zastupují pixely s rozdílem jedné úrovně šedi atd. Výpočet *GLCM* bere v úvahu i prostorové vztahy uvnitř filtračního okna. *GLCM* je odvozena pro vztahy pixelů v osách definovaných úhly 0° , 45° , 90° , 135° nebo nezávisle na směru („all dir.“) (Haralick, Shanmugam, Dinstein, 1973; Definiens AG, 2006b; PCI Geomatics, 2003).

Z matice *GLCM* jsou následně počítány statistické míry převážně metodou váženého průměru buněk matice (Dobrovolný, 2007). Haralick, Shanmungam, Dinstein (1973) popsali čtrnáct měr.

Míry založené na kontrastu používají vahy vztažených ke vzdálenosti buněk od hlavní diagonály. S rostoucí vzdáleností roste kontrast a váha prvku. Vedle měr založených na kontrastu existují míry založené na pravidelnosti nebo na popisných statistikách *GLCM*. Např. *GLCM Průměr* („*Mean*“) vyjadřuje střední hodnotu buněk matice, *GLCM Std. odchylka* („*Std. deviation*“) udává proměnlivost hodnot kolem průměru a *GLCM Korelace* („*Correlation*“) je mírou lineární závislost sousedních pixelů (Dobrovolný, 2007).

Praktického využití (např. Zhang, 2001; Narashimha Rao et al., 2002) a implementace v komerčním software dosahuje zhruba polovina měr. Častým tématem odborné literatury je komparace různých texturálních měr. Korelaci pěti vybraných *GLCM* prvků a typů lesních stanovišť za účelem inventarizace lesních porostů studují Tuominen & Pekkarinen (2005). Zhang (2001) porovnává lokální statistické míry s prvky odvozenými *GLCM* matice a hranovými operátory. Narashima et al. (2002) se snaží o porovnání přínosu texturálních příznaků pro klasifikace land cover.

3.2.3 Geometrické a kontextuální příznaky

Vedle spektrálních a texturálních vlastností lze popsat obrazové objekty geometrickými charakteristikami nebo jejich vzájemnými prostorovými vztahy. Kontextuální příznaky popisují prostorové uspořádání objektů v obrazu. Základní topologické vazby jako je vzdálenost, směr nebo dotyk vyjadřují relace k objektům ve stejné úrovni objektů. Hierarchická síť objektů umožňuje vytvoření kontextuálních vazeb i mezi objekty („*superobjects*“) a jejich hierarchicky níže postavenými podobjekty („*subobjects*“). Geometrické příznaky dovolují popsat objekty vlastnostmi odvozených z tvaru: délka hranice, plocha, pravidelnost tvaru atd.

3.2.4 Optimalizace příznakového prostoru

V předchozích kapitolách bylo popsáno několik příznaků. Většina software zaměřených na zpracování obrazu umožnuje tvorbu mnoha dalších vlastních uživatelských příznaků. Jednoduchou cestou lze vytvořit velmi rozmněný příznakový

prostor. Výpočetní doba klasifikace se tak může i mnohonásobně prodloužit bez viditelného efektu na zlepšení klasifikačních výsledků. Předcházení používání nadbytečných příznaků může částečně pomoci uživatelská znalost například texturálních vlastností zkoumaných prvků, ale je těžké odhadnout podíl jednotlivých prvků na klasifikačních výsledcích (Leduc, 2004).

Jednou z nejčastěji používaných metod je analýza hlavních komponent (*PCA*). Snahou *PCA* je zmenšení rozměrnosti příznakového prostoru soustředěním co největší variability dat do co nejmenšího počtu nových příznaků. Problémem může být to, že variabilita dat nemusí korespondovat s největším množstvím informace. Jako příklad je udáván projev vodní plochy v radarovém snímku. Hladiny jezera se v radarových datech neprojevuje vysokou variabilitou. Proto komponenta *PCA* nemůže být použita pro interpretaci vodní plochy.

Pratt (1991) dělí metody redukce optimalizace příznakového prostoru do dvou skupin. Jedna kategorie přístupů je založena klasifikací dat s různými kombinacemi datových sad. Nejúspěšnější klasifikace je zvolena jako nejoptimálnější. V druhém případě je vyhodnocena separabilita objektů pro jednotlivé příznaky. Pásma s největší vzdáleností (divergencí) jsou využita. Divergence je statistický parametr vyjadřující kovarianční váhovou vzdálenost mezi průměry jednotlivých kategorií (Halounová, Kolář, Pavelka, 1991). Leduc (2004) jako příklad uvádí kritérium pro hodnocení separability: „*Bhattacharyya distance*“. *Bhattacharyya distance* je statistická míra podobnosti dvou diskrétních rozložení pravděpodobnosti (Wikipedia contributors, 2007a):

$$BC(p, q) = \sum_{x \in X} \sqrt{p(x)q(x)}$$

p a q jsou pravděpodobnostní rozdělení a x je z množiny náhodných veličin X

K optimalizaci příznakového prostoru jsou také používány i analýza kanonických komponent („*canonical component analysis*“ – *CCA*) nebo diskriminační analýza („*discriminant analysis*“). *CCA* transformace je podobná *PCA* analýze s tím rozdílem, že soustředí většinu variability do hlavní komponenty. Diskriminační analýza patří mezi statistické metody pomocí níž lze objekt zařadit do jedné existující třídy (Rees, 2001).

3.3 Objektově orientovaná klasifikace

Software Definiens podporuje různé techniky řízené klasifikace a umožňuje několik způsobů získání expertní znalosti pro klasifikační fázi. Základem je vytvoření hierarchie tříd. Hierarchický systém tříd může odpovídat sémantickému vztahům reálných objektů a zároveň může respektovat logickou strukturu klasifikačního postupu. Výhodu lze spatřovat v dědičnosti popisu tříd a možnosti využití sémantiky pro tvorbu různých klasifikačních strategií (Definiens AG, 2006b).

Největším rozdílem oproti tradičním spektrálním pixelovým klasifikacím je ten, že objektově orientovaná klasifikace pracuje s obrazovým segmentem nebo objektem. Objekty je možné popsat různými vlastnostmi (viz kapitola 3.2). Klasifikační model je založen na popisu tříd. Popis jednotlivých tříd se skládá z pravidel určujících hodnoty příznaků, které třída nabývá. Výhodou objektově orientované klasifikace je možnost vytvoření pravidel pomocí fuzzy logiky. Tzv. funkce příslušnosti („*membership function*“ – *MF*) umožňují vyjádření neurčitosti v zařazení objektů. Hodnota příslušnosti k dané třídě se pohybuje mezi 0 a 1 včetně. Nula znamená absolutní nezařazení objektu do třídy, zatímco 1 vyjadřuje absolutní příslušnost (Dobrovolný, 2007). Každé pravidlo vyjadřuje vztah jedné třídy a jednoho příznaku. Pomocí logických operátorů lze kombinovat více pravidel pro jednu třídu. Stupeň příslušnosti závisí na tom jak konkrétní objekt vyhovuje všem pravidlům, kterými je každá třída charakterizována. Problémem členským funkcí je určení jejich tvaru a průběhu. Nejčastěji používaným způsobem je manuální určení parametrů *MF* na základě expertní znalosti. Získání potřebné znalosti však vyžaduje časově velmi náročnou interakci uživatel-software. Automatické vygenerování funkcí příslušnosti pro více příznaků najednou je možné pomocí klasifikátoru nejbližšího souseda.

Automatickým zjištěním parametrů *MF* mimo software Definiens se zabývají Brodský & Borůvka (2006). Na příkladě mapování světlosti půd porovnávají čtyři způsoby stanovení parametrů *MF*. Vedle manuálního způsobu využívají shlukové analýzy K-means. Dalšími prezentovanými metodami jsou odvození *MF* z funkce hustoty pravděpodobnosti normálního rozložení a z tvaru histogramu tříd.

Po vytvoření klasifikačních pravidel je provedena fuzzy klasifikace porovnáním každého objektu s pravidlovým popisem všech tříd a přiřazením stupně příslušnosti ke

každé třídě. Každému objektu jsou na konci klasifikace ponechány tři nejvyšší hodnoty příslušnosti. Výsledky lze prezentovat jako rastry vyjadřující příslušnost k třídám nebo jednoznačně zařadit objekty na základě nejvyšší hodnoty příslušnosti.

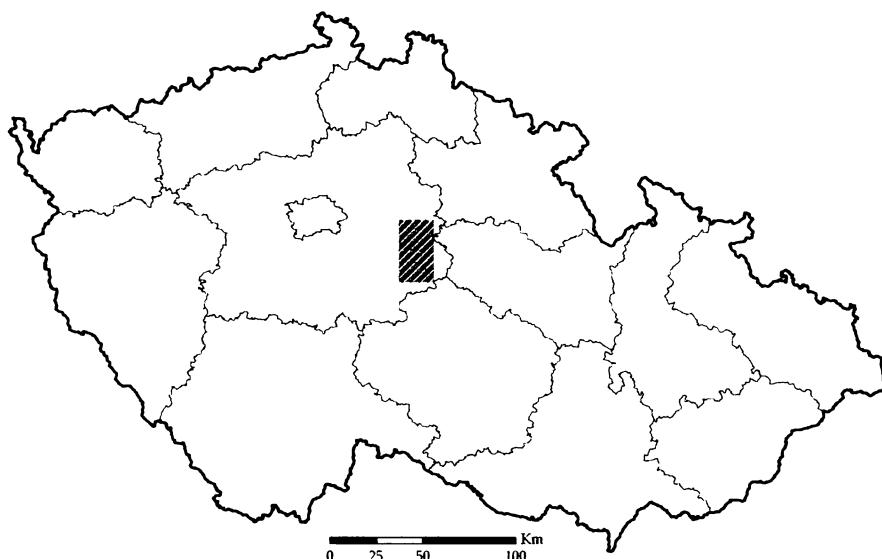
Kapitola 4

Data a zájmové území

4.1 Modelové území

V rámci práce je hodnocena přenositelnost objektových příznaků. Faktorem, který může působit na přenositelnost je krajinný ráz mapované oblasti. Z tohoto důvodu byla v souladu s pokrytím satelitními snímkami jako modelové území zvolena oblast ve Středočeském kraji (viz obr. 4.1), jejíž hlavními centry jsou města Kolín a Kutná Hora. Na sledovaném území lze zaznamenat různorodé fyzickogeografické podmínky, které předurčují charakter sídelní struktury a formu využití zemědělské půdy. Na základě přírodních poměrů lze vymezit ve sledovaném území dvě oblasti, severní rovinatou a jižní s členitějším reliéfem.

Obr. 4.1 Poloha modelového území v rámci ČR



Zdroj: ArcČR © ArcData Praha a vlastní

Území v severní části výřezu je součástí Středolabské tabule s nejvyššími nadmořskými výškami do 350 m n.m. Převažujícími typem využití relativně ploché krajiny jsou velké areály orné půdy. Nezanedbatelnou rozlohu také zaujmají zastavěná území (město Kolín) a vodní plochy (řeka Labe, slepá ramena a nádrže vzniklé těžbou

štěrku a písku). Jižní polovina je charakterizována zvlněným terénem zvedající se Hornosázavské pahorkatiny dosahujících výšek až 550 m n.m. Vzhled území je venkovského typu s výskytem malých vesnic, malých zemědělských polí a většího množství luk a lesů.

Zonalita je patrná i z pedologického hlediska. Na severu v okolí řeky Labe se vyskytují především nivní půdy (fluvizemě) a úrodné černozemě. Směrem na jih s rostoucí nadmořskou výškou nížinné typy půd přecházejí v hnědozemě a luvizemě a v nejvyšších polohách až do lesních typů (kambizemě) (Tomášek, 2000).

4.2 Družicová data IKONOS a charakteristika platformy

Jako hlavní datová základna byly zvoleny družicové snímky s velmi vysokým prostorovým rozlišením. Po diskusi a prozkoumání pokrytých oblastí byla vybrána, jako vhodná, data družice IKONOS. Pro účely této magisterské práce byly firmou Gisat zapůjčeny tři snímky. Jednotlivé snímky pokrývající území 11×11 km jsou pořízeny 15.6. 2006 v jedné sekvenci a pokrývají tak souvislý pás o velikosti 11×33 km. Poskytnutá data byla již ortorektifikována do systému S-JTSK. Ortorektifikace byla podle ústního sdělení pracovníka firmy provedena s maximální střední polohovou chybou 2,5 m s využitím resamplingovací metody nejbližšího souseda. Sadu poskytnutých dat tvořil jeden celý snímek v panchromatickém pásmu (PAN) a čtyři pansharpovalé výřezy (každý $\frac{1}{4}$ PAN) multispektrálního snímku ve formátu TIFF.

IKONOS patří do skupiny družicových systémů poskytujících data s velmi vysokým prostorovým rozlišením (v řádu 1 m a méně). Jako hlavní směry využití jsou nejčastěji uváděny aplikace vyžadující velký prostorový detail, např. národní bezpečnost (monitorování nepřístupných území, krizové akce vyžadující rychlé zmapování situace), topografické mapování (Kopalová, 2007), územní plánování na lokální a regionální úrovni, plánování, projektování a monitorování liniových staveb (produktovody, dopravní stavby), zemědělské a lesní hospodářství, meteorologie a sledování životního prostředí.

Družice IKONOS byla vypuštěna na oběžnou dráhu jako první komerční satelit v této skupině v roce 1999. Obrazová data jsou pořizována současně pomocí pushbroom scanneru v panchromatickém a multispektrálním módu. Černobílé panchromatické

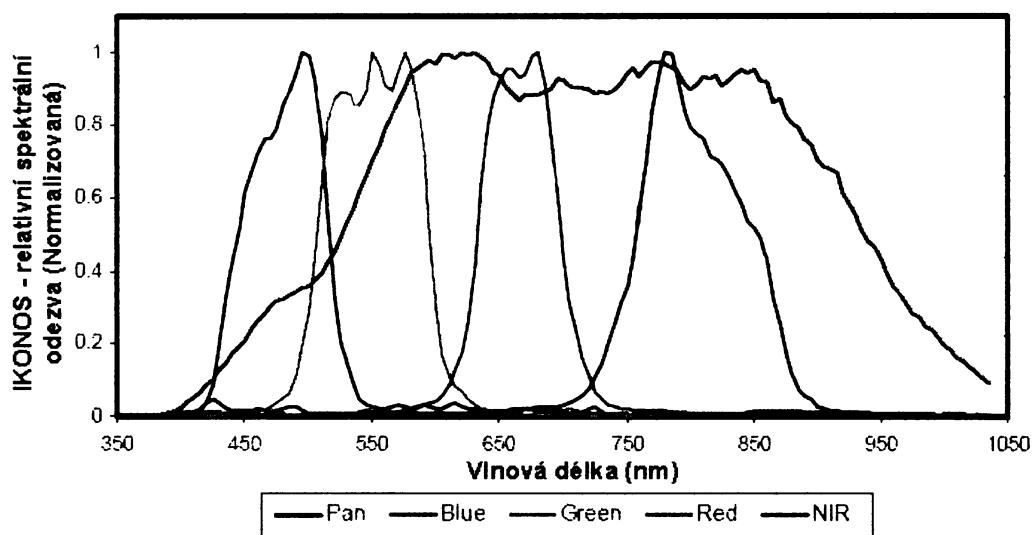
snímky jsou pořizovány na vlnových délkách 0,45 – 0,9 nm s velikostí jednoho pixelu 1 m (po převzorkování). Barevná multispektrální data jsou zaznamenávána ve 4 spektrálních intervalech v rozsahu uvedeném přehledové tabulce 4.1 a s prostorovým detailem 4 m (po převzorkování). Spektrální odezva detektorů v jednotlivých spektrálních pásmech je znázorněna na obrázku 3.2. Průběh odezvy je jedním z uvažovaných faktorů při využití jednotlivých pásem pro klasifikaci. Z překryvu modrého a zeleného spektrálního kanálu lze poukázat na možnou korelaci naměřených veličin v těchto pásmech.

Tab. 4.1 Přehled parametrů družice IKONOS

Obecné	
Datum vypuštění	24.9.1999
Místo startu	Vandenberg, Kalifornie
Očekávaná životnost	více než 8,5 let
Oběžná dráha	
Typ	slunečně synchronní, 98,1°
Rychlosť na ob. dráze	7,5 km/s
Rychlosť nad zem. povrchem	6,8 km/s
Počet oběhů Země za 1 den	14,7 / 24 h
Doba 1 oběhu Země	98 minut
Výška	681 km
Přechod rovníku	10:30 (lokálního času)
Temporální rozlišení (40° zem. šířky, max. výklon)	cca 3 dny
Parametry obrazových dat	
Prostorové rozlišení (nadír)	0,82 m / 3,2 m (PAN / MS)
Prostorové rozlišení (výklon 26°)	1 m / 4 m (PAN / MS)
Šířka záběru (nadír)	11,3 km
Radiometrické rozlišení	11 bitů
Spektrální pásma	
Panchromatické (PAN)	526 - 929 nm
Modré (Blue)	445 - 516 nm
Zelené (Green)	506 - 595 nm
Červené (Red)	632 - 698 nm
Blízké infračervené (NIR)	757 - 853 nm

Zdroj: GeoEye (2007)

Obr. 4.2 Spektrální rozsah a odezva družice IKONOS



Zdroj: GeoEye (2007)

4.3 Pomocná data

Jako pomocná data pro ověření přesnosti výsledné klasifikace byla využita vektorová data Základní báze geografických dat (ZABAGED). 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). Současná podoba ZABAGED je výsledkem digitalizace Základní mapy ČR 1:10 000 několika fází provedených aktualizací. Pro tuto práci byly ČÚZK poskytnuty vybrané mapové listy v souřadnicovém systému S-JTSK a formátu SHP („shapefile“).

Kapitola 5

Metodika

Cílem této kapitoly je popsat postup zpracování dat zvolený pro splnění cílů práce. Obrázek 5.1 shrnuje hlavní kroky praktické části. Sekvence kroků obnášela definici klasifikovaných tříd a vymezení testovacích území. Následovala příprava družicových a referenčních dat v PCI Geomatica a ESRI ArcGIS, vytvoření pomocných vrstev *NDVI100*, *Border* a *Frame*. V prostředí Definiens Professional byla provedena tréninková segmentace pro manuální klasifikaci tréninkových objektů. Vybrané spektrální a texturální příznaky tréninkových objektů byly poté vyexportovány a analyzovány ve statistickém programu SPSS. Výsledkem analýzy byl výběr prostorově stabilních příznaků vhodných pro klasifikaci jednotlivých tříd. Prostorová stabilita je chápána jako minimální proměnlivost hodnot příznaku pro jednu třídu mezi testovacími výřezy. Lze ji také chápat jako přenositelnost příznaků mezi lokalitami. Na základě těchto příznaků byla vytvořena fuzzy pravidla a sestaven popis tříd. V prostředí Definiens byla poté provedena hierarchická segmentace, fuzzy klasifikace, ověření tématické přesnosti a přenositelnosti celého klasifikačního modelu.

5.1 Odborná příprava

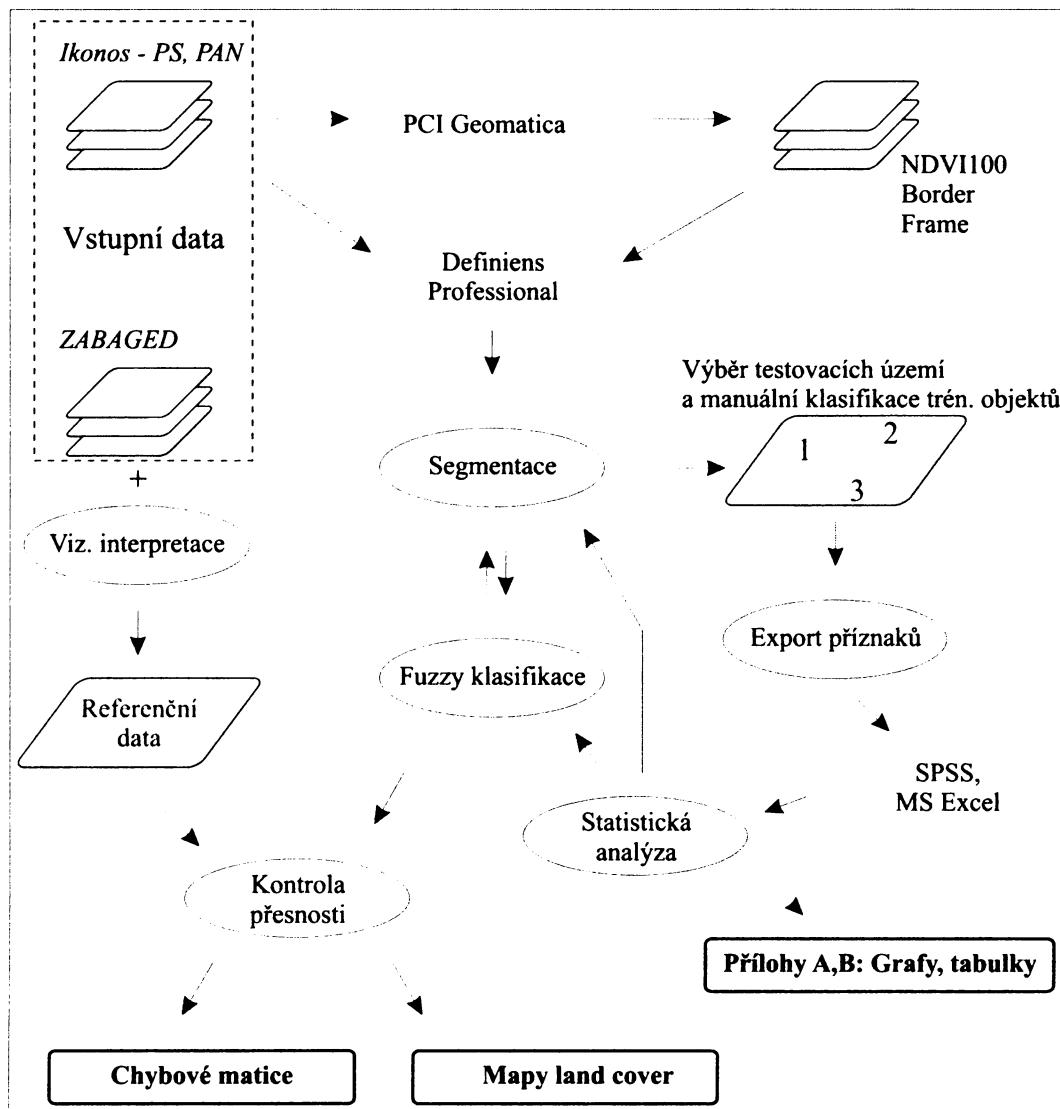
Použitými softwary v této práci byly ESRI ArcGIS Desktop 9.2, Definiens Professional 5, SPSS 13.0 a PCI Geomatica 10. Vzhledem k tomu, že před zahájením praktické části práce nebyla možnost se seznámit s programem Definiens bylo užitečné nejprve absolvovat školení ke zmíněnému softwaru. V rámci přípravy jsem se proto zúčastnil dvou akcí zaměřených na zpracování a analýzu družicových dat.

První z nich byl dvoudenní seminář k programům PCI Geomatica a Definiens konaný v září 2006 v Praze v rámci programu *CITT Praha Akademie kosmických technologií, oblast Galileo, GMES*. V rámci semináře došlo k základnímu představení funkcí software Definiens Professional a PCI Geomatica pracovníky firem PCI Geomatics, Definiens AG a Gisat, s.r.o.

Druhé školení proběhlo 4.-6. ledna 2007 v Krakówě. Během „*3rd eCognition Workshop ver.5 Professional – Interactive training on Object Based Image Analysis*

Process, architectural design“ byly Dr. Ir. R. de Kokem a jeho spolupracovníky prezentovány základní koncepty objektově orientované analýzy obrazu a její implementace v DPZ. V průběhu workshopu byla většina teorie demonstrována na připravených projektech. Přínosem obou školení bylo kromě vytvoření přehledu v oblasti OBIA, praktické osvojení práce s programem Definiens Professional verze 5 a otestování jeho vhodnosti pro různé aplikace.

Obr. 5.1 Schéma pracovního postupu



5.2 Přípravné práce

5.2.1 Definice tříd land cover

Objektově orientovaná klasifikace v této práci je zaměřena na vymezení zastavěných území a na mapování krajinného pokryvu (land cover) uvnitř sídel. V první úrovni klasifikačního systému (obr. 5.2) jsou dvě kategorie zastavěné a nezastavěné území. Pro vymezení třídy zastavěné území byla přijata definice ze stavebního zákona (viz kap. 2.2). Stručně ji lze charakterizovat jako území dotčené zástavbou, tj. budovy a plochy s nimi přímo související (např. zahrady). Všechny ostatní plochy jsou zařazeny do třídy nezastavěné území. V rámci nezastavěného území byly definovány tyto třídy: holá půda, vegetace, lesy a vodní plochy. Třída holá půda zahrnuje půdu bez vegetace a holé skály. Třída vegetace obsahuje všechny vegetační porosty mimo zástavbu s výjimkou lesa. V třídě les jsou zahrnutы jehličnaté, listnaté i smíšené lesy. Vodní plochy zahrnují řeky, rybníky a nádrže. Třída zastavěných území byla dále rozdělena do pěti podkategorií: budovy s červenými a světlými střechami, ostatní zpevněné povrchy s výjimkou budov, stromy a trávníky v zástavbě. K zastavěnému území byly přiřazeny i stíny.

Obr. 5.2 Klasifikační schéma

- ○ Nezastavěné území
 - Holá půda
 - Les
 - Vegetace
 - Vodní plochy
- ● Zastavěné území
 - Červené střechy
 - Stíny
 - Stromy
 - Světlé střechy
 - Trávníky
 - Zpevněné povrchy

5.2.2 Výběr testovacích území

Hlavním cílem této práce je nalezení prostorově stabilních objektových příznaků, které umožní odlišení jednotlivých tříd v různých testovacích územích. Za účelem hodnocení prostorové přenositelnosti příznaků byly v zájmovém území vymezeny tři testovací výřezy o velikost zhruba $5\ 000 \times 5\ 000$ pixelů. Jako kvalitativní faktor ovlivňující hodnoty příznaku byl uvažován i charakter krajiny. Proto byly testovací výřezy vymezeny v typově odlišných částech scény.

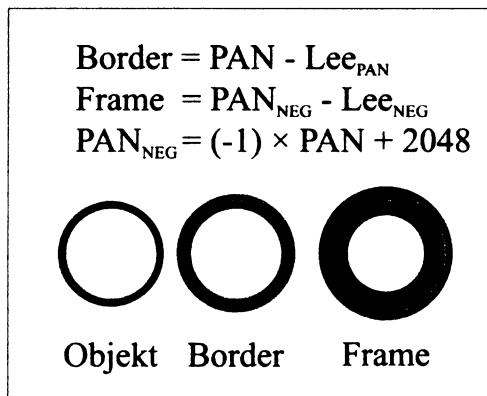
První oblast pokrývá velkou část města Kolín a přilehlé okolí. Území lze charakterizovat převážně městským land usem s výskytem velkých obytných domů, pravidelné zástavby rodinných domů, průmyslových a obchodních areálů a sídelní vegetace. Druhá oblast zaujímá východní polovinu města Kutná Hora a okolní vesnice vyznačující se kompaktní zástavbou rodinných domů. Plochy mimo zastavěné území pokrývají lesy, zemědělská pole a vodní plochy. Celkově se dá tento výřez považovat za území smíšeného městského a venkovského charakteru. Vzhled třetí testovací lokality je možno popsat jako typický venkovský. Vyskytují se zde malé vesnice se zemědělskými usedlostmi, rodinnými domy a větší rozlohou areálů zemědělské půdy, lesů a trvalých travních porostů. Zástavbu v tomto území lze charakterizovat jako rozptýlenou a nesouvislou s velkým podílem vegetace.

5.2.3 Předzpracování dat

Před zahájením samotné obrazové analýzy bylo nutné podkladová data sjednotit a připravit na vstup do programu Definiens. Předzpracování proběhlo v prostředí programu PCI Geomatica. Všechna data byla nejprve importována do nativního formátu PCIDSK. Snímky IKONOSu byly poskytnuty již radiometricky i geometricky zpracované, proto byla provedena pouze úprava územního rozsahu. Pro analýzu v Definiens byla připravena tři nová pásma. Prvním byl vegetační index *NDVI100*. Rozdíl mezi *NDVI* a *NDVI100* je pouze ve formátu hodnot, kterých index nabývá. *NDVI100* je vypočten jako $(NDVI + 1) * 100$ a ve výsledku nabývá kladných celých hodnot v rozsahu zhruba 100-180. Vegetační index by mohl být spočítán až v Definiens jako uživatelský příznak. Důvodem jeho vytvoření již v této fázi byla snaha o ušetření výpočetního výkonu při pozdější analýze. Dalšími dvěma novými pásmeny byla odvozená pásmo *Border* a *Frame*.

Border a *Frame* byly vytvořeny v prostředí EASI Modelling se záměrem použití a otestování míry textury *PAN_BF* jako objektového příznaku. Princip vzniku prvků *Border* a *Frame* ilustruje obrázek 5.3.

Obr. 5.3 Princip tvorby prvků *Border* a *Frame*



Zdroj: De Kok (2007)

Border byl spočten jako rozdíl hodnot šedi v pásmu *PAN* a v rozostřeném pásmu *PAN* radarovým filtrem *Lee sigma*. Filtr *Lee sigma* je především používán pro vyhlazení vysoce texturovaných radarových dat (Esch, Roth, Dech, 2005). Jeho výhodou je, že zachovává hrany a ostré tvary. V PCI Geomatica se nachází v knihovně algoritmů pod názvem *FLE* nebo *FELEE* (PCI Geomatics, 2003).

Frame je odvozen z negativů obou pásem použitých pro *Border*. *Border* ve výsledku reprezentuje hranici objektu a *Frame* obal hranice, tzv. rám. Jejich smyslem bylo vytvoření pásem reprezentujících hrany objektů. Při vhodném nastavení velikosti filtračního okna (7×7 pixelů) jsou detekovány nejvýznamější změny úrovní šedi. Obě pásmá velmi dobře zvýrazňují hrany střech budov a jiných ostrých tvarů, ale i jednotlivých korun stromů. Toho je využito při následné konstrukci texturálního příznaku *PAN_BF*, který je na objektové úrovni spočítán jako podíl střední hodnoty objektu v panchromatickém pásmu a součtu středních hodnot objektu v pásmech *Border* a *Frame* (De Kok, 2007). Výsledná hodnota příznaku reprezentuje frekvenci hran v objektu. *PAN_BF* nabývá velkého rozsahu hodnot, přičemž velmi texturované objekty dosahují nejnižších hodnot.

Výstupem z předzpracování rastrových dat v PCI Geomatica bylo 8 vrstev: panchromatické pásmo, 4 pansharpovalé kanály, vegetační index *NDVI100* a pásmá *Border* a *Frame*.

Zpracováním vektorových dat byly vytvořeny tři soubory referenčních dat pro ověření tématické přesnosti a přenositelnosti klasifikace (viz podkap. 6.2). Vybrané vrstvy ze ZABAGED byly použity jako vstupní data, jenž byla posléze manuálně editována v prostředí ArcGIS. Nejprve byly odstraněny nepoužité objekty. Vizuální interpretací byly upraveny obrysy střech a dalších prvků tak, aby souhlasily s družicovým snímkem. V dalším kroku byl soubor vektorových dat doplněn o nové objekty třídy stíny. Všechny prvky byly průběžně atributovány podle zvoleného klasifikačního schématu. Výsledný vektorový soubor byl vyexportován z formátu ESRI Personal geodatabase do formátu ESRI shapefile podporovaného programem Definiens. Pro účely ověření přesnosti vymezení měst byly zvektorizovány také hranice měst Kolína a Kutné Hory.

5.2.4 Pre-segmentace a výběr příznaků

Při pohledu na obrazová data lze popsat významovou strukturu jednotlivých krajinných prvků. Sídla, lesy, vodní plochy a plochy ZPF (Zemědělský půdní fond) tvoří velké objekty jejichž vnitřní struktura je vyjádřena pomocí vztahů ke svým subobjektům. Například sídla vymezená obrysovou linií jsou tvořena dalšími objekty: budovy, silniční síť a vegetace. Je zřejmé, že lze odlišit několik významových úrovní, kde na nejvyšší pozici stojí objekty jako jsou zastavěná území nebo objekty srovnatelné velikosti, zatímco na nižší úrovni se nachází základní prvky (malé domy, segmenty silnic, vegetace, atd.) (Hofmann et al., 2006).

Algoritmus *multiresolution segmentation* umožňuje vytvoření hierarchické struktury objektů respektujících významové úrovně skutečných objektů. Hierarchická segmentace provedená v této práci je popsána v podkapitole 5.4.1 v rámci strategie celého klasifikačního procesu. Pro vypočtení objektových příznaků a export statistik byla nejprve vytvořena jedna vrstva objektů s parametry segmentační úrovně 2 (viz tab. 5.2). Ve střední segmentační úrovni by mělo v následující klasifikaci být zařazeno do tříd nejméně objektů, proto byla vybrána jako zdroj statistických vlastností objektů.

V dalším kroku bylo ve všech třech lokalitách manuálně interpretováno přibližně 250 tréninkových objektů pro každou z deseti tříd land cover, což zahrnuje zhruba 7500 objektů. Pro všechny tréninkové objekty bylo následně vypočteno 36 vybraných spektrálních a texturálních příznaků. Výběr zahrnuje základní absolutní spektrální příznaky, odvozené spektrální indexy (lineární i nelineární transformace), základní texturální statistické míry, texturální míry odvozené z matice GLCM. Jejich výběr proběhl na základě obvyklého použití v různých projektech (De Kok, 2003; Zhan, 2003, aj.). Kromě příznaků popsaných v kapitole 3 byly do výběru zařazeny tyto příznaky vyjadřující texturu: standardní odchylky (STD) v jednotlivých pásmech a poměry střední hodnoty a standardní odchylky v jednom pásmu. Přehled všech vybraných příznaků podává tabulka 5.1. Hodnoty objektových příznaků byly z Definiens vyexportovány jako atributy vektorové vrstvy objektů do formátu DBF (*dBase file*). Následná statistická analýza proběhla v prostředích SPSS a MS Excel.

Tabulka 5.1 Spektrální a texturální příznaky vybrané pro hodnocení přenositelnosti

Spektrální příznaky			Texturální míry	
Absolutní	Poměrové	Ortogonalní		GLCM
<i>Mean Blue</i>	<i>Brightness</i>	<i>TCT1</i>	<i>M. Blue / STD Blue</i>	<i>Contrast NIR</i>
<i>Mean NIR</i>	<i>eNDGI</i>	<i>TCT2</i>	<i>M. NIR / STD NIR</i>	<i>Contrast Red</i>
<i>Mean Red</i>	<i>Mean NDVI100</i>	<i>TCT3</i>	<i>M. Red / STD Red</i>	<i>Correlation NIR</i>
-	<i>NDBI</i>	<i>TCT4</i>	<i>PAN_BF</i>	<i>Correlation Red</i>
-	<i>NDGI</i>	<i>eTCT1</i>	<i>STD Blue</i>	<i>Homogeneity NIR</i>
-	<i>Ratio Blue</i>	-	<i>STD NDVI100</i>	<i>Homogeneity Red</i>
-	<i>Ratio NIR</i>	-	<i>STD NIR</i>	<i>STD Blue</i>
-	<i>Ratio Red</i>	-	<i>STD Red</i>	<i>STD NIR</i>
-	<i>RV</i>	-	<i>Sum_STD / Brightness</i>	<i>STD Red</i>
-	<i>Zabud1</i>	-	-	-

Zdroj: vlastní

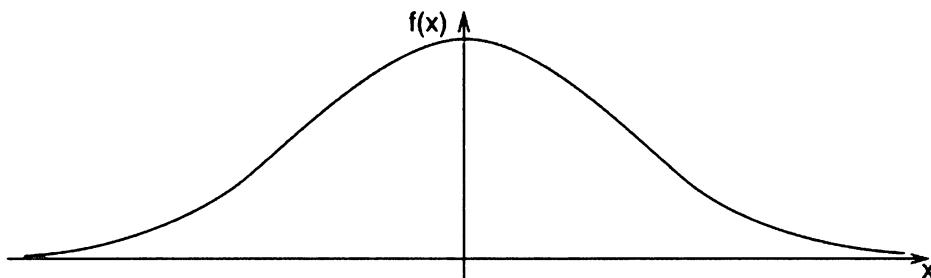
5.3 Analýza příznaků

5.3.1 Normální rozložení

Základní myšlenkou při výběru statistických nástrojů byl předpoklad, že se rozložení hodnot příznaku tréninkových objektů jedné třídy blíží Gaussovu normálnímu rozložení (Halounová, Kolář, Pavelka, 1997). Gaussovo rozložení $N(\mu_i, \sigma^2)$ je popsáno střední hodnotou μ a rozptylem σ^2 a definováno funkcí hustoty pravděpodobnosti normálního rozložení:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

Obr. 5.4 Funkce hustoty pravděpodobnosti Gaussova normálního rozložení



Zdroj: Tvrđík (1998)

Normální distribuce předpokládá symetrické rozložení výskytu hodnot kolem střední hodnoty výběru (viz obr. 5.4). V ideálním případě (velké množství objektů) by se výskyt tréninkových objektů měl blížit normálnímu rozložení. Ve skutečnosti je však rozložení hodnot provedeného výběru asymetrické a grafy jsou pouze approximací ideální situace a generalizují získanou informaci. Předpokladu normálního rozložení bylo využito při analýze a zároveň byly vytvořeny grafy hustoty normálního rozložení pro objekty jednotlivých tříd a lokalit (viz Přílohy B).

5.3.2 Analýza rozptylu (ANOVA)

Z dostupných statistických nástrojů byla vybrána jako hlavní metoda analýza rozptylu („*Analysis Of Variance*“ - ANOVA). ANOVA je statistická metoda vhodná pro porovnání několika výběrových souborů (dále skupina), které jsou pořízeny ze stejného základního souboru za různých podmínek. Na rozdíl od jiných testů (např. Párový T-test) umožňuje srovnání více než dvou skupin. V této práci použitý jednofaktorový model předpokládá pouze jednu kvalitativní veličinu mající vliv na výběrové soubory (tzv. faktor). Během analýzy se pro každou skupinu zvlášť počítá průměrná hodnota a rozptyl skupiny (s_i^2), průměrný rozptyl všech skupin (S_{res}^2), a zároveň rozptyl mezi průměry všech skupin ($S_{\bar{X}}^2$):

$$S_{res}^2 = \frac{s_1^2 + s_2^2 + s_3^2}{3},$$

$$S_{\bar{X}}^2 = \frac{\sum (\bar{X}_i - \bar{X})^2}{2},$$

kde $s_1^2 \dots s_i^2$ jsou rozptyly skupin a \bar{X}_i jsou průměry skupin a \bar{X} je průměr celého souboru (Anděl, 1978; Tvrdík, 1998).

Podstata analýzy rozptylu tkví v posouzení, jak velký podíl z celkového rozptylu je způsoben náhodnými vlivy a jak velký podíl zapříčinují různé úrovně faktoru. Pro zajištění správných výsledků je nutné splnění několika předpokladů. Předpokladem analýzy je, že všechny skupiny jsou výběrem ze základního souboru s normálním rozdělením $N(\mu_i, \sigma_i^2)$. Dalším předpokladem analýzy je rovnost rozptylů: $\sigma_1^2 = \sigma_2^2 = \sigma_3^2 = \sigma^2$, kde σ^2 je neznámý rozptyl základního souboru. Za uvedených předpokladů je platná nulová hypotéza: $H_0 : \mu_1 = \mu_2 = \mu_3$. Alternativní hypotéza H_1 znamená, že alespoň jedna průměrná hodnota se liší. Při posuzování nulové hypotézy existuje riziko chybného vyhodnocení. Mluvíme o chybě prvního druhu. Chyba prvního druhu je zvolena před začátkem testování a je nazývána signifikační úroveň či hladina významnosti (Tvrdík, 1998). Obvykle se volí 5%.

Výsledná charakteristika F-kritéria se spočítá jako:

$$F = \frac{\sigma_A^2}{\sigma_Z^2},$$

kde: σ_A^2 je rozptyl způsobený vlivem různých hodnot faktoru a σ_Z^2 rozptyl způsobený náhodnou složkou. F-kritérium se poté porovnává s tzv. kritickou hodnotou F (F_{KRIT}). F_{KRIT} je tabulková hodnota pro zvolenou signifikativní úroveň α . Je-li testovací F menší než F_{KRIT} , tak je potvrzena platnost nulové hypotézy a není důvod domnívat se, že faktor má podstatný vliv na výběrové soubory. Analýzu rozptylu lze použít i obráceným způsobem. Podle hodnoty výsledného kritéria lze testovat variabilitu mezi skupinami (Tvrdík, 1998).

Analýza rozptylu je robustní test, který umožňuje náhodné odchylky od podmínky normality. Vyžaduje však rovnost rozptylů. Pro testování podmínky analýzy rozptylu rovnosti rozptylů skupin byl použit Levenův test homogenity rozptylů. V případě negativního výsledku musel být pro analýzu místo testu ANOVA použit Brown-Forsytheův robustní test rovnosti průměrů, který shodnost rozptylů nepředpokládá (SPSS, 2004). Výsledkem je podobně jako u analýzy rozptylu F-kritérium, jehož hodnoty lze interpretovat stejně.

Výše uvedené statistické nástroje byly použity ve dvou fázích testování vybraných příznaků (viz tab. 5.1). V prvním kroku byla analýza rozptylu použita pro hodnocení variability tříd. Cílem bylo nalézt příznaky nehodící se pro odlišení žádné ze tříd. Všechny tréninkové objekty byly rozděleny do skupin podle příslušnosti k třídám LC. Jako kvalitativní faktor ovlivňující hodnoty jednoho příznaku byl uvažován popis třídy. Výsledná charakteristika F reprezentuje variabilitu mezi třídami v jednom příznaku. Analýza byla opakován provedena pro všechny příznaky. Na základě výsledků analýzy byl soubor zkoumaných příznaků redukován o ty, které se prokázaly jako nevhodné pro odlišení alespoň jedné třídy.

V druhé fázi hodnocení příznaků byla sledována proměnlivost jednotlivých příznaků mezi testovacími lokalitami. Příznaky byly rozděleny do skupin podle testovacích lokalit a tříd. Jako kvalitativní faktor ovlivňující hodnoty příznaku jedné třídy byla určena lokalita. Prostorová stabilita byla testována na hladině významnosti

$\alpha = 0,05$. Účelem této fáze analýzy byla snaha o určení těch příznaků, které pro konkrétní třídy vykazují stejné hodnoty a nemění se výrazně pro různé lokality. Vzhledem k širší definici některých tříd a tím způsobené variabilitě rozptylů musel být použit Brown-Forsytheův test.

Vzhledem k tomu, že výsledná prostorová stabilita příznaku pro konkrétní třídu nekoresponduje se separabilitou třídy od všech ostatních tříd, byly pro závěrečný výběr příznaků použity další nástroje. Pro grafické vyhodnocení odlišitelnosti tříd byly jako pomocné nástroje využity grafy hustoty pravděpodobnosti normálního rozložení (viz Přílohy B) a dvourozměrné rozptylogramy („scatterploty“) v Definiens, poskytující zároveň možnost posouzení korelace mezi dvěma příznaky.

5.4 Klasifikační strategie

Ověření prostorové stability vyběru příznaků bylo provedeno při objektové klasifikaci land cover. Klasifikace byla orientovaná na přesné vymezení zastavěných území a podrobnější rozlišení jejich struktury. Celý proces klasifikace se skládá ze dvou hlavních fází: iterativní segmentace založené na expertní znalosti, tj. s využitím (re)klasifikace a sestavení klasifikačních fuzzy pravidel. Iterativní přístup k segmentaci s využitím (re)klasifikace bývá někdy označován jako „*knowledge-based*“ (Hofmann et al., 2006). Zvolená klasifikační strategie byla založena na principu maskování, kdy byla nejprve segmentována hierarchicky nejvyšší vrstva. Po klasifikaci proběhla další segmentace a následně znova (re)klasifikace. V další úrovni byla provedena segmentace pouze neklasifikovaných objektů nebo objektů reprezentujících zastavěné území. Po klasifikaci byla vytvořena třetí nejnižší vrstva, jejíž pomocí byla optimalizována hranice zastavěných území a doklasifikovány nejmenší objekty. Klasifikační pravidla byla vytvořena na základě výsledků analýzy příznaků (viz kap. 5.4.2). V následujících dvou oddílech je nejprve detailněji popsána hierarchická segmentace a následně průběh fuzzy klasifikace a tvorby klasifikačního fuzzy modelu.

5.4.1 Hierarchická segmentace

Klíčovým krokem pro provedení objektově orientované klasifikace je tvorba obrazových segmentů. Prostředí zastavěných území je složité svojí strukturou skládající se z objektů různých velkostí, tvarů a spektrálních vlastností. Rozbor výsledků

předchozích prací ukázal, že pro klasifikaci sídel je vhodné použít více segmentačních úrovní (De Kok, et al., 2003; Taubenböck et al, 2006). Závěry odborných prací také poukazují na vhodná měřítka pro extrakci různých prvků (van der Sande, 2003). Na základě získaných informací a vlastního testu byla provedena hierarchická segmentace ve třech objektových úrovních. Parametry jednotlivých segmentací jsou uvedeny v tabulce 5.2.

Tabulka 5.2 Segmentační parametry

	Váhy spektrálních pásům				Kritéria homogeneity			Váhy parametru <i>shape</i>	
	Blue	Green	Red	NIR	Scale	Color	Shape	Smoothness	Compactness
Úroveň 1a	0	0	1	1	100	0,9	0,1	0,9	0,1
Úroveň 1b	1	0	1	1	100	0,1	0,9	0,9	0,1
Úroveň 2	0	1	1	1	30	0,2	0,8	0,9	0,1
Úroveň 3	1	1	1	1	10	0,1	0,9	0,9	0,1

Zdroj: Van der Sande et al. (2003) a vlastní nastavení

Na první úrovni (1a) byly vytvořeny objekty s parametrem *scale* 100. Použitá spektrální pásmo *Red* a *NIR* citlivá na přítomnost vegetace v kombinaci s vysokou váhou kritéria *color* měla sloužit k vytvoření spektrálně kompaktních objektů respektujících hranici mezi segmenty reprezentujícími vegetaci a umělé povrchy. Vysoká váha parametru *smoothness* je nastavena z důvodu požadavku co nejhladší hranice objektů. Na stejně úrovni byla nejprve odlišena pomocí prvku *PAN_BF* skupina texturovaných objektů (zástavba a texturovaná vegetace – lesy). Pomocí indexu *NDVI100* byla tato skupina rozdělena na vegetaci a nevegetaci. Texturované objekty nevegetace byly dále sloučeny a segmentovány znova (Úroveň 1b), ale s vysokou váhou kritéria *shape*. Cílem této operace byla snaha o vytvoření objektů pravidelného tvaru vhodných pro odlišení budov. V rámci celkové klasifikační strategie bylo na této úrovni hlavním záměrem určení největších budov a klasifikace velkých vodních ploch, lesů, a vegetace pro odmaskování ploch zástavby.

V druhé úrovni byla aplikována segmentace s měřítkovým parametrem 30 na neklasifikované objekty z první úrovni a objekty zástavby. Větší váha parametru *shape* měla znova zajistit správnou segmentaci objektů zástavby. Na této úrovni byla klasifikována většina objektů.

Smyslem vytvoření třetí vrstvy ($scale = 10$, $shape = 0,9$) byla snaha o klasifikaci nejmenších objektů a optimalizaci hranice zastavěných území. Pomocí kontextuálních příznaků, např. „*Relativní hranice s konkrétní třídou*“ a nástroje „*border optimization*“ pracujícího na principu eroze a dilatace (Pavelka, 1999) byla optimalizována hranice zastavěného území.

5.4.2 Fuzzy klasifikace

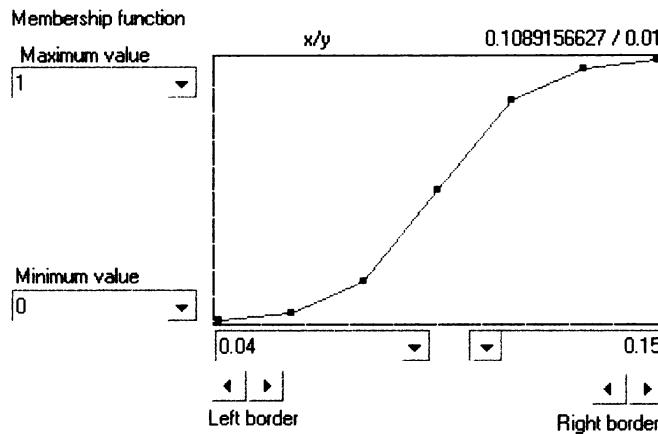
V kapitole 5.3 byla popsána metoda výběru spektrálních a texturálních příznaků pro jednotlivé třídy. Příznaky vykazující dostatečnou přenositelnost mezi testovacími oblastmi a separabilitu tříd byly následně použity pro tvorbu klasifikačních fuzzy pravidel. Vedle spektrálních a texturálních příznaků byly použity i kontextuální a tvarové příznaky. Výběr těchto objektů proběhl standardní způsobem v Definiens.

Klasifikační pravidlo popisuje hodnoty jednoho příznaku, kterých nabývají objekty jedné třídy. V případě klasických pravidel založených na ostrých hranicích tříd a Booleovské logice jsou objekty buď jednoznačně přiřazeny do třídy nebo jsou odmítnuty. Fuzzy pravidlo umožnuje vyjádření neurčitosti přiřazením určitého stupně příslušnosti. Předpis, kterým je určeno jaká hodnota příznaku odpovídá konkrétnímu stupni příslušnosti se nazývá funkce příslušnosti (Zadeh, 1965).

Celý proces fuzzy klasifikace lze charakterizovat jako přiřazení atributu třídy land cover obrazovým objektům s využitím fuzzy logiky. Tento proces lze rozdělit do třech fází:

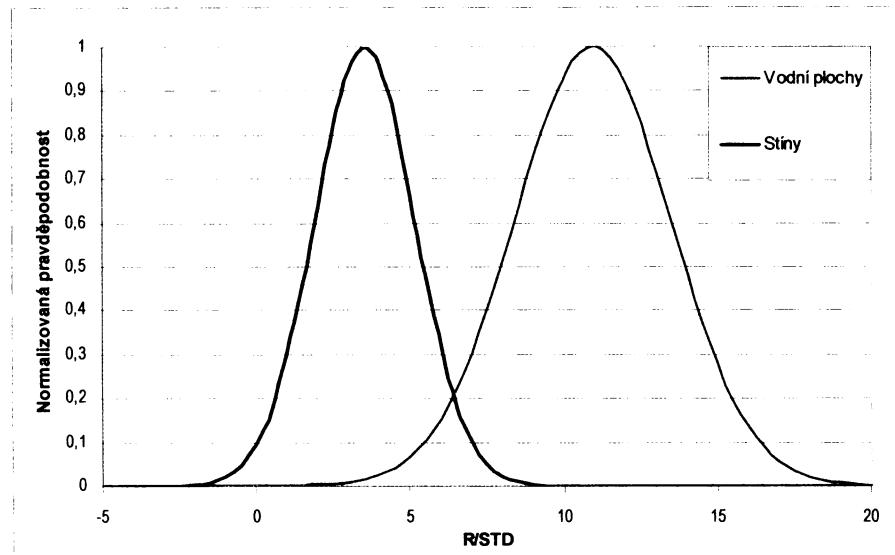
- Fuzifikace – je procedura, při které dochází k přiřazení hodnoty příslušnosti k fuzzy množině všem hodnotám příznaku. Hodnotám příznaku z normalizovaného souboru může být přiřazen stupeň příslušnosti k jedné nebo více fuzzy množinám (Zadeh, 1965). Na příkladu obr. 5.5 funkce příslušnosti lze fuzifikaci vysvětlit. Osa x reprezentuje část množiny hodnot objektového příznaku $eNDGI$. Osa y vyjadřuje stupeň příslušnosti k třídě stíny. Pro zjištěnou hodnotu příznaku objektu $eNDGI$ stanovíme hodnotu příslušnosti k dané třídě. Zároveň by však mohla být stejně hodnotě $eNDGI$ určena příslušnost 0,6 k jiné třídě. Stejným způsobem je hodnotám v celém rozsahu příznaku určena příslušnost k jedné nebo více třídám land cover.

Obr. 5.5 Funkce příslušnosti tvaru S



- Inference – je fází vytvoření fuzzy pravidel. Fuzzy pravidla jsou typu „*IF - THEN*“ (*JESTLIŽE - POTOM*). V první části pravidla je určena míra pravdivosti předpokladu a v druhé je určena funkce příslušnosti pro každé pravidlo. Tvar funkce příslušnosti popisuje závislost hodnot příslušnosti na odpovídajících hodnotách v ostré množině. Příklad tvaru „S“ funkce příslušnosti je na obrázku 5.5. Vhledem k tomu, že k přesnému popisu jedné třídy je často nutné použít více pravidel, je možné využít logických operátorů jako spojovacích výrazů (např. „*and (min)*“ a „*or (max)*“) (Zhang & Maxwell, 2006; Definiens AG, 2006).
- Defuzifikace – opak fuzifikace. Z hodnot příslušnosti objektu k jednotlivým třídám je získána jednoznačná hodnota zařazující objekt do jediné konkrétní třídy. V Definiens je defuzifikace aplikována jako přiřazení objektu do třídy land cover na základě nejvyšší hodnoty příslušnosti (Definiens AG, 2006).

Na příkladu třídy vodní plochy bude popsán průběh tvorby fuzzy pravidel, která byla aplikována při klasifikaci. V grafu 5.1 jsou zobrazeny funkce normalizovaného rozložení tréninkových objektů tříd vodní plochy a stíny. Každou z funkcí lze popsat střední hodnotou a rozptylem (resp. směrodatnou odchylkou).

Graf 5.1 Normalizovaná hustota pravděpodobnosti Gaussova rozložení – příznak R/STD 

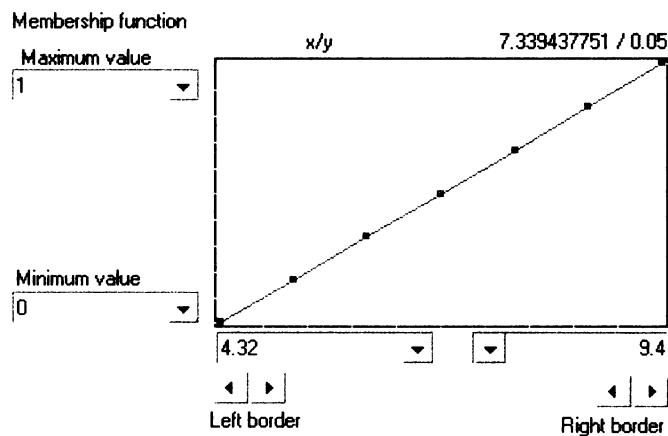
Podle tabulkových hodnot leží 99,73 % všech dat výběru ve vzdálenosti $\pm 3 \times$ směrodatná odchylka od střední hodnoty. Pro třídu vodní plochy je střední hodnota výběru pro příznak R/STD rovna 11,91. Po výpočtu lze tvrdit, že objekty z třídy vodní plochy nabývají hodnot příznaku R/STD 4,32 až 19,52 a použít tyto hodnoty jako ostré hranice třídy. Stejným způsobem vymezíme hranici třídy stíny <-0,34;9,40>.

Z překryvu obou množin i z překryvu v grafu je patrná neurčitost v určení obou tříd na intervalu <4,32;9,40>. Použijeme-li velmi jednoduchého pravidla: *JESTLI* na daném intervalu roste vzdálenost od střední hodnoty rozložení, *POTOM* klesá i hodnota příslušnosti k třídě získáme funkci příslušnosti. Z předdefinovaných funkcí v Definiens takovému pravidlu vyhovuje lineární funkce příslušnosti (viz obr. 5.6). Jako parametry funkce byly nastaveny hranice intervalu neurčitosti. Objektům s hodnotou menší než 4,32 bude přiřazena hodnota příslušnosti k třídě vody 0 a objektům s hodnotou příznaku větší než 9,40 bude určena příslušnost 1. Pomocí lineární funkce s opačnou orientací a stejnými parametry byla charakterizována třída stíny.

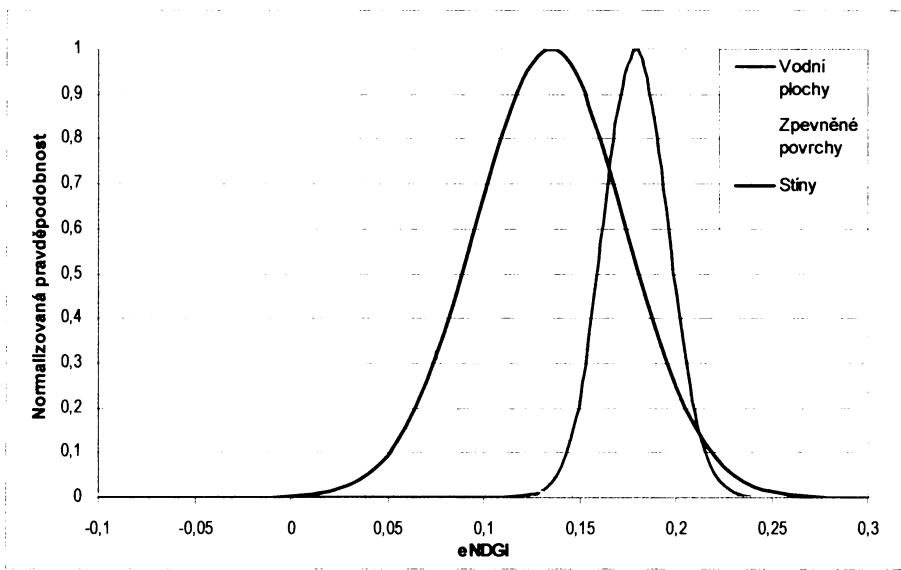
Následující pravidlo bylo použito pouze k oddělení vodních ploch a stínů od ostatních kategorií. Graf 5.2 znázorňuje funkce normálního rozložení tříd vodní plochy, stíny a zpevněné povrchy. Zpevněné povrhy jsou projevem nejbližší třídou pro tento příznak. Ostatní třídy dosahují v eNDGI větších záporných hodnot a nacházejí se mimo zobrazený rozsah eNDGI. Po výpočtu ze středních hodnot a směrodatných odchylek je

zřejmé, že rozsah neurčitosti je interval $<0,04;0,15>$. 0,15 je zároveň střední hodnotou třídy stíny a znamená, že objekty s příznakem $eNDGI$ větším než 0,15 jsou buď stíny nebo vodní plochy. Pro toto pravidlo byla zvolena funkce tvaru S respektující průběh funkce hustoty normálního rozložení (viz obr. 5.6).

Obr. 5.6 Lineárná funkce příslušnosti



Graf 5.2 Normalizovaná hustota pravděpodobnosti Gaussova rozložení – příznak $eNDGI$



Analogickým způsobem byly vytvořeny popisy všech tříd. Vedle vybraných spektrálních a texturálních příznaků byly do tvorby klasifikačních pravidel zahrnuty také kontextuální informace, především *Relativní hranice s třídou*, a geometrické vlastnosti objektů – velikost, pravidelný tvar, asymetrie a délka.

Výsledný klasifikační model byl vytvořen nad testovacím územím číslo 1. Přenositelnost celého modelu byla testována nad zbývajícími dvěma výřezy. Hodnocení tématické přesnosti bylo provedeno standardními statistickými metodami s využitím připravených referenčních dat (viz podkap. 5.2.3).

Kapitola 6

Výsledky

V předchozí kapitole byl charakterizován postup navržené metody výběru texturálních a spektrálních příznaků a strategie objektově orientované klasifikace. Následující dvě podkapitoly obsahují výsledky analýzy příznaků a vyhodnocení tématické přesnosti a přenositelnosti klasifikačního modelu.

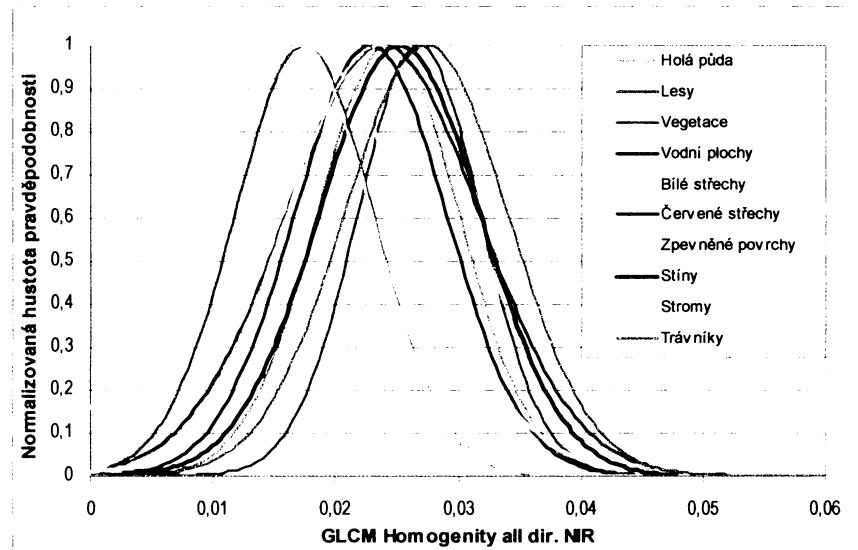
6.1 Zhodnocení výsledků analýzy příznaků

V prvním kroku statistického šetření bylo pro každý příznak provedeno porovnání tříd pomocí jednofaktorové analýzy rozptylu (ANOVA). Jako kvalitativní faktor byl uvažován popis třídy. Cílem analýzy bylo nalezení těch příznaků, které umožňují odlišení alespoň jedné ze tříd od ostatních. Kompletní tabelární výstupy jsou uvedeny v přílohách A.1 a A.2. Jako pomocný výstup pro hodnocení separability tříd byly vytvořeny grafy hustoty normálního rozložení (viz Přílohy B).

Tabulky analýzy rozptylu v přílohách A poskytují přehled o několika charakteristikách výběrů. U každého příznaku je celková variabilita rozdělena na dvě části. Variabilita mezi skupinami reprezentuje proměnlivost průměrů skupin (v tomto případě tříd) vzhledem k průměru celého souboru. Variabilita uvnitř skupin znamená proměnlivost hodnot objektových příznaků kolem průměru třídy. Pro hodnocení rozdílnosti tříd jsou však významnější hodnoty F-kritéria a Signifikance. Signifikance menší než 0,05 (pro hranici významnosti 95%) znamená zamítnutí nulové hypotézy o rovnosti průměrů jednotlivých skupin a rozdílnost alespoň jedné ze tříd od ostatních. Nulová hypotéza byla zamítnuta u všech příznaků (viz Přílohy A).

Absolutní velikost F-kritéria umožňuje vyhodnotit celkovou rozdílnost tříd v příznaku. Pořadí příznaků v tabulkách A.1 a A.2 je seřazeno sestupně podle F-kritéria. Při porovnání výsledků analýzy s grafy lze konstatovat, že existuje souvislost mezi hodnotou F-kritéria a separabilitou tříd. S rostoucími rozdíly mezi průměry tříd roste i hodnota F-kritéria. Nevýhodou je nemožnost popsání separability individuální třídy. F-kritérium tak slouží pouze jako indikátor variability tříd v příznaku.

Graf 6.1: Hustota pravděpodobnosti normálního rozložení tréninkových objektů – příznak
GLCM Homogeneity all dir. NIR

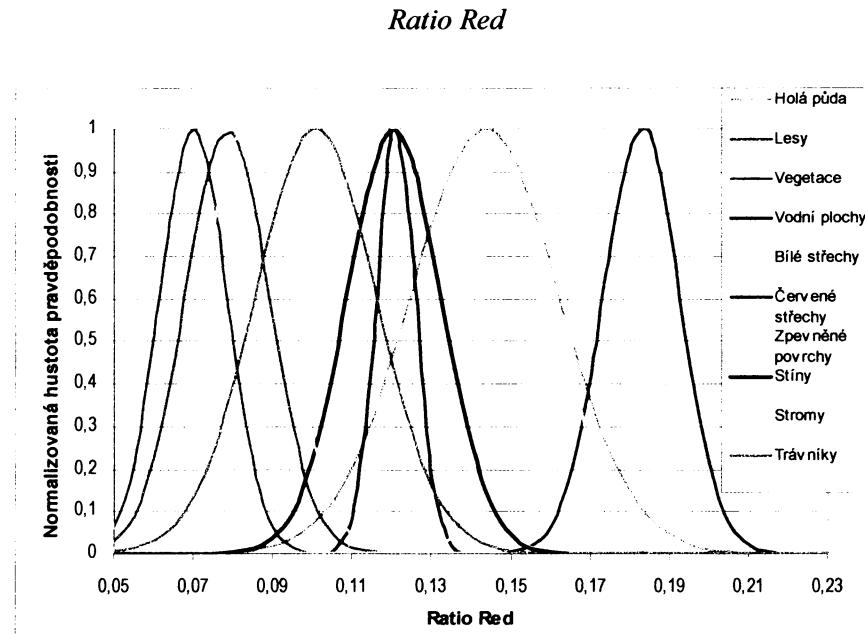


Grafy 6.1 a 6.2 reprezentují příznak s nejnižší, resp. nejvyšší hodnotou F-kritéria. Z grafu 6.1 je zřejmé, že střední hodnoty Gaussovy distribuce jednotlivých tříd jsou si velice blízké a třídy se vzájemně překrývají a jsou proto neodlišitelné s využitím *GLCM Homogeneity* ($F = 162$). Podobně nízkou rozdílností se projevují třídy také u všech hodnocených texturálních měr odvozených od *GLCM*, ale i standardních odchylek spektrálních pásem.

Naopak graf 6.2 ukazuje vysokou variabilitu tříd v příznaku *Ratio Red* ($F = 6672$). Na základě porovnání průběhu funkcí pravděpodobnosti lze poukázat na větší separabilitu vegetačních tříd od kategorie vodních ploch a stínů a kategorií umělých povrchů.

Po porovnání výsledků analýzy rozptylu s grafy hustoty normálního rozložení bylo rozhodnuto pro následující krok analýzy o vynechání těchto příznaků vykazujících nejmenší odlišitelnost tříd: všechny testované míry textury *GLCM*, příznaky *standardní odchylka Red, Blue, NIR a NDVI* a texturální příznak *Sum STD/Brightness*.

Graf 6.2: Hustota pravděpodobnosti normálního rozložení tréninkových objektů – příznak



V první fázi analýzy byl počet příznaků redukován. V druhé části byla pozornost zaměřena na nalezení objektových vlastností vhodných pro unikátní popis jednotlivých tříd a zároveň vykazujících stabilní hodnoty příznaků při změně lokality (tzn. nízké hodnoty F-kritéria). V tabulkách 6.1 – 6.3 jsou pro jednotlivé třídy uvedeny jak prostorově stabilní příznaky, tak příznaky s větší proměnlivostí, ale lepší odlišitelností tříd. Chybějící hodnota znamená, že příznak nebyl shledán pro třídu jako vhodný.

Tabulka 6.1 Vybrané příznaky tříd vodní plochy a stíny

ANOVA	Voda		Stíny		
	Příznak	F	Sig.	F	Sig.
<i>Ratio Red</i>	0,375	0,687	-	-	-
<i>B/STD</i>	30,237	0,000	10,154	0,000	
<i>R/STD</i>	50,156	0,000	7,219	0,001	
<i>eNDGI</i>	29,897	0,000	90,817	0,000	
<i>NDGI</i>	37,439	0,000	-	-	
<i>Brightness</i>	7,303	0,001	21,069	0,000	
<i>Mean Red</i>	4,120	0,018	-	-	
<i>Mean Blue</i>	3,976	0,020	-	-	
<i>Pan_BF</i>	115,077	0,000	2,982	0,053	
<i>eTCT1</i>	2,671	0,071	21,017	0,000	
<i>Zabud1</i>	6,641	0,002	-	-	
<i>NSTD</i>	-	-	4,333	0,014	
<i>TCT4</i>	-	-	0,500	0,607	

Zdroj: Vlastní výpočty

V následujícím hodnocení jsou příznaky rozděleny do skupin podle podobného spektrálního projevu. Jedním z problémů při klasifikaci VHR dat je velký výskyt stínů. Jejich spektrální chování v obrazových datech je velmi blízké vodním plochám. Při pohledu na grafy většiny příznaků je zřejmý překryv těchto dvou kategorií a relativně složitá možnost jejich vzájemného odlišení. V tabulce 6.1 je uveden přehled příznaků v nichž se projev tříd mírně liší a zároveň je u nich zjištěna dobrá prostorová stabilita mezi testovacími výřezy. S tímto tvrzením kontrastují hodnoty F-kritéria u příznaků *PAN_BF* a *eNDGI*. Pro oba příznaky nabývá jedna z tříd alespoň v jedné lokalitě vysoce extrémních hodnot (nejvyšší nebo nejnižší hodnoty z celého rozsahu příznaku), ale zároveň nedochází k překryvu s ostatními třídami. Krajních hodnot, ale se stabilnějším chováním dosahují obě třídy i u příznaků *Brightness* a *eTCTI* (viz Příloha B.2). Toho lze využít k odlišení třídy, resp. obou od všech ostatních. Pro vzájemné odlišení vodních ploch a stínů pak může být použit jeden z texturálních prvků, *R/STD*, *B/STD*, *PAN_BF* nebo jejich kombinace. Vodní plochy se na rozdíl od stínů projevují více homogenně. Stíny se sice jeví na první pohled podobně, ale radiometrická rozlišovací schopnost družice IKONOS 11 bitů umožňuje rozlišit více úrovní šedi a pořídit informaci o objektech ve stínu. Důsledkem je větší heterogenita třídy stíny.

Pro vytvoření pravidel a následnou klasifikaci land cover byly použity prvky *Brightness* a *eNDGI* za účelem odlišení obou kategorií od ostatních tříd a *PAN_BF*, *R/STD* a *B/STD* pro vzájemné odlišení tříd stíny a vodní plochy.

Tabulka 6.2 zastupuje povrchy pokryté vegetací. K odlišení vegetace existuje velké množství indexů, které jsou navrženy buď k detekci vegetace nebo k získání informace o jejich struktuře (Liang, 2004). Největší separabilitu všech tříd vegetace od ostatních povrchů vykazuje stejně ve všech lokalitách normalizovaný vegetační index *NDVI 100* poskytující informace o množství zelené biomasy a obsahu chlorofylu. Jako zásadní se pro následující klasifikační proces ukázal být příznak *PAN_BF* (viz Příloha B.1). Pouze za použití jednoduché prahové hodnoty lze rozdělit vegetaci ve snímku na texturovanou a netexturovanou. Výsledek analýzy rozptylu (viz tabulka 6.2) potvrzuje za statisticky stabilní tento příznak pouze pro stromy a trávníky. Relativně větší variabilita u lesů a vegetace je však způsobena širší definicí těchto tříd. V kategorii les lze nalézt lesy listnaté, jehličnaté i smíšené, jež se projevují mírně odlišnými spektrálními vlastnostmi. Podobně zahrnuje třída vegetace trvalé travní porosty a různé

zemědělské plodiny na orné půdě. I když byly tréninkové objekty vybírány se snahou o rovnoměrné zastoupení mohlo dojít k převážení některého z podtypů v jedné z lokalit a tím ovlivnění celé stability příznaku. Vliv širší definice třídy byl zaznamenán pomocí Levenova testu. Z důvodu nehomogenity rozptylů tříd byl použit pro třídy vegetace a les Brown-Forsytheův test rovnosti průměrů.

Tabulka 6.2 Vybrané příznaky tříd lesy, stromy, vegetace a trávníky

ANOVA	Lesy		Stromy		Trávníky		Vegetace	
	Příznak	F	Sig.	F	Sig.	F	Sig.	F
B/STD	-	-	0,334	0,716	3,181	0,044	-	-
<i>Brightness</i>	20,278	0,000	4,045	0,019	-	-	-	-
eNDGI	-	-	-	-	-	-	17,990	0,000
eTCT1	5,701	0,003	3,990	0,020	8,643	0,000	-	-
Mean Blue	-	-	0,429	0,651	-	-	-	-
Mean NDVI100	27,456	0,000	2,442	0,089	31,719	0,000	10,049	0,000
Mean NIR	-	-	5,467	0,005	-	-	20,687	0,000
Mean Red	-	-	3,553	0,030	-	-	-	-
N/STD	10,871	0,000	2,163	0,117	2,646	0,074	-	-
NDGI	-	-	9,055	0,000	-	-	9,110	0,000
Pan_BF	21,393	0,000	6,106	0,003	1,604	0,204	57,668	0,000
R/STD	-	-	0,191	0,826	5,374	0,005	-	-
Ratio Red	-	-	2,470	0,086	-	-	-	-
RVI	773,437	0,000	2,911	0,056	-	-	7,875	0,000
TCT1	14,220	0,000	4,186	0,016	-	-	-	-
TCT2	-	-	5,343	0,005	-	-	12,385	0,000
TCT3	-	-	3,462	0,033	-	-	-	-
TCT4	-	-	-	-	5,975	0,003	-	-
Zabud1	-	-	5,310	0,005	-	-	10,134	0,000

Pozn.: Pro lesy a vegetaci uvedené hodnoty reprezentují výsledky Brown-Forsytheova testu, pro lesy a stromy výsledky analýzy rozptylu (ANOVA). Šedě jsou zvýrazněny příznaky použité při klasifikaci.

Zdroj: Vlastní výpočty

Pro obě kategorie reprezentující vegetaci v zastavěných územích lze nalézt více statisticky stabilních příznaků. V absolutních hodnotách se kritériu stability velmi přibližují i příznaky tříd les (s vyjímkou vegetačního indexu *RVI*) a vegetace.

Vliv definice třídy je nutné vzít v potaz při celkovém hodnocení výsledků analýzy rozptylu. Účelem zařazení více podtypů do jedné kategorie land coveru byla snaha o použití menšího počtu tříd pro odmaskování části nezastavěného území, na které nebyla při klasifikaci soustředěna hlavní pozornost. Pro sestavení popisu vegetačních tříd byl vybrán vegetační index *NDVI 100* a texturální prvek *PAN_BF*. Pro

konečné odlišení vegetace v zástavbě a mimo zastavěné území bylo použito kontextuálního příznaku sousedství s budovami nebo zpevněnými povrchy.

Tabulka 6.3 Vybrané příznaky tříd holá půda, světlé a červené střechy a zpevněné povrchy

ANOVA	Holá půda		Světlé střechy		Červené střechy		Zpevněné povrchy	
Příznak	F	Sig.	F	Sig.	F	Sig.	F	Sig.
eNDGI	10,006	0,000	-	-	-	-	94,038	0,000
NDGI	16,073	0,000	-	-	-	-	-	-
Pan_BF	11,766	0,000	-	-	-	-	0,288	0,750
NDBI	1,339	0,264	-	-	-	-	112,731	0,000
TCT3	39,013	0,000	-	-	6,786	0,001	19,385	0,000
Ratio Red	-	-	47,709	0,000	30,277	0,000	-	-
Brightness	-	-	31,137	0,000	-	-	-	-
Mean NDVI100	-	-	35,995	0,000	-	-	-	-
eTCT1	-	-	28,624	0,000	0,159	0,853	-	-
TCT4	-	-	1,639	0,196	16,836	0,000	-	-
Mean Red	-	-	-	-	2,804	0,063	-	-
Ratio Blue	-	-	-	-	-	-	79,719	0,000
NSTD	-	-	-	-	-	-	1,932	0,146

Pozn.: Pro zpevněné povrchy a světlé střechy výsledné hodnoty reprezentují výsledky Brown-Forsytheova testu, pro ostatní třídy (ANOVA). Šedě jsou zvýrazněny příznaky použité při klasifikaci.

Zdroj: Vlastní výpočty

Třetí skupinou podobně spektrálně projevujících se tříd jsou holá půda, budovy se světlými a červenými střechami a zpevněné povrchy. Tabulka 6.3 reprezentuje vybrané příznaky pro tyto třídy. Z výsledků analýzy rozptylu lze konstatovat absolutní statisticky podloženou stabilitu jen u příznaků se signifikancí vyšší než 0,05.

Podobně jako stíny a vodní plochy dosahují krajních hodnot příznaků Brightness, resp. eTCT1 třídy světlé střechy a holá půda. Prvek Brightness reprezentuje průměr ze středních spektrálních hodnot objektů. Světlé střechy často představují materiály typu plechu, které se projevují jako dobrý odražeč především v pásmech Red, Green a Blue. Proto nabývají velmi vysokých hodnot. V závislosti na složení půd a vlhkostních podmínkách dosahuje vysokých hodnot i holá půda. Jejich rozlišení dovoluje použití texturálního příznaku PAN_BF. Rozdíly mezi oběma třídami jsou malé, proto může při klasifikaci docházet k jejich chybnému zařazení.

Problémem je také odlišení červených střech od holé půdy a ostatních zpevněných materiálů ve spektrálním pásmu Red. Separaci těchto tříd umožňují TCT3 a TCT4. Červené střechy odrážejí relativně méně v modrému pásmu v porovnání

s umělými povrhy. Z konstrukce výpočtu *TCT3*, kdy je od DN hodnoty v červeném pásmu odečtena DN hodnota v modrém pásmu, pak vyplývá možnost zvýraznění červených střech. Podobně je vliv odrazivosti v červeném pásmu zvýrazněn při výpočtu transformace *TCT4*.

U zpevněných povrchů lze obecně zaznamenat větší variabilitu uvnitř třídy. Přičinou je výskyt velkého množství materiálů a vysoká frekvence změn velikosti, tvaru a struktury materiálů v zástavbě. Proto je velmi těžké je odlišit od okolních povrchů. Tuto vlastnost je možné zobecnit na celá sídla a využít ji pro detekci zastavěných území. Texturální prvek vyjadřující právě frekvenci výskytu hran je velmi vhodný a zároveň stabilní pro odlišení složitého prostředí zástavby (De Kok, 2003). Postupným odmaskováním budov se světlými střechami pomocí *eTCT1* resp. *Brightness* a budov s červenými střechami s využitím *TCT3* a *TCT4* ve spojení s tvarovými příznaky lze získat třídu zahrnující ostatní zpevněné povrhy.

Z výsledků analýzy rozptylu lze poukázat na obecně vyšší prostorovou stabilitu texturálních příznaků. Zároveň je nutné podotknout, že prostorová stabilita neznamená automaticky vhodnost příznaku pro odlišení tříd. Podobně lze hodnotit spektrální příznaky. Jednou z domněnek před začátkem analýzy byl předpoklad rozdílné přenositelnosti spektrálních příznaků v závislosti na způsobu jejich výpočtu. Z vybraných příznaků pro sestavení klasifikačních pravidel je zřejmé, že absolutní spektrální příznaky jsou z hlediska přenositelnosti méně vhodné než ostatní spektrální příznaky. Mezi poměrovými a transformovanými spektrálními příznaky nelze pozorovat významné rozdíly.

6.2 Zhodnocení tématické přesnosti klasifikace a přenositelnosti klasifikačního modelu

Hlavním výstupem z klasifikace jsou tématické mapy land cover pro všechna tři testovací území a mapy vymezení zastavěného území (viz Příloha C). Hodnocení tématické přesnosti bylo provedeno na základě porovnání výsledných rastrů s připravenými referenčními daty (viz podkap. 5.2.3). Statistické vyjádření úspěšnosti klasifikací poskytují tabulky 6.4 až 6.6.

Při porovnání celkové přesnosti a kappa indexu lze konstatovat, podobnou úspěšnost klasifikace na prvních dvou výřezech (Celková přesnost - 95,1% a 92,1%) a mnohem horší na třetí venkovské lokalitě (76,8%). V maticích se vyskytují dva další ukazatele. Tématickou správnost jednotlivých tříd popisuje přesnost zpracovatele a uživatele. Přesnost uživatele je spočtena jako podíl správně zařazených pixelů a celkového počtu pixelů zařazených do dané třídy. Naopak přesnost zpracovatele udává procentuální podíl správně klasifikovaných pixelů na počtu všech pixelů klasifikovaných do dané třídy.

Tabulka 6.4 Chybová matice klasifikace land cover – lokalita 1

Lokalita 1	Referenční data											Suma	PU (%)
	Klasifikovaná data	Červ. střechy	Bilé střechy	Zpev. Povrchy	Stromy	Trávníky	Lesy	Vegetace	Vodní plochy	Holá půda	Stíny		
Červ. střechy	45394	0	4214	126	0	0	0	0	0	0	2673	52407	86,6
Bilé střechy	0	165564	5538	0	0	0	0	0	0	325	8911	180338	91,8
Zpev. Povrchy	17945	30634	327258	20542	0	0	12124	0	10478	12563	431544	75,8	
Stromy	2412	0	8564	253062	10316	10797	3412	0	0	2245	290808	87,0	
Trávníky	126	0	0	1348	174896	1957	29688	0	0	1591	209606	83,4	
Lesy	450	0	0	19788	144	1533269	47961	2560	653	0	1604825	95,5	
Vegetace	0	0	0	531	2563	32149	5651236	0	94563	0	5781042	97,8	
Vodní plochy	0	0	8423	0	0	1563	0	301613	0	8623	320222	94,2	
Holá půda	0	4202	9568	0	245	0	27260	0	743257	0	784532	94,7	
Stíny	2523	3913	15680	5463	1185	0	0	1025	0	213756	243545	87,8	
Suma	68850	204313	379245	300860	189349	1579735	5771681	305198	849276	250362	9898869		
PZ (%)	65,9	81,0	86,3	84,1	92,4	97,1	97,9	98,8	87,5	85,4			
PU - přesnost uživatele; PZ - přesnost zpracovatele				Celková přesnost = 95,1 %				Kappa = 0,918					

Zdroj: Hodnocení přesnosti klasifikace z Definiens

Při podrobnějším rozboru chybových matic jsou zřejmě rozdíly mezi jednotlivými kategoriemi. Na prvních dvou lokalitách byly velmi přesně klasifikovány všechny vegetační kategorie, vodní plochy ale i stíny. Zřejmě je špatné zařazení budov s červenými i světlými střechami do kategorie zpevněných povrchů. Příčinou je pravděpodobně chybná segmentace střech. Při popisu třídy budov je jedním z rozhodovacích pravidel pravidelný tvar objektu. Okolní vegetace nebo cizí objekty na střechách působí heterogenně a můžou zapříčinit nepravidelný tvar výsledného segmentu. Frekventovanou záměnou je zařazení zpevněných povrchů a budov se světlými střechami do třídy holá půda. Příčinou je spektrální podobnost tříd (viz podkap. 6.1).

Poměrně dobře jsou odlišeny stíny a vodní plochy. Nižší přesnost uživatele je způsobena nadhodnocením obou kategorií na úkor zpevněných povrchů. Některé materiály (např. asfalt) používané na střechy nebo silnice se projevují podobně a často proto dochází k záměně.

Tabulka 6.5 Chybová matice klasifikace land cover – lokalita 2

Lokalita 2	Referenční data										Suma	PU (%)
	Červ. střechy	Bílé střechy	Zpev. Povrchy	Stromy	Trávníky	Lesy	Vegetace	Vodní plochy	Holá půda	Stíny		
Červ. střechy	18930	0	405	0	0	0	0	0	0	0	19335	97,9
Bílé střechy	0	55188	1179	0	0	0	0	0	0	0	56367	97,9
Zpev. Povrchy	6547	5211	100693	2874	0	0	1735	128	8954	10437	136579	73,7
Stromy	1236	0	0	69834	0	1932	0	0	0	579	73581	94,9
Trávníky	0	0	0	0	35698	0	563	0	753	215	37229	95,9
Lesy	0	0	0	6596	0	125365	15987	1453	4608	0	154009	81,4
Vegetace	0	0	0	0	106	10716	1150389	0	43562	0	1204773	95,5
Vodní plochy	0	0	4873	0	0	2036	0	100538	0	356	107803	93,3
Holá půda	0	3489	5647	0	0	0	23965	0	354012	0	387113	91,4
Stíny	347	1271	7604	1214	0	115	0	3006	0	75814	89371	84,8
Suma	27060	65159	120401	80518	35804	140164	1192639	105125	411889	87401	2266160	
PZ (%)	70,0	84,7	83,6	86,7	99,7	89,4	96,5	95,6	85,9	86,7		
PU - přesnost uživatele; PZ - přesnost zpracovatele				Celková přesnost = 92,1 %				Kappa = 0,894				

Zdroj: Hodnocení přesnosti klasifikace z Definiens

Ukazatelem svědčícím o nezávislosti referenčních dat je chybné zařazení objektů vzájemně si odpovídajících tříd mezi sebou, např. světlé střechy a stíny nebo zpevněné povrchy a stromy. Často používanou metodou sběru referenčních dat pro hodnocení přesnosti je manuální klasifikace objektů. Při tomto způsobu bývá výsledek klasifikace často nadhodnocen (van der Sande, 2003). Při klasifikaci jsou zařazovány do tříd celé objekty. I když je objekt klasifikován správně, nemusí jeho hranice respektovat hranici skutečných objektů (např. střechy). Při tvorbě nezávislých referenčních dat vizuální interpretací odpovídají výsledné vektory hranici skutečných objektů a přesahující část obrazového segmentu je správně vyhodnocena jako chyba.

Při porovnání dosažených výsledků v prvních dvou lokalitách s třetím testovacím územím je zřejmá špatná detekce objektů rozptýlené zástavby ve třetí lokalitě. Zejména při vizuální kontrole výsledků je patrné podhodnocení budov. Tomu odpovídá nízká zpracovatelská přesnost červených střech. Extrémně nízká přesnost uživatele (11 %) světlých střech je způsobena malým výskytem tréninkových objektů v lokalitě a zařazením velké plochy místního lomu do této třídy. S podhodnocením

objektů zástavby souvisí špatné určení vegetace v zástavbě pomocí kontextuálního pravidla založeného na sousedství budov a vegetace.

Vedle celkové tématické přesnosti land cover je pro účely sledování sídel důležitým ukazatelem také tématická přesnost tříd zástavby. Pro třídy vyskytující se v zastavěném území je výsledná přesnost zpracovatele, resp. uživatele 84 a 85 % pro první lokalitu a 86 a 86 % pro lokalitu číslo 2. Při porovnání výsledků klasifikace s předem vytvořenou maskou měst Kolína a Kutně Hory dosahuje celková přesnost v obou lokalitách dokonce 95 %. V případě města Kolín byla hranice města výrazněji nadhodnocena vzhledem k třídě les, v případě Kutně hory byla chyba rozložena mezi více tříd.

Tabulka 6.6 Chybová matice klasifikace land cover – lokalita 3

Lokalita 3	Referenční data											Suma	PU (%)
	Červ. střechy	Bilé střechy	Zpev. Povrchy	Stromy	Trávníky	Lesy	Vegetace	Vodní plochy	Holá půda	Stíny			
Červ. střechy	10544	0	0	0	0	0	0	0	0	0	0	10544	100,0
Bilé střechy	0	1856	0	0	0	0	1569	0	12586	0	0	16011	11,6
Zpev. Povrchy	3540	425	65125	0	0	0	423	0	8003	1150	78666	82,8	
Stromy	1565	0	0	20263	0	0	0	0	661	746	23235	87,2	
Trávníky	0	0	0	0	6942	0	0	0	0	0	0	6942	100,0
Lesy	8563	0	12569	15689	5645	75633	16786	778	2838	543	139044	54,4	
Vegetace	0	0	0	0	0	11252	103694	0	16995	0	131941	78,6	
Vodní plochy	0	0	0	0	0	314	0	75632	0	0	75946	99,6	
Holá půda	0	0	1986	0	0	320	11291	0	89364	0	102960	86,8	
Stíny	0	0	365	0	0	0	0	125	0	2367	2857	82,8	
Suma	24212	2281	80045	35952	12587	87519	133763	76535	130447	4806	588147		
PZ (%)	43,5	81,4	81,4	56,4	55,2	86,4	77,5	98,8	68,5	49,3			
PU - přesnost uživatele; PZ - přesnost zpracovatele	Celková přesnost = 76,8 %										Kappa = 0,732		

Zdroj: Hodnocení přesnosti klasifikace z Definiens

Z hodnocení tématické přesnosti v lokalitách z různým charakterem krajiny vyplývá, že vytvořený model lze považovat za přenositelný pouze při detekci měst a sídel střední velikosti vyznačujících se kompaktní strukturou a vyšším podílem zpevněných povrchů. Výsledek na lokalitě číslo 3 prokázal neúčinnost klasifikačního modelu při určování extrémně rozptýlené zástavby. Při klasifikaci struktury land coveru sídel lze jako úspěšnou považovat pouze odlišení zpevněných povrchů od vegetace v zástavbě.

Kapitola 7

Diskuse použitých metod, dat, výsledků a jejich uplatnění

Hlavním cílem této práce bylo vytvoření metody umožňující získání dostatečné informace o obrazových objektech a jejich vlastnostech pro vytvoření přenositelného klasifikačního modelu zastavěných území. Z dřívějších prací je zřejmé, že hledání parametrů segmentace a klasifikace je v prostředí Definiens velmi časově náročné a nepřehledné (Schiewe et al., 2001; Kopalová, 2007). Vzhledem k tomu, že téma hledání optimálních segmentačních nastavení je věnována obrovská pozornost (Zhang & Maxwell, 2006; Bauer & Yuan, 2006; Jupová, 2007 aj.), byl v této práci kladen důraz na nalezení přenositelných parametrů klasifikace.

Přenositelnost objektových (spektrálních a texturálních) příznaků byla zkoumána na třech charakterově odlišných testovacích územích v rámci jedné scény. Zvolenou metodou pro hodnocení přenositelnosti příznaků byla jednofaktorová analýza rozptylu výběrů tréninkových objektů (ANOVA). ANOVA na rozdíl od např. párového T-testu umožňuje porovnávat více výběrových souborů (Anděl, 1978) a zkoumá závislost výběrových souborů (příznaky třídy) na kvalitativním faktoru (typ lokality). Analýza rozptylu předpokládá podobnost výběrových souborů. Průběh samotné analýzy a doplňkové testy homogenity rozptylů (Levenův) a shodnosti průměrů (Brown-Forsytheův) umožnily posoudit prostorovou stabilitu příznaků, ale poukázaly také na fakt, že příznaky některých tříd vykazují vysokou vnitřní variabilitu nevhodnou pro analýzu rozptylu. Velký podíl na tom měla i široká definice některých tříd (vegetace, les, zpevněné povrchy). Vyřešení tohoto problému by pomohlo definování většího počtu přesněji vymezených kategorií land cover nebo využití některého z robustních neparametrických testů výběrů, nevyžadujících tak striktní podmínky jako analýza rozptylu (např. Kruskal-Wallisův).

Nevýhodou zvolené analýzy rozptylu je nemožnost přímého vyjádření separability jednotlivých tříd. Pro tento účel se jako vhodný nástroj ukázaly být grafy hustoty pravděpodobnosti jednotlivých tříd a dvouozměrných rozptylogramů. Především kombinace grafů a výsledků analýzy umožnila poměrně rychlý výběr příznaků vhodných pro popis klasifikovaných tříd.

Možnost využití grafů hustoty pravděpodobnosti a jejich charakteristik pomohla také jednoduchému a přehlednému postupu při tvorbě klasifikačních fuzzy pravidel. Metoda externího určení parametrů funkcí příslušnosti pomocí funkcí hustoty pravděpodobnosti je jedním z použitelných statistických způsobů (Brodský & Borůvka, 2006). Další výzkum by se mohl soustředit na porovnání různých přístupů ke stanovení fuzzy funkcí příslušnosti.

Přenositelnost vytvořeného klasifikačního modelu byla posléze otestována na třech výrezech scény. Použitá strategie hierarchické klasifikace a tří segmentačních úrovní odpovídá obvyklým přístupům ke klasifikaci zastavěných území (Gu, Chen, Zhou, 2005; Hofmann et al., 2006). Výsledky poukázaly na dobrou přenositelnost klasifikačního modelu pro účely vymezení zastavěných území s kompaktní strukturou. Při klasifikaci rozptýlené zástavby se však vyskytly problémy s extrakcí budov. Detekce takových území je velmi složitá a vyžaduje podrobnější segmentaci a znalost kontextuálních vlastností (Hofmann et al., 2006). V rámci analýzy byl zkoumán široký soubor spektrálních a texturálních příznaků. Navazující práce by se mohla zaměřit na detailní studium kontextuálních a geometrických příznaků popisujících vnitřní prostorovou strukturu zastavěných území.

Kontextuální informace je do jisté míry závislá na úspěšnosti segmentace. Tvar hranice výsledných segmentů může ovlivňovat některé topologické příznaky (Hofmann et al., 2001). Podobně jako u Kopalové (2007) byl zaznamenán největší problém při segmentaci objektů reprezentujících budovy. Řešení tohoto problému lze najít ve využití dat z různých zdrojů, např. výšková data z laserového skenování (Walter, 2004). Údaje o výšce by pomohly k přesnějšímu odlišení budov od ostatních zpevněných povrchů. Užitečné by mohlo být i zahrnutí vektorových dat z katastrální mapy do analýzy obrazu (Bauer & Steinhöcher, 2001).

Celkově lze zvolenou metodu i přes zmíněné nedostatky považovat za přehledný, rychlý a jednoduchý způsob nalezení důležitých parametrů pro sestavení klasifikačního modelu. Výsledný klasifikační model lze vzhledem k nedostatečnému vymezení tříd použít pouze pro detekci měst a sledování změn v suburbánních zónách, jako je např. rozšiřování zastavěných území. Při podrobnějším vymezení tříd povrchů

v zástavbě by bylo možné takový model použít i pro sledování struktury sídel a mapování land use.

Možnou aplikací je také využití pro účely mapování nepropustných povrchů. Výstup z klasifikace je možné vyexportovat ve vektorovém formátu a okamžitě ji použít jako vrstvu v GIS, například v hydrologickém modelování.

7.1 Použitá data

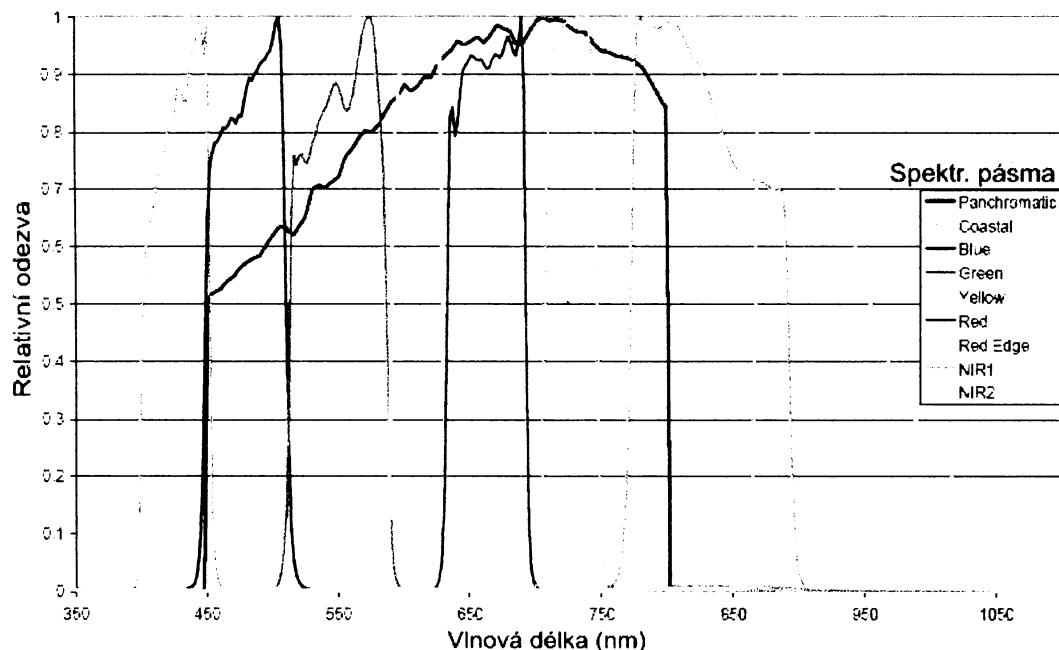
V této práci byla použita 1-metrová pansharpovalaná data družice IKONOS. Data vyhovují svým prostorovým rozlišením mapování složitých prostředí jako je struktura zastavěných území (De Kok et al., 2003). Ve smyslu prostorového rozlišení jsou k dispozici detailnější pouze data družice QuickBird. Podobně zaměřené studie však neprokazují významné rozdíly v úspěšnosti klasifikace mezi 1-metrovými daty IKONOS a 60-centimetrovými daty QuickBird. Zásadní rozdíly při klasifikaci nebyly dokonce shledány ani při použití multispektrálních (4 m) a pansharpovalých dat (1 m) (Hájek, 2005). Význam pansharpovalých dat tak lze spatřovat především při segmentaci.

Částečným omezením je spektrální rozlišení IKONOSu (Herold et al., 2002). Čtyři spektrální pásma neumožňují odlišení mnoha povrchů. Velmi často jsou proto využívána i v kombinaci s daty SPOT-5 (Gu, Chen, Zhou, 2005). Perspektivou v otázce spektrálního rozlišení jsou dva plánované satelity s velmi vysokým prostorovým rozlišením (WorldView-1 a WorldView-2). WV-1 bude poskytovat obrazová data s velikostí pixelu 50 cm v panchromatickém módu a WV-2 navíc i v multispektrálním s rozlišením 1,8 m. WorldView-2 bude pořizovat multispektrální snímky ve čtyřech standardních a ve čtyřech nových spektrálních pásmech (viz obr. 7.1). WV-2 by tak mohlo umožnit detailnější rozlišení různých materiálů.

Vedle optických a laserových dat by v budoucnu mohla být využita i radarová data s velmi vysokým rozlišením. V tomto roce vypuštěná družice TerraSAR-X bude poskytovat data s prostorovým rozlišením až 1 m. Jak doslova tvrdí Esch, Roth, Dech (2005, s.4): „*Vzhledem k vysokému prostorovému rozlišení v kombinaci se silnou závislostí zpětného radarového odrazu na geometrických podmínkách osvětleného povrchu, skrývají radarová data s velmi vysokým prostorovým rozlišením určitý*

potenciál pro analýzu strukturálních charakteristik urbanizovaných území." Tento potenciál lze spatřovat především ve využití při segmentaci prostředí zástavby. Pomocí radarových dat by mohly být zvýrazněny např. hrany budov. Vzhledem k plánovanému startu druhého radarové družice je perspektivní i využití radarové interferometrie pro zisk informace o výškách v území.

Obr. 7.1 Relativní odezva WorldView-2



Zdroj: DigitalGlobe (2007)

Kapitola 8

Závěr

Tématem této práce bylo využití objektově orientované klasifikace satelitních snímků s velmi vysokým prostorovým rozlišením pro vymezení a mapování land coveru zastavěných území. Objektová klasifikace byla provedena v softwaru Definiens Professional s využitím pancharpovaných snímků družice IKONOS. Určování parametrů obrazové segmentace a klasifikace je v prostředí Definiens obvykle prováděno manuálním způsobem a je velmi časově náročné. Hlavním vytvořeným úkolem magisterské práce, proto bylo nalezení nebo vytvoření metody maximálně automatizovaného výběru objektových příznaků a způsobu určení parametrů funkcí příslušnosti. Při výběru objektových příznaků měl být kladen důraz na jejich přenositelnost.

V průběhu samotné práce byly nejprve představeny hlavní současně pohyby v prostředí sídel a jejich vliv na sociální podmínky a životní prostředí. V teoretické rovině byly také charakterizovány běžně používané nástroje pro usměrňování územního rozvoje sídel. Dále byla stručně vystížena objektově orientovaná analýza obrazu. V další části byla popsána navržená metoda určování parametrů klasifikačního modelu. Její princip je založen na analýze příznaků tříd a jejich proměnlivosti v závislosti na změně klasifikovaného území. Pro testování prostorové variability příznaků byly zvoleny tři typově odlišné oblasti.

Výhodou navržené metody je rychlé nalezení prahových hodnot a příznaků vhodných pro odlišení jednotlivých tříd. Za přednost lze považovat možnost otestování přenositelnosti objektových příznaků (tedy části klasifikačního modelu) ještě před provedením klasifikace. Kladem prezentované metody je i možnost určení parametrů funkcí příslušnosti poloautomatickým způsobem a použití jako vhodného nástroje při sestavování klasifikačního modelu. Přenositelnost a tématická přesnost sestaveného klasifikačního modelu byly testovány standardními prostředky. Z výsledků je zřejmá využitelnost prezentované metodiky pro sledování plošného rozvoje zastavěných území nebo mapování životního prostředí.

Vzhledem k tomu, že v předložené práci je provedena klasifikace land coveru, bylo by vhodné navázat na tuto práci klasifikací land use sídel. Ta by rozšířila využití stávající metody v aplikacích typu územního plánování, jež vyžadují informaci o funkčním využití ploch.

Použité zdroje:

- ADAMS, D.** *Urban planning and the development process*. London : University College London Press, 1994. 248 s. ISBN 1-85728-022-9.
- ANDĚL, J.** Matematická statistika. Praha: SNTL, 1978. ISBN 99-00-00150-X.
- BAATZ, M., SCHÄPE, A.** Multiresolution segmentation - an optimization approach for high quality multi-scale image segmentation. In *Angewandte geographische Informationsverarbeitung XII: Beiträge zum AGIT-Symposium Salzburg*. Salzburg, 2000. s. 12-23.
- BENZ, U.C., et al.** Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2004, vol. 58, no. 3-4, s. 239-258.
- BLASCHKE, T., STROBL, J.** What's wrong with pixels? *Some recent developments interfacing remote sensing and GIS*. GeoBIT/GIS. 2001, no. 6, s. 12-17.
- BRODSKÝ, L., BORŮVKA, L.** Object-oriented fuzzy analysis of remote sensing data for bare soil. *Water and Soil Research*. 2006, vol. 1, no. 3, s. 79-84. Dostupné z www: <http://www.cazv.cz/userfiles/File/SWR%201_79-84.pdf>.
- BRODSKÝ, L., SOUKUP,T.** Objektově orientovaná fuzzy klasifikace krajinného pokryvu (land cover) se zaměřením na zemědělskou krajinu. In *Sborník sympozia GIS Ostrava 2007*, Ostrava, ČR, 2007. s.6.
- CLARK, D.** *Urban World/Global City*. London : Routledge, 1996. 211 s. ISBN 0 415 14437 X.
- CRIST, E.P., CICONE, R.C.** A physically-based transformation of thematic mapper data - the TM tasseled cap. *IEEE Transactions on Geoscience and Remote Sensing*. 1984, vol. 22, no. 3, s. 256-263.
- DE KOK, R., et al.** Analysis of urban structure and development applying procedures for automatic mapping of large area data.. In CARSTENS, J. *Remote Sensing of Urban Areas 2003*. Regensburg : ISPRS, 2003. s. 5. ISSN 1682-1777.
- DOBROVOLNÝ, P.** *Dálkový průzkum Země : Digitální zpracování obrazu*. 1. vyd. Brno : Masarykova univerzita v Brně, 1998. 210 s. ISBN 80-210-1812-7.

DOBROVOLNÝ, P., GOLÁŇ, J. Monitorování územního rozvoje města Třebíč s využitím leteckých snímků. In *Sborník příspěvků z konference GIS... Ostrava 2000*. Ostrava : VŠB - TU Ostrava, 2000. s. 6. Dostupný z WWW: <http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2000/Sbornik/Dobrovolny/Referat.htm>.

DONNAY, J.-P., BARNSLEY, M. J., LONGLEY, P. A. *Remote Sensing and Urban Analysis*. 1st edition. London : Taylor & Francis, 2001. 268 s. GISDATA; sv. 9. ISBN 0-7484-0860-6.

ESCH, T., ROTH, A., DECH, S. Robust approach towards an automated detection of built-up areas from high resolution radar imagery. In *Proceedings of the ISPRS WG VII/1 "Human Settlements and Impact Analysis" 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) and 5th International Symposium Remote Sensing of Urban Areas (URS 2005)*. Tempe, AZ, USA, 2005. s. 6.

GU, J., CHEN, J., ZHOU, Q. A Hierarchical Object-Oriented Approach for Extracting Residential Areas from High Resolution Imagery. In *IPSRS Hannover Workshop: High Resolution Earth Imaging for Geospatial Information : Proceedings*. Hannover : ISPRS, 2005. s. 6. Dostupné z www: <<http://www.ipi.uni-hannover.de/html/publikationen/2005/workshop/060-gu.pdf>>.

HÁJEK, F. Object-oriented classification of remote sensing data for the identification of tree species composition. In *Proceedings of ForestSat 2005 conference, May 31 - June 3*. Boras, Sweden, 2005. s. 6.

HALOUNOVÁ, L., KOLÁŘ, J., PAVELKA, K. *Dálkový průzkum země 10*. 1. vyd. Praha : Vydavatelství ČVUT, 1997. 164 s. ISBN 80-01-01567-X.

HALOUNOVÁ, L.: Zkušenosti s programem eCognition pro klasifikaci urbanizovaného území z leteckých černobílých snímků a snímků (TM). In *Sborník příspěvků z konference GIS... Ostrava 2002*, Ostrava, ČR, 2002. Dostupný z WWW: <http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2002/Sbornik/Referaty/halounova3.htm>.

HARALICK, R.M. Statistical and Structural Approaches to Texture. *Proceedings of the IEEE*. May 1979, vol. 67, no. 5, s. 786-804.

HARALICK, R.M., SHANMUGAM, K., DINSTEIN, I. Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*. November 1973, vol. SMC-3, no. 6, s. 610-621.

HARVEY, R. O., CLARK, W. A. V.: The nature and economics of urban sprawl. In: *Internal Structure of the City*, New York: Oxford University Press, 1971. s. 475 –482.

HAY, G.J., CASTILLA, G. Object-Based Image Analysis: Strengths, Weaknesses, Opportunities and Threats (Swot). In LANG, S., et al. *Proceedings of 1st International Conference on Object-based Image Analysis*. 2006. s. 3. Dostupné z www: <http://www.commission4.isprs.org/obia06/Papers/01_Opening%20Session/OBIA2006_Hay_Castilla.pdf>.

HEROLD M., SCEPAN, J., CLARKE, K. The use of remote sensing and landscape metrics to describe structures and changes in urban land uses. *Environment and Planning*, vol. 34, 2002, s. 1443 – 1458.

HOFMANN, P., et al. Detecting Informal Settlements from QuickBird Data in Rio de Janeiro using an Object Based Approach. In LANG, S., et al. *Proceedings of 1st International Conference on Object-based Image Analysis*. 2006. s. 6. Dostupné z www:<http://www.commission4.isprs.org/obia06/Papers/05_Automated%20classification%20Urban/OBIA2006_Hofmann_et_al.pdf>.

HORNE, J. A Tasseled Cap Transformation for IKONOS Images. *Proceedings of the ASPRS: 2003 Annual Conference And Technology Exhibition*. 2003, s. 9.

HUANG, C., et al. Derivation of a tasselled cap transformation based on Landsat 7 at-satellite reflectance. *International Journal of Remote Sensing*. . 2002, vol. 23, is. 8, s. 1741-1748. Dostupné z www: <<http://landcover.usgs.gov/pdf/tasseled.pdf>>.

CHUNFANG, K. – KAI, X. – CHONGLONG, W. Classification and Extraction of Urban Land-Use Information from High-Resolution Image Based on Object Multi-features. In *Journal of China University of Geosciences*, vol. 17, no. 2, 2006. s. 151 – 157.

JACKSON, J. Urban sprawl. *Urbanismus a územní rozvoj*. 2002, 5, č.6, Česká Republika Ústav Územního Rozvoje, Brno, s.21-27.

JOHNSTON, R. J. et al. *The Dictionary of Human Geography*. Oxford : Blackwell Publishers, 2000. 976 s. ISBN 9780631205616.

JUPOVÁ, K. *Využití objektové klasifikace dat DPZ pro monitorování rozptýlené zeleně v krajině* Praha, 2007. 78 s. Vedoucí diplomové práce Doc. Ing. J. Kolář, CSc.

KAMAGATA, N. et al. 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*.

KARTOGRAFIE PRAHA. Školní atlas České republiky. 1. 2. dotisk vyd. Praha : Kartografie Praha, a. s., 2002. 32 s. ISBN 80-7011-657-9.

KAUTH, R.J., THOMAS, G.S. The Tasseled Cap - A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT. In *Proceedings of the Symposium on Machine Processing of Remotely Sensed Data*. Purdue University of West Lafayette, Indiana, 1976. s. 4B41-4B51.

KERLE, N., JANSSEN, L. L.F., HUURNEMAN, G. (eds.) *Principles of Remote Sensing : An introductory textbook*. 3rd edition. Enschede, The Netherlands : ITC, 2004. 250 s. ITC Educational Textbook Series. ISBN 90-6164-227-2.

KOLOMAZNÍK, J. Hodnocení přesnosti oficiální evidence využití ploch pomocí DPZ a GIS. Praha, 2007. 88 s. , 22. Přírodovědecká fakulta Univerzity Karlovy v Praze. Vedoucí diplomové práce Mgr. Přemysl Štych.

KOPALOVÁ, I. Semiautomatická aktualizace digitálních topografických map s využitím snímků vysokého rozlišení Praha, 2007. 81 s., 7 Přírodovědecká fakulta Univerzity Karlovy v Praze. Vedoucí diplomové práce Ing. Markéta Potůčková, Ph.D.

KRESSLER, F. P., KIM, Y. S., STEINHOCHER, K. Enhanced Semi-Automatic Image Classification of High-Resolution Data. In *Proceedings of the IGARSS 2005 Symposium. Seoul, Korea, 25 – 29 July 2005*.

KUČERA, Z.: Sídlo a obce: Základní pojmy geografie osídlení a jejich vztah. *Geografie - Sborník ČGS*. 2007, 112, č.1, Praha, s. 84 - 94

LEDUC, F. Feature Space Optimization Prior to Fuzzy Image Classification. In SVENSSON, P., SCHUBERT, J. *Proceedings of the Seventh International Conference on Information Fusion*. 1st edition. Mountain View, CA : International Society of Information Fusion, 2004. Image Fusion 1. s. 547-554. Dostupné z www: <<http://www.fusion2004.foi.se/papers/IF04-0547.pdf>>. ISBN 91-7056-115-X.

LIANG, S. *Quantitative remote sensing of land surfaces*. 1st edition. New Jersey : John Wiley & Sons, Inc. Hoboken, 2004. 536 s. , 1 CD-ROM. ISBN 0-471-28166-2.

LILLESAND, T. M., KIEFER, R. W. *Remote sensing and image interpretation*. Barry Harmon and Marian Provenzano. 3rd edition. New York, USA : John Wiley & Sons, 1994. 750 s. ISBN 0-471-57783-9.

LIZARAZO, I. Urban land cover and land use classification using high spatial resolution images and spatial metrics : Application & Development. In BRAUN, M. *Proceedings of the Second Workshop of the EARSeL SIG on Remote Sensing of Land Use and Land Cover*. Bonn: 2006. s. 292-298. Dostupný z WWW: <http://www.zfl.uni-bonn.de/earsel/papers/292-298_lizarazo.pdf>. ISBN 3-00-020518-7.

MATUŠKA, P., PETROVÁ, A. Zjišťování změn ve využití země pomocí DPZ (suburbánní oblast Brna). In *Sborník příspěvků z konference GIS... Ostrava 2001*. Ostrava, ČR, 2001. s. 7. Dostupný z WWW: <http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2001/Sbornik/Referaty/Matuskar.htm>.

MEINEL, G., NEUBERT, M. A Comparison of Segmentation Programs for High Resolution Remote Sensing Data. In *Proceedings of the XXth ISPRS Congress*. Istanbul, Turkey . 2004. s. 6. Dostupné z www: <<http://www.isprs.org/istanbul2004/comm4/papers/506.pdf>>.

MELICHAROVÁ, J., et al. *Kutnohorsko a Střední Polabí*. 1. vyd. Praha : Olympia, 1970. 243 s. , 8. Turistický průvodce ČSSR; sv. 20. ISBN 27-056-70.

MORI, M., et al. Object-based classification of IKONOS data for rural land use mapping. In *Proceedings of XXth ISPRS Congress*. 35th edition. Istanbul, Turkey : ISPRS, 2004. Commission III papers. s. 4. Dostupné z WWW: <<http://www.isprs.org/istanbul2004/comm3/papers/305.pdf>>. ISSN 1682-1750 .

NARASHIMHA RAO, P. V., et al. Textural analysis of IRS-1D panchromatic data for land cover classification. *International Journal of Remote Sensing*. . 2002, vol. 23, no. 17, s. 3327-3345.

ORUC, M. et al. 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*.

OUŘEDNÍČEK, M. Teorie stádií vývoje měst a diferenciální urbanizace. *Sborník ČGS*. 2000, roč. 105, č. 4, s. 361-369.

PÁTÍKOVÁ, A. Sledování dynamiky rozvoje Bratislavы v období 1949-1997 (MURBANDY projekt). In *Sborník příspěvků z konference GIS... Ostrava 2000*. Ostrava : VŠB - TU Ostrava, 2000. s. 8. Dostupné z WWW: <http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2000/Sbornik/Patikova/Referat.htm>.

PAVELKA, K. *Zpracování obrazových záznamů DPZ*. 1. vyd. Praha : Vydatelství ČVUT, 1999. 138 s. ISBN 80-01-02031-2.

PRATT, W.K. *Digital Image Processing*. 2nd edition. New York : John Wiley & Sons, 1991. 320 s. ISBN 0-471-85766-1.

PUISSANT, A., HIRSCH, J., WEBER, C. The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery. In *International Journal of Remote Sensing*, vol. 26, no. 4, 2005. s. 733 – 745.

REES, W.G. *Physical Principles of Remote Sensing*. 2nd edition. Cambridge, UK : Cambridge University Press, 2001. 343 s. ISBN 0 521 66034 3.

RIDLEY, H. M. et al. Evaluating the Potential of the Forthcoming Commercial U.S. High-Resolution Satellite Sensor Imagery at the Ordnance Survey. *Photogrammetric Engineering and Remote Sensing*. 1997, Vol. 63, No. 8, s. 997 – 1005.

SEDLÁK, P. Zjišťování změn ve využití země města Olomouce pomocí DPZ. In *Sborník příspěvků z konference GIS... Ostrava 2004*. Ostrava : VŠB - TU Ostrava, 2004. s. 5. Dostupné z www: <http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2004/Sbornik/Referaty/sedlak.htm>.

SCHIEWE, J. Segmentation of high-resolution remotely sensed data - concepts, applications and problems. *International Archives of Photogrammetry and Remote Sensing*. 2002, vol. 34, no. 4, s. 380-385. Dostupné z www: <<http://definiens.com/pdf/publications/358.pdf>>.

SCHIEWE, J., TUFTE, L., EHLERS, M. Potential and problems of multi-scale segmentation methods in remote sensing. *GIS - Geographische Informationssysteme*. 2001, no. 6, s. 34-39.

SLEPIČKA, A. *Venkov a/nebo město : Lidé/Sídla/Krajina*. 1. vyd. Praha : Svoboda, 1981. 368 s. ISBN 25-138-81.

ŠIMON, M. *Teoretické přístupy ke studiu urbanizace* Praha, 2006. 65 s. Přírodovědecká fakulta Univerzity Karlovy v Praze. Vedoucí bakalářské práce RNDr. Martin Ouředníček, Ph.D.

TAUBENBÖCK, H., ESCH, T., ROTH, A. An urban classification approach based on an object-oriented analysis of high resolution satellite imagery for a spatial structuring within urban areas. In *Proceedings of First Workshop of the EARSeL*. Berlin : [s.n.], 2006. s. 8. Dostupné z www: <http://helmholtz-eos.dlr.de/docs/EARSeL1_Taubenboeck.pdf>.

TOMÁŠEK, M. *Půdy České republiky*. 2. vyd. Praha : Český geologický ústav, 2000. 68 s. ISBN 80-7075-403-6.

TOMOWSKI, D., et al. *Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten*. Osnabrück : IGF, 2006. 129 s. ISBN 1863-0103.

TUOMINEN, S., PEKKARINEN, A. Performance of different spectral and textural aerial photograph features in multi-source forest inventory. *Remote Sensing of the Environment*. 2005, vol. 94, is. 2, s. 256-268.

TVRDÍK, J. *Základy statistické analýzy dat*. Ostrava : Ostravská Univerzita, 1998. ISBN 80-7042-770-1.

ÚZEMNÍ PLÁNOVÁNÍ ze zorného úhlu urban sprawl: *Veřejná Správa*, č.9. [online]. 2005 [cit. 2007-06-09]. Dostupné z www: <http://www.mvcr.cz/2003/casopisy/vs/0509/pril2_info.html>.

VAN DEN BERG, L., et al. *A Study of Growth and Decline*. Oxford : Pergamon Press, 1982. 162 s. ISBN 0-08-023156-X.

VAN DER SANDE, C.J., DE JONG, S.M., DE ROO, A.P.J. A segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist flood risk and flood damage assessment. *International Journal of Applied Earth Observation and Geoinformation*. 2003, vol. 4, s. 217-229.

WALTER, V. Object-Based Evaluation of LIDAR and Multispectral data for automatic change detection in GIS databases. In *Proceedings of the XXth ISPRS Congress*., 2004. s. 6.

WEITZ, J., MOORE, T. Development inside urban growth boundaries: Oregon's empirical evidence of contiguous urban form. *Journal of the American Planning Association*. 1998, vol. 64, no. 4, s. 424-440.

WHITESIDE, T., AHMAD, W. 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, Australia, September 2005*.

YUAN, F., BAUER, M.E. Mapping Impervious Surface Area using High Resolution Imagery: A Comparison of Object-Based and Per-Pixel Classification. In *Proceedings of the ASPRS: 2006 Annual Conference*. Reno, Nevada :ASPRS, 2006. s. 10.

ZADEH, L. A. Fuzzy Sets. *Information and Control*. 1965, vol. 8, s. 338-353. Dostupné z www:<<http://www-bisc.cs.berkeley.edu/zadeh/papers/Fuzzy%20Sets-1965.pdf>>.

ZENG, H., et al. Linking Urban Field Theory with GIS and Remote Sensing to Detect Signatures of Rapid Urbanization on the Landscape: Toward a New Approach for Characterizing Urban Sprawl. *Urban Geography*. 2005, vol. 26, no. 5, s. 410-434.

ZHAN, Q. *A Hierarchical Object-Based Approach for Urban Land-Use Classification from Remote Sensing Data* Enschede, The Netherlands : ITC, 2003. 271 s. Wageningen University. Vedoucí dizertační práce Prof. Dr. Ir. M. Molenaar. ISBN 90-5808-917-7.

ZHANG, Y. A spectral and spatial information integrated approach for object extraction from high-resolution digital imagery. *Second Digital Earth Conference*, Fredericton, Canada, June 24-28, 2001.

ZHANG, Y. Optimisation of building detection in satellite images by combining multispectral classification and texture filtering. *ISPRS Journal of Photogrammetry & Remote Sensing*. 1999, vol. 54, no. 1, s. 50-60.

Další zdroje:

ČESKO. Zákon č.183 ze dne 14. března 2006 o územním plánování a stavebním řádu (stavební zákon). In *Sbírka zákonů České republiky*. 2006, částka 63, s.2233-2260. Dostupný z www: <<http://www.mvcr.cz/sbirka/2006/sb063-06.pdf>>.

DE KOK, R. *3rd eCognition Workshop ver.5 Professional – Interactive training on Object Based Image Analysis Process, architectural design*. Kraków, 2007.

DEFINIENS AG. *Definiens Professional 5 : Reference Book*. München, Germany : Defininiens AG, 2006a. 123 s.

DEFINIENS AG. *Definiens Professional 5 : User Guide*. München, Germany : Defininiens AG, 2006b. 249 s.

PCI GEOMATICS ENT. INC. *Geomatica Prime Help*. Richmond Hill, ON Canada : PCI Geomatics Enterprises Inc., 2003.

POPULATION REFERENCE BUREAU: *2006 World Population Data Sheet* [online]. 2006 [cit. 2007-06-11]. Dostupné z www: <<http://www.prb.org/pdf06/06WorldDataSheet.pdf>>.

UNITED NATIONS: *World Urbanization Prospects: The 2005 Revision* [online]. 2006 [cit. 2007-06-09] Dostupné z www: <<http://www.un.org/esa/population/publications/WUP2005/2005wup.htm>>.

Internetové zdroje:

BARNES, K. B., MORGAN, III, J.M., ROBEREGE, M.C., LOWE, S.: *Impervious surfaces and the quality of natural and built environments. A white paper prepared for the project Chesapeake Bay From Space* [online]. 2000 [cit. 2007-06-09]. Dostupné z www: <<http://www.chesapeakebayfromspace.net>>.

BARNES, K. B., MORGAN, III, J.M., ROBEREGE, M.C., LOWE, S.: *Sprawl Development: Its Patterns, Consequences, And Measurment. A white paper prepared for the project Chesapeake Bay From Space* [online]. 2001 [cit. 2007-06-09]. Dostupné z www: <<http://chesapeake.towson.edu/downloads.asp>>.

ČÚZK. *Základní Báze Geografických Dat* [online]. 2007 [cit. 2007-05-30]. Dostupné z www:<http://www.cuzk.cz/Dokument.aspx?PRARESKOD=998&MENUID=0&AKCE=DOC:30-ZU_ZABAGED>.

DIGITALGLOBE. *Imaging Systems* [online]. 2007 [cit. 2007-08-30]. Dostupné z www: <http://www.digitalglobe.com/downloads/WV1_WV2_SpectralResponse.pdf>.

DOBROVOLNÝ, P. Digitální zpracování materiálů DPZ [online]. 2007 [cit. 2007-06-07]. Dostupné z www: <http://geogr.muni.cz/archiv/vzuka/DPZ_cviceni/texty/cviceni_uvod.html>.

GEOEYE. *Imagery Products* [online]. 2007 [cit. 2007-08-31]. Dostupné z www: <http://www.geoeye.com/whitepapers_pdfs/GeoEye_IKONOS_Product_Guide_v17.pdf>

GISAT. Družicová data [online]. 2007 [cit. 2007-06-09]. Dostupné z www: <<http://gisat.cz/content/cz/druzicova-data>>

IURS - Institut pro udržitelný rozvoj sídel o.s. *Brownfields.cz* [online]. 2007 [cit. 2007-06-05]. Dostupné z www: <<http://www.brownfields.cz/e107/news.php>>.

JACKSON, J.: ABC brownfields [online]. 2003 [cit. 2007-06-09]. Dostupné z www: <<http://www.brownfields.cz/e107/download.php?list.4>>.

MUSIL, J.: Proces urbanizace v Evropě [online]. 2005 [cit. 2007-06-09]. Dostupné z www: <<http://www.cefres.cz/austerlitz.php>>.

OUŘEDNÍČEK, M. *Urbanizace a vývoj měst* [online]. 2007 [cit. 2007-06-05]. Dostupné z www: <<http://www.natur.cuni.cz/~slamak/>>.

THE SIERRA CLUB. *Sprawl Overview* [online]. 2001 [cit. 2007-06-05]. Dostupné z www: <<http://www.sierraclub.org/sprawl/overview/>>.

USEPA: *Why should we be concerned about sprawl?* [online]. 2001 [cit. 2007-06-09]. Dostupné z www: <www.epa.gov/region5/air/sue/sprawl/htm>.

WIKIPEDIA CONTRIBUTORS. *Bhattacharyya distance* [online]. Wikipedia, The Free Encyclopedia, [2007a] , Last revision: 27 July 2007 22:20 UTC [cit. 2007-08-10]. Dostupné z www:<http://en.wikipedia.org/w/index.php?title=Bhattacharyya_distance&oldid=147547192>.

Seznam příloh

- Příloha A.1 ANOVA – variabilita tříd v příznacích
- Příloha A.2 ANOVA – variabilita tříd v příznacích
- Příloha B.1 Grafy normalizované pravděpodobnosti tréninkových objektů (PAN_BF, eNDGI)
- Příloha B.2 Grafy normalizované pravděpodobnosti tréninkových objektů (eTCT1, Brightness)
- Příloha B.3 Grafy normalizované pravděpodobnosti tréninkových objektů (Red/STD, B/STD)
- Příloha B.4 Grafy normalizované pravděpodobnosti tréninkových objektů (NDBI, Ratio Blue)
- Příloha B.5 Grafy normalizované pravděpodobnosti tréninkových objektů (TCT3, TCT4)
- Příloha B.6 Grafy normalizované pravděpodobnosti tréninkových objektů (NDVI100)
- Příloha C.1 Land cover a detail zastavěného území – lokalita 1
- Příloha C.2 Land cover a vymezení zastavěného území – lokalita 1
- Příloha C.3 Land cover a detail zastavěného území – lokalita 2
- Příloha C.4 Land cover a vymezení zastavěného území – lokalita 2
- Příloha C.5 Land cover a detail chybně oklasifikovaného lomu – lokalita 3

Příloha A.1: ANOVA - variabilita tříd v příznacích

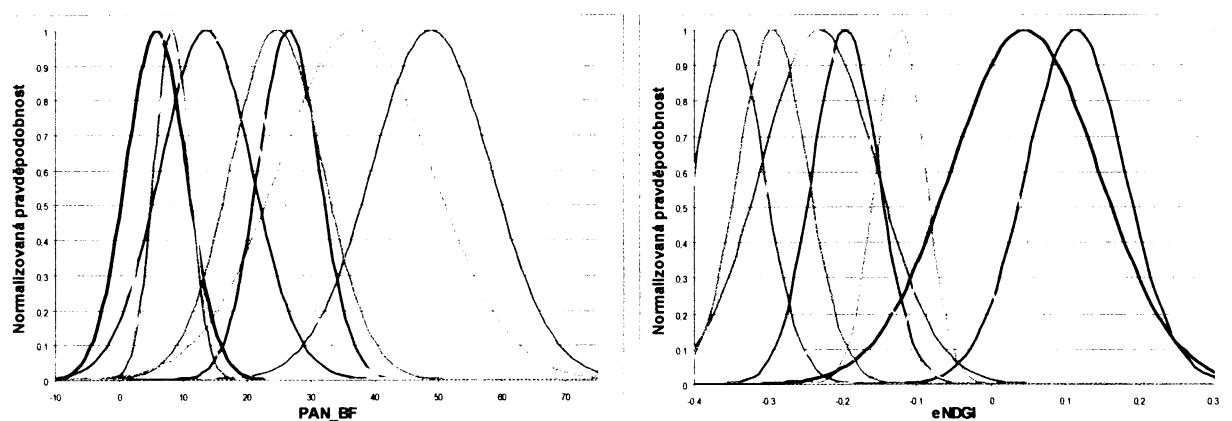
Příznak	Variabilita	Součet čtverců	df	Střední čtverec	F	Sig.
RVI	Mezi skupinami	335	9	37,223	6 724,933	0,000
	Uvnitř skupin	44	8 039	0,006		
	Celkem	380	8 048			
Ratio Red	Mezi skupinami	9,06	9	1,007	6 672,182	0,000
	Uvnitř skupin	1,21	8 039	0,000		
	Total	10,27	8 048			
Mean NDVI100	Mezi skupinami	2 720 844	9	302 316,041	5 729,765	0,000
	Uvnitř skupin	424 157	8 039	52,762		
	Total	3 145 001	8 048			
Mean Red	Mezi skupinami	380 734 468	9	42 303 829,780	4 357,677	0,000
	Uvnitř skupin	78 041 692	8 039	9 707,886		
	Total	458 776 160	8 048			
Mean Blue	Mezi skupinami	134 437 620	9	14 937 513,381	3 834,899	0,000
	Uvnitř skupin	31 313 123	8 039	3 895,152		
	Total	165 750 744	8 048			
Pan BF	Mezi skupinami	1 176 600	9	130 733,339	3 686,993	0,000
	Uvnitř skupin	284 940	8 036	35,458		
	Total	1 461 540	8 045			
NDGI	Mezi skupinami	180	9	20,034	2 967,902	0,000
	Uvnitř skupin	54	8 039	0,007		
	Total	235	8 048			
Brightness	Mezi skupinami	93 584 340	9	10 398 259,987	2 609,972	0,000
	Uvnitř skupin	32 027 784	8 039	3 984,051		
	Total	125 612 124	8 048			
TCT1	Mezi skupinami	964 370 835	9	107 152 314,959	2 534,762	0,000
	Uvnitř skupin	339 833 638	8 039	42 273,123		
	Total	1 304 204 472	8 048			
Ratio NIR	Mezi skupinami	21	9	2,363	2 247,194	0,000
	Uvnitř skupin	8	8 039	0,001		
	Total	30	8 048			
TCT3	Mezi skupinami	5 160 324	9	573 369,361	2 170,743	0,000
	Uvnitř skupin	2 123 382	8 039	264,135		
	Total	7 283 706	8 048			
N/STD	Mezi skupinami	113 456	9	12 606,222	1 754,668	0,000
	Uvnitř skupin	57 748	8 038	7,184		
	Total	171 204	8 047			
NDBI	Mezi skupinami	135	9	14,970	1 751,784	0,000
	Uvnitř skupin	69	8 039	0,009		
	Total	203	8 048			
R/STD	Mezi skupinami	83 980	9	9 331,080	1 574,723	0,000
	Uvnitř skupin	47 629	8 038	5,926		
	Total	131 609	8 047			
B/STD	Mezi skupinami	323 878	9	35 986,407	1 482,675	0,000
	Uvnitř skupin	195 092	8 038	24,271		
	Total	518 970	8 047			
eTCT1	Mezi skupinami	279 019 493	9	31 002 165,881	1 335,287	0,000
	Uvnitř skupin	186 646 278	8 039	23 217,599		
	Total	465 665 771	8 048			
eNDGI	Mezi skupinami	69	9	7,637	1 249,576	0,000
	Uvnitř skupin	49	8 039	0,006		
	Total	118	8 048			
Zabud1	Mezi skupinami	250 075 474	9	27 786 163,809	1 174,387	0,000
	Uvnitř skupin	190 203 874	8 039	23 660,141		
	Total	440 279 348	8 048			

Příloha A.2: ANOVA - variabilita tříd v příznacích

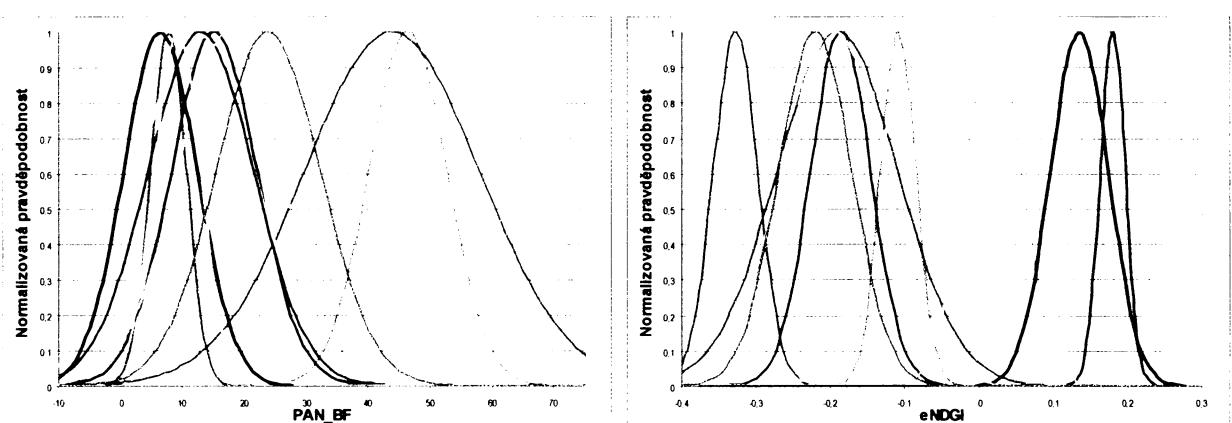
Příznak	Variabilita	Součet čtverců	df	Střední čtverec	F	Sig.
Std. dev Blue	Mezi skupinami	1 324 499	9	147 166,503	1 146,327	0,000
	Uvnitř skupin	1 032 054	8 039	128,381		
	Total	2 356 553	8 048			
Ratio Blue	Mezi skupinami	3	9	0,285	1 053,159	0,000
	Uvnitř skupin	2	8 039	0,000		
	Total	5	8 048			
Mean NIR	Mezi skupinami	302 344 687	9	33 593 854,158	1 016,340	0,000
	Uvnitř skupin	265 719 012	8 039	33 053,740		
	Total	568 063 700	8 048			
TCT4	Mezi skupinami	474 893	9	52 765,849	1 008,164	0,000
	Uvnitř skupin	420 750	8 039	52,339		
	Total	895 642	8 048			
Std. dev Red	Mezi skupinami	3 156 245	9	350 693,944	958,785	0,000
	Uvnitř skupin	2 940 418	8 039	365,769		
	Total	6 096 663	8 048			
TCT2	Mezi skupinami	114 064 667	9	12 673 851,845	877,831	0,000
	Uvnitř skupin	116 064 602	8 039	14 437,691		
	Total	230 129 268	8 048			
Std. dev NIR	Mezi skupinami	5 406 444	9	600 715,986	562,865	0,000
	Uvnitř skupin	8 579 606	8 039	1 067,248		
	Total	13 986 050	8 048			
Sum STD/ Brightness	Mezi skupinami	187	9	20,819	497,480	0,000
	Uvnitř skupin	336	8 039	0,042		
	Total	524	8 048			
Std. dev NDVI100	Mezi skupinami	19 203	9	2 133,679	319,165	0,000
	Uvnitř skupin	53 742	8 039	6,685		
	Total	72 945	8 048			
GLCM StdDev Blue	Mezi skupinami	46 618	9	5 179,787	284,691	0,000
	Uvnitř skupin	146 265	8 039	18,194		
	Total	192 883	8 048			
GLCM StdDev NIR	Mezi skupinami	44 129	9	4 903,219	262,214	0,000
	Uvnitř skupin	150 324	8 039	18,699		
	Total	194 453	8 048			
GLCM StdDev Red	Mezi skupinami	41 689	9	4 632,124	260,096	0,000
	Uvnitř skupin	143 169	8 039	17,809		
	Total	184 858	8 048			
GLCM Contrast NIR	Mezi skupinami	3 684 810 080	9	409 423 342,203	214,768	0,000
	Uvnitř skupin	15 325 143 773	8 039	1 906 349,518		
	Total	19 009 953 853	8 048			
GLCM Correlation NIR	Mezi skupinami	32	9	3,508	185,980	0,000
	Uvnitř skupin	152	8 039	0,019		
	Total	183	8 048			
GLCM Correlation Red	Mezi skupinami	32	9	3,577	177,112	0,000
	Uvnitř skupin	162	8 039	0,020		
	Total	195	8 048			
GLCM Homogeneity Red	Mezi skupinami	0	9	0,009	173,311	0,000
	Uvnitř skupin	0	8 039	0,000		
	Total	1	8 048			
GLCM Contrast Red	Mezi skupinami	3 109 731 765	9	345 525 751,627	171,676	0,000
	Uvnitř skupin	16 179 795 682	8 039	2 012 662,729		
	Total	19 289 527 447	8 048			
GLCM Homogeneity NIR	Mezi skupinami	0	9	0,008	161,913	0,000
	Uvnitř skupin	0	8 039	0,000		
	Total	0	8 048			

Příloha B.1: Grafy normalizované pravděpodobnosti tréninkových objektů

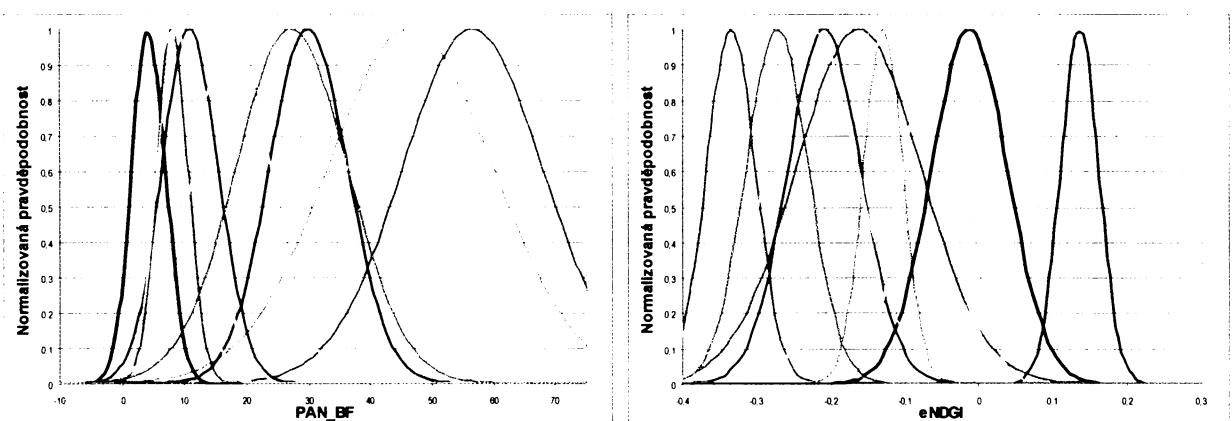
Lokalita 1



Lokalita 2



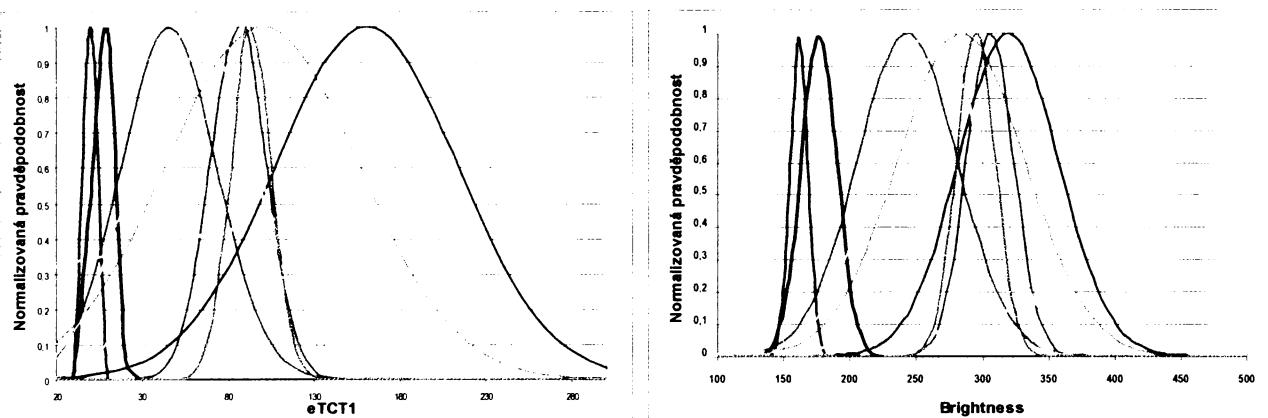
Lokalita 3



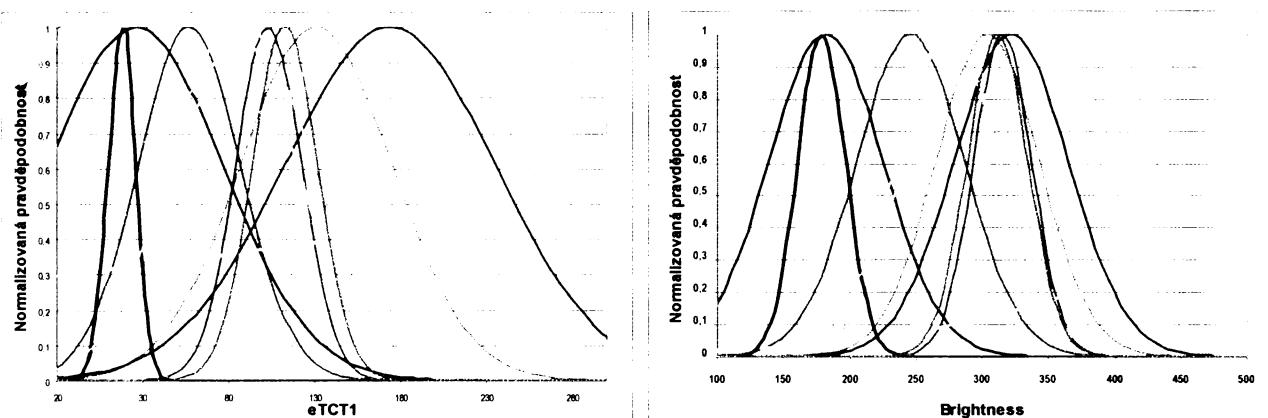
Holá půda	Lesy	Vegetace
Vodní plochy	Bílé střechy	Červené střechy
Zpevněné povrchy	Stíny	Stromy
Trávníky		

Příloha B.2: Grafy normalizované pravděpodobnosti tréninkových objektů

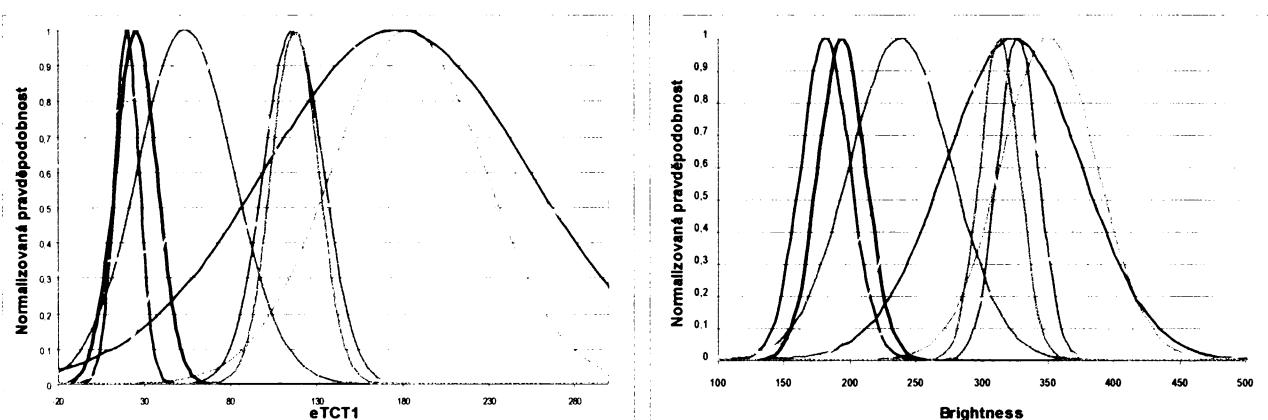
Lokalita 1



Lokalita 2



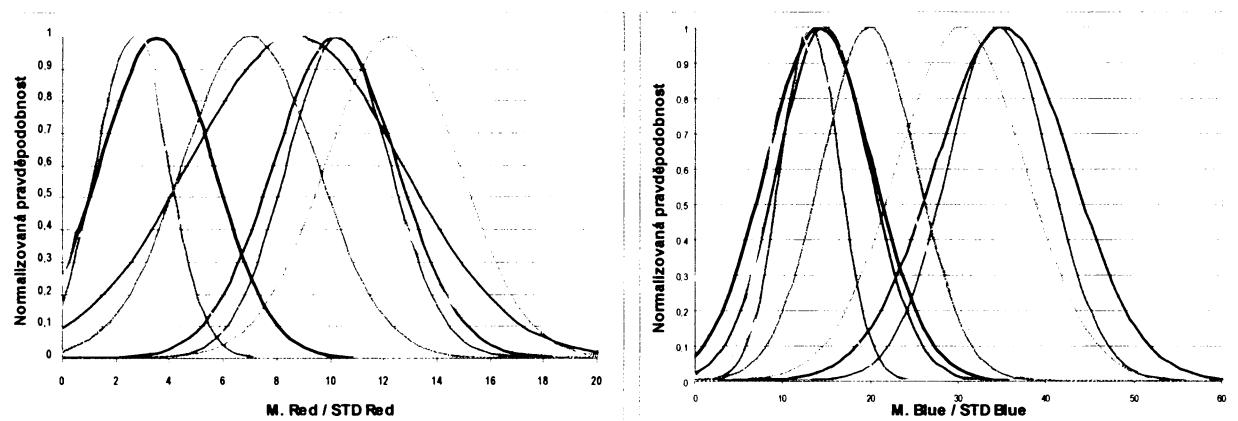
Lokalita 3



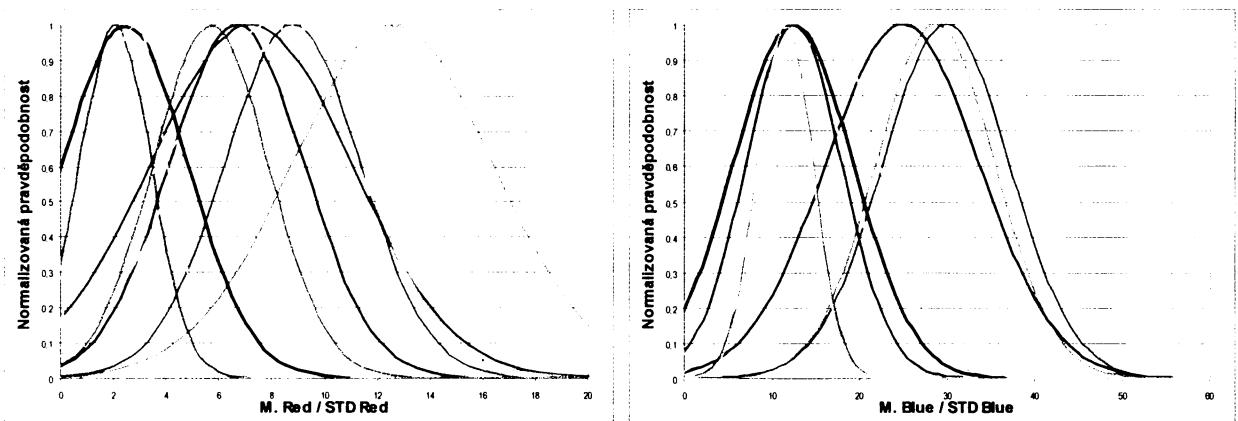
— Holá půda	— Lesy	— Vegetace
— Vodní plochy	— Bílé střechy	— Červené střechy
— Zpevněné povrchy	— Stíny	— Stromy
— Trávníky		

Příloha B.3: Grafy normalizované pravděpodobnosti tréninkových objektů

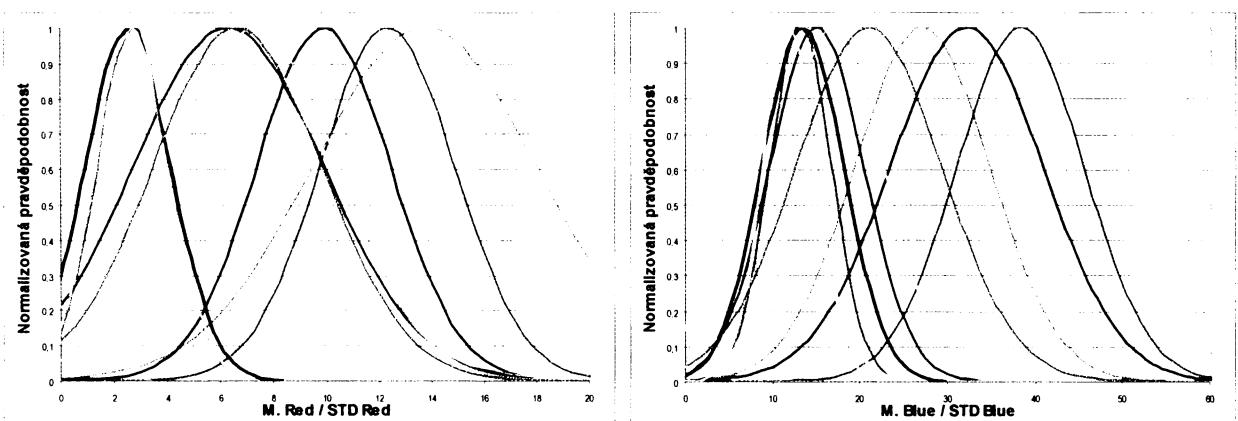
Lokalita 1



Lokalita 2



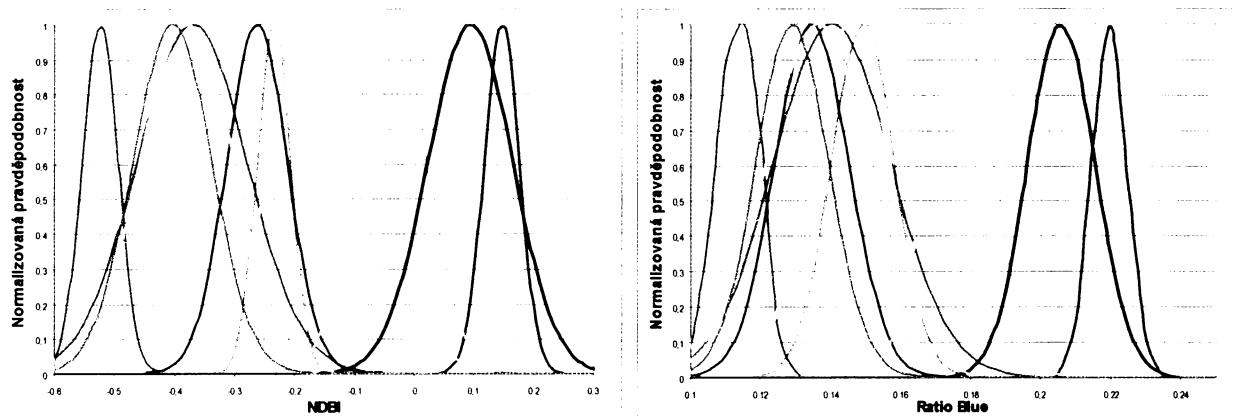
Lokalita 3



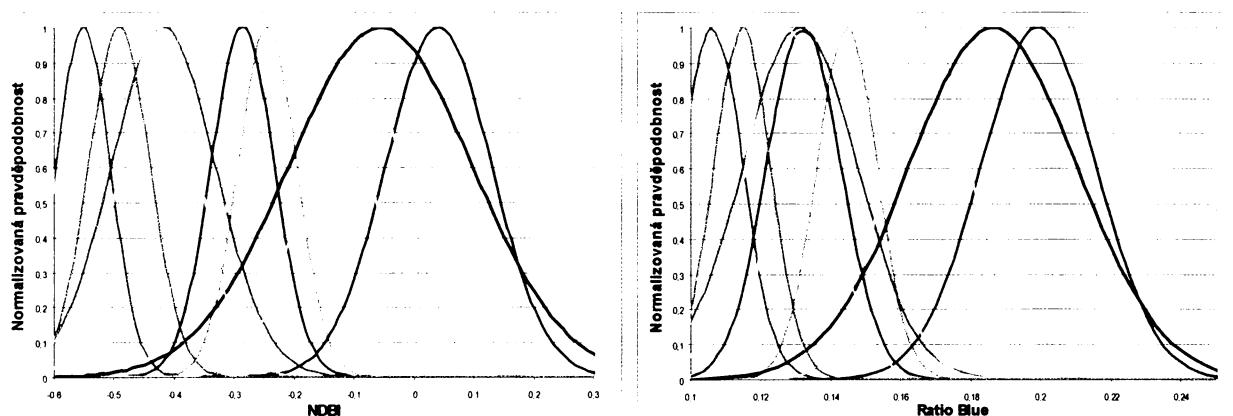
Holá půda	Lesy	Vegetace
Vodní plochy	Bílé střechy	Červené střechy
Zpevněné povrchy	Stíny	Stromy
Trávníky		

Příloha B.4:Grafy normalizované pravděpodobnosti tréninkových objektů

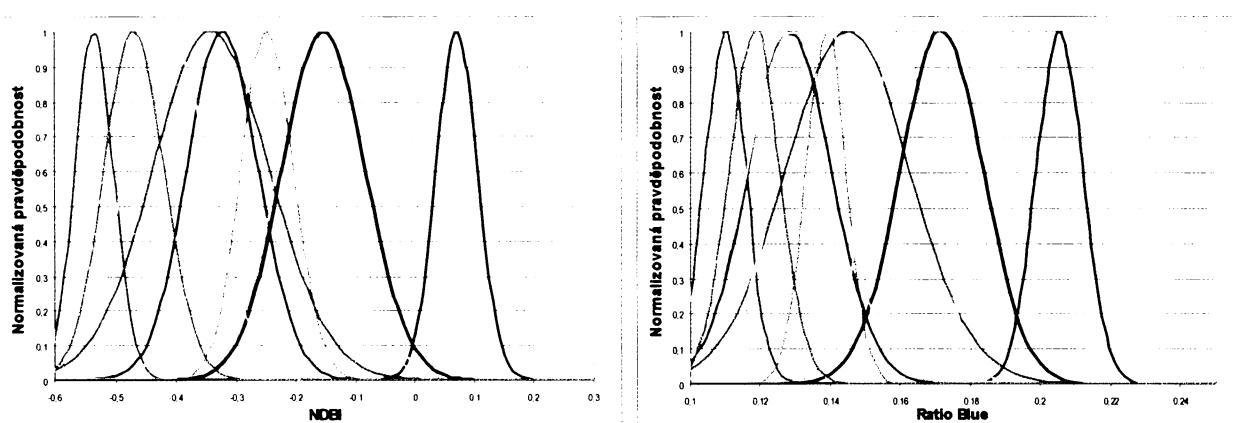
Lokalita 1



Lokalita 2



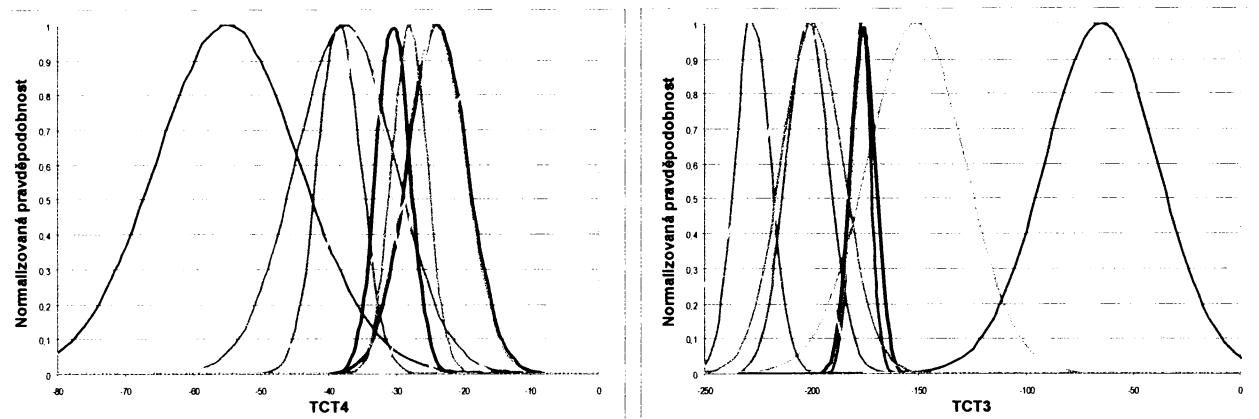
Lokalita 3



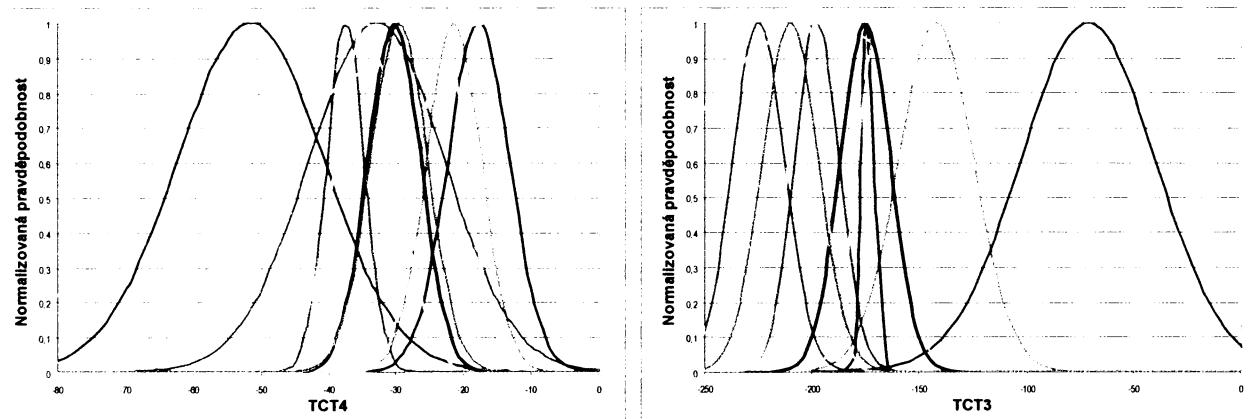
— Holá půda	— Lesy
— Vodní plochy	— Bílé střechy
— Zpevněné povrchy	— Stíny
— Trávníky	— Vegetace
	— Červené střechy
	— Stromy

Příloha B.5: Grafy normalizované pravděpodobnosti tréninkových objektů

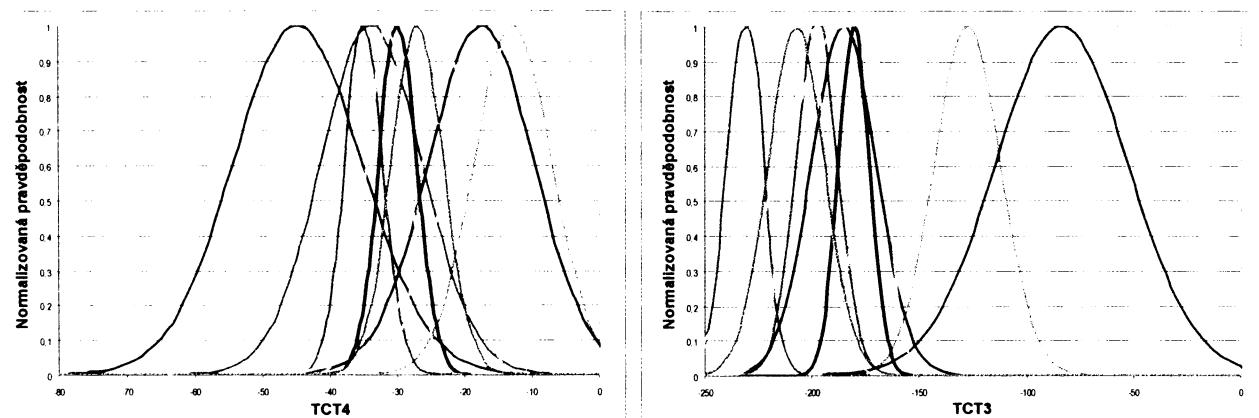
Lokalita 1



Lokalita 2



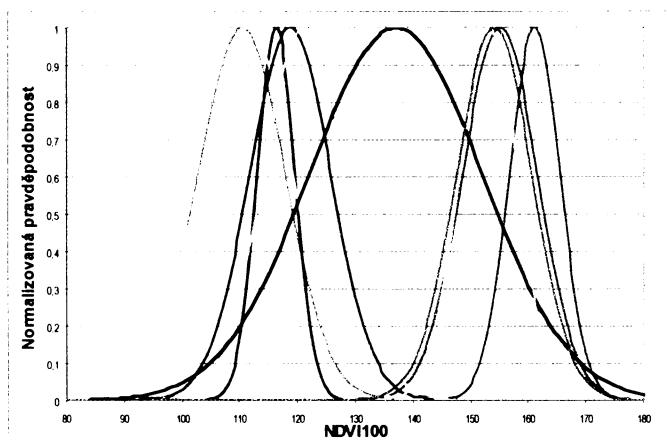
Lokalita 3



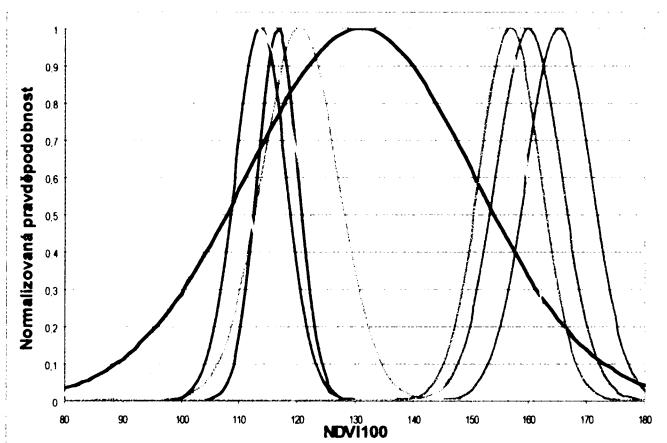
— Holá půda	— Lesy	— Vegetace
— Vodní plochy	— Bílé střechy	— Červené střechy
— Zpevněné povrchy	— Stíny	— Stromy
— Trávníky		

Příloha B.6: Grafy normalizované pravděpodobnosti tréninkových objektů

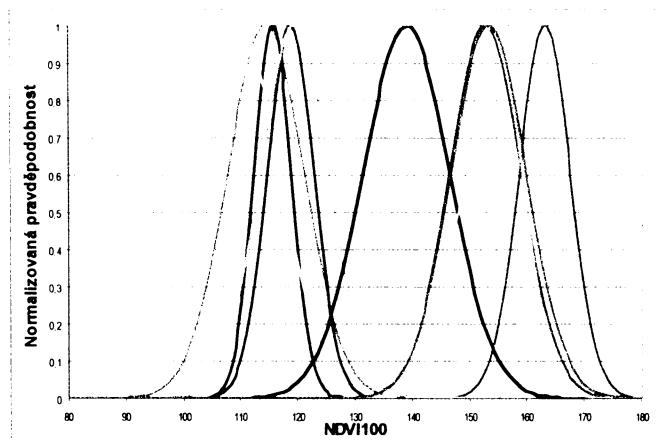
Lokalita 1



Lokalita 2

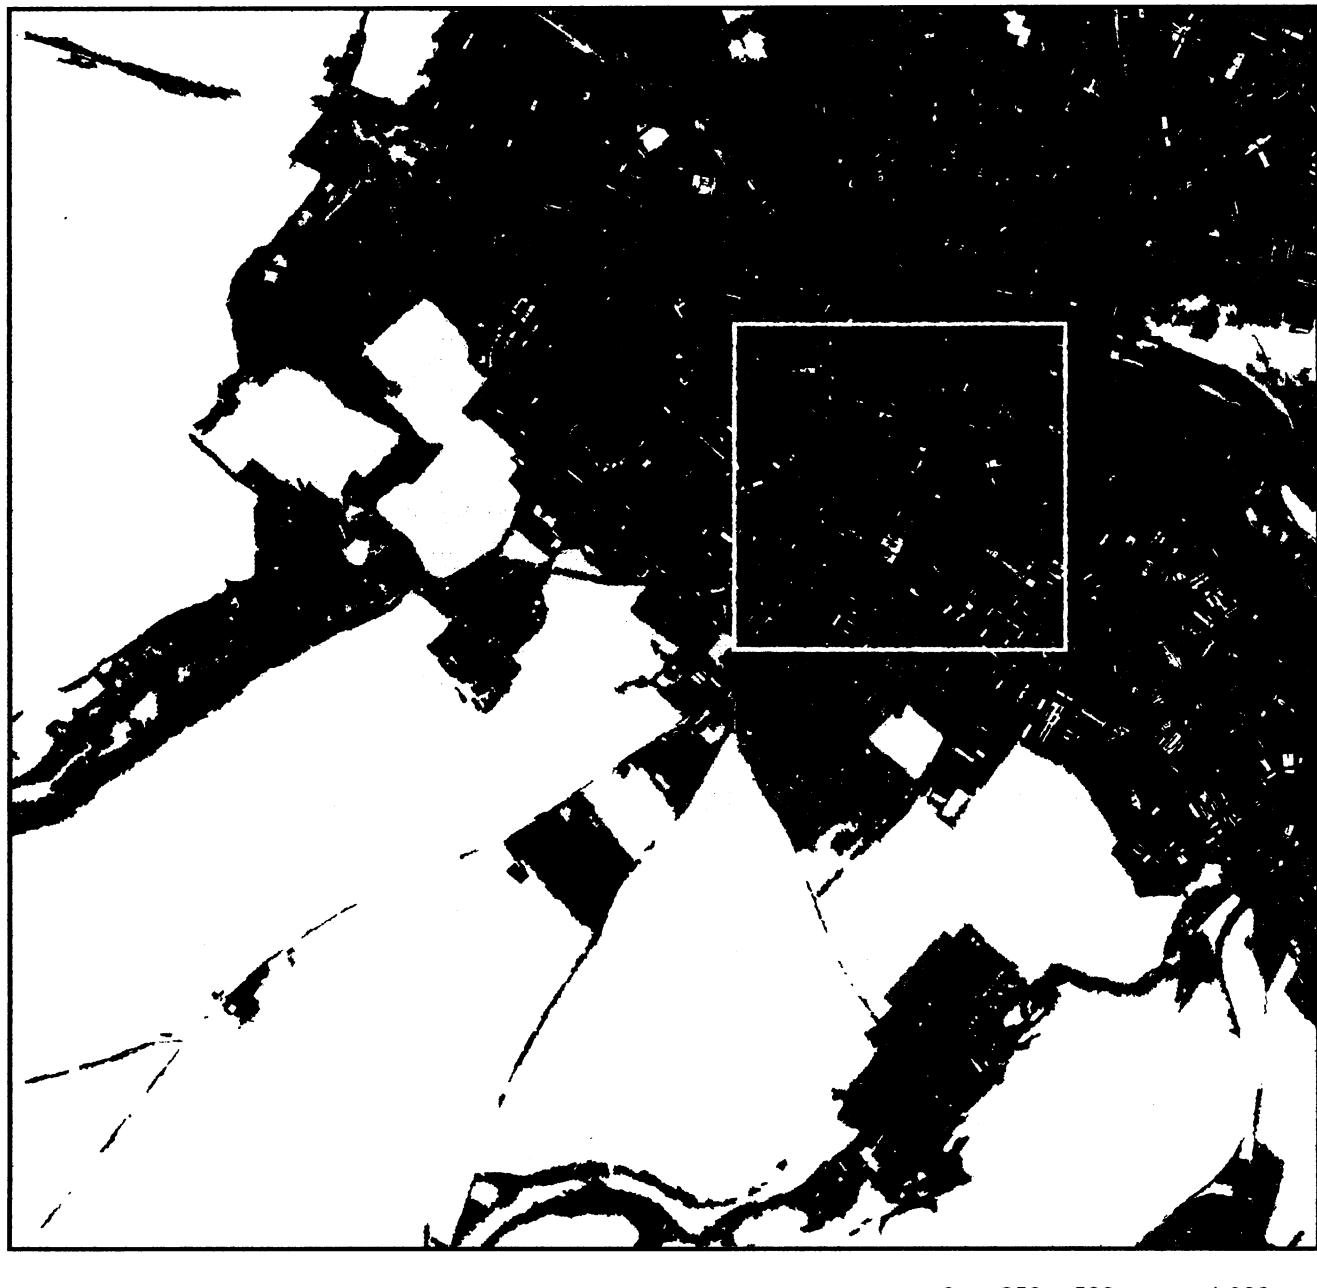


Lokalita 3



— Holá půda	— Lesy	— Vegetace
— Vodní plochy	— Bílé střechy	— Červené střechy
— Zpevněné povrchy	— Stíny	— Stromy
— Trávníky		

Příloha C.1: Land cover a detail zastavěného území - lokalita 1



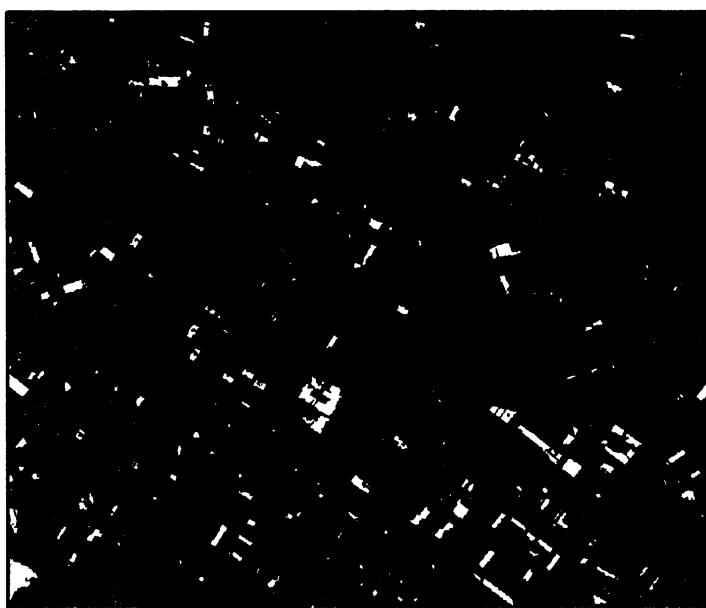
0 250 500 1 000 m

Legenda:

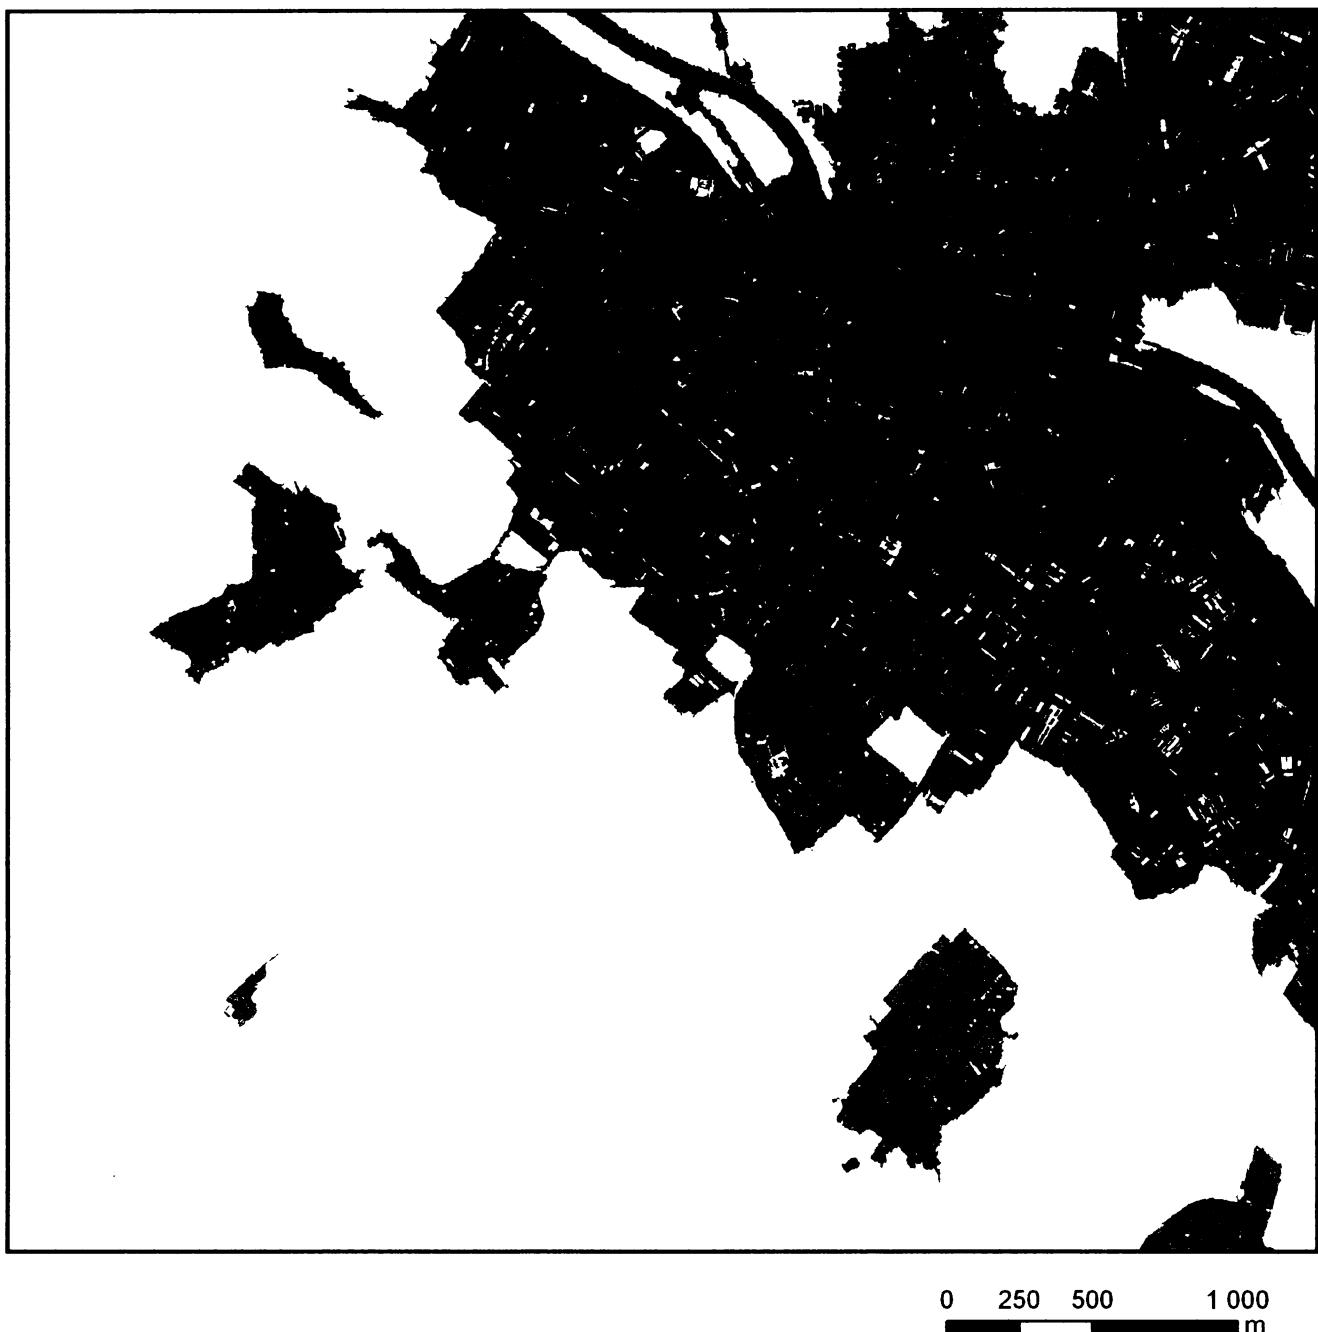
Třída LC	
■	Červené střechy
■	Světlé střechy
■	Síny
■	Zpevněné povrchy
■	Stromy
■	Trávníky a travnatá sportoviště
■	Holá půda
■	Vegetace
■	Lesy
■	Vodní plochy

0 100 200 400 m

S



Příloha C.2: Land cover a vymezení zastavěného území - lokalita 1



0 250 500 1 000 m

Legenda:

Třída LC

- Červené střechy
- Světlé střechy
- Stíny
- Trávníky
- Stromy
- Zpevněné povrchy / Zastavěné území
- Vodní plochy
- Nezastavěně území



0 500 1 000 m



Příloha C.3: Land cover a detail zastavěného území - lokalita 2



Legenda:

Třída LC



Červené střechy



Světlé střechy



Stíny



Zpevněné povrchy



Stromy



Trávníky a travnatá sportoviště



Holá půda



Vegetace



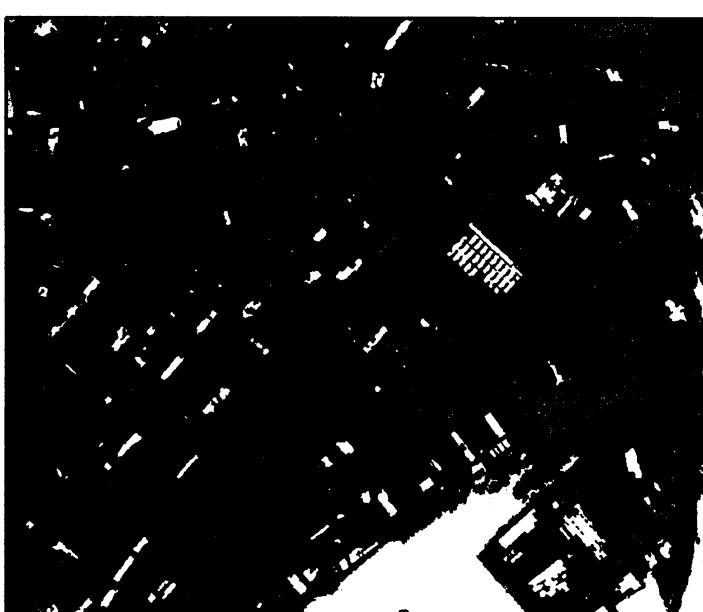
Lesy



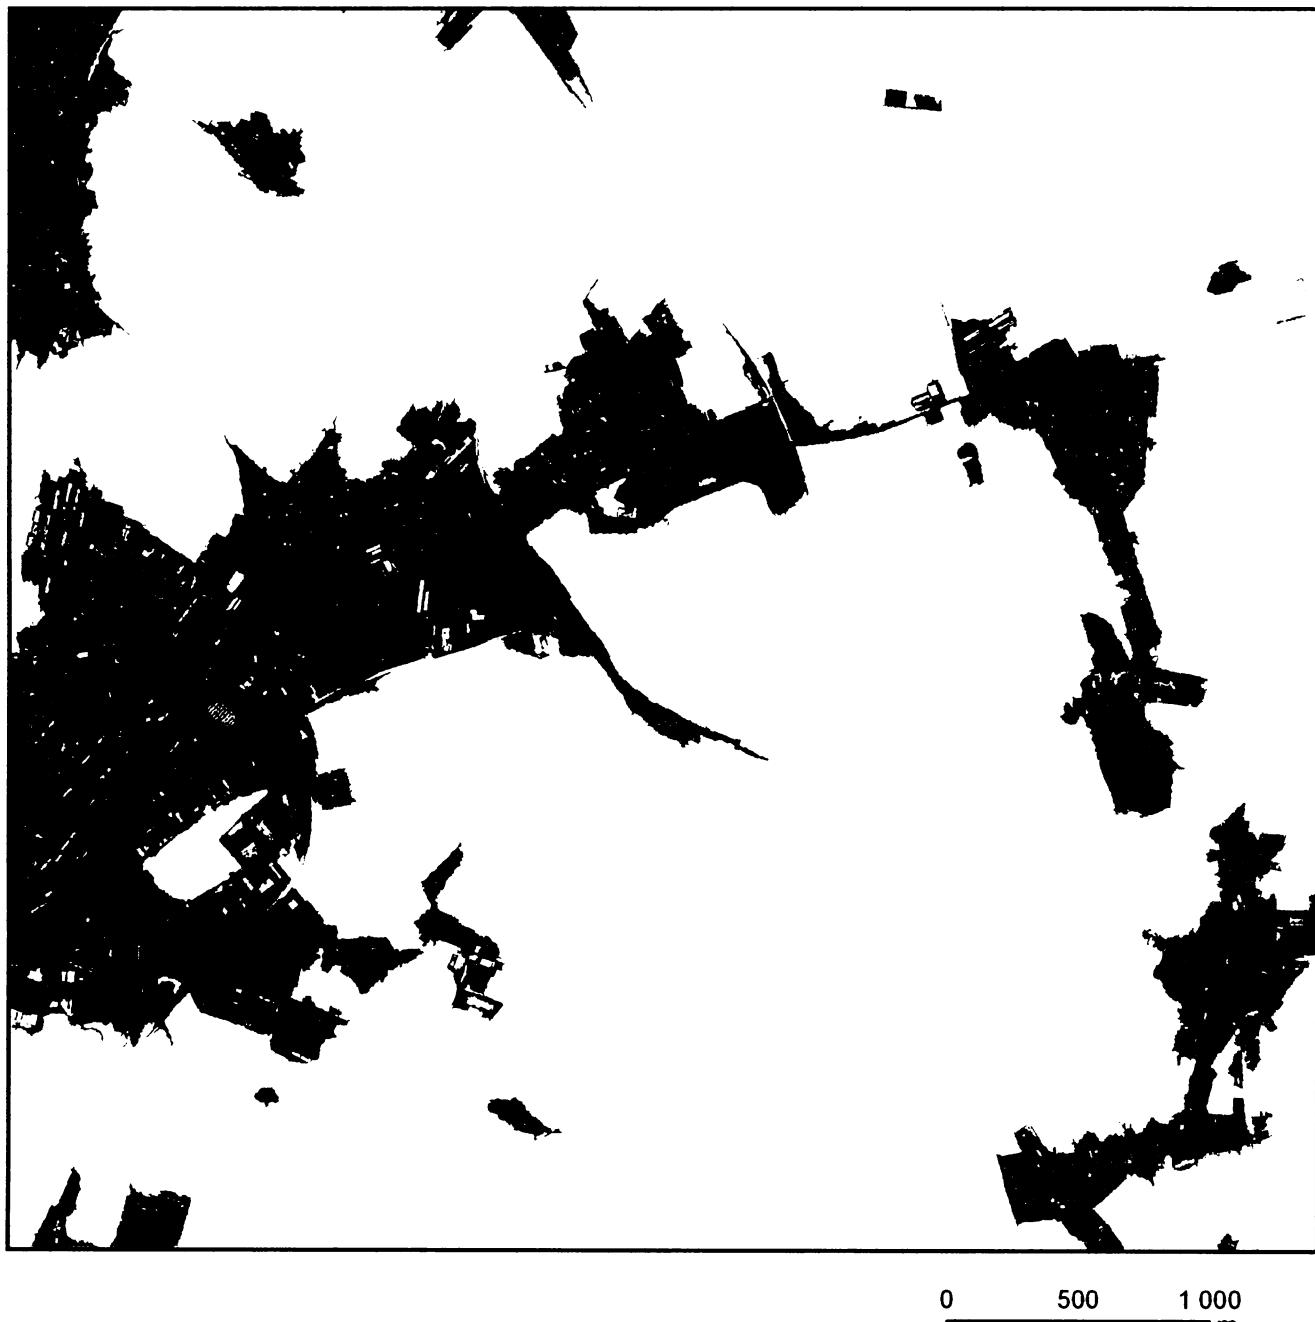
Vodní plochy

S

0 100 200 400 m



Příloha C.4: Land cover a vymezení zastavěného území - lokalita 2



Legenda:

Třída LC

- Červené střechy
- Světlé střechy
- Stíny
- Trávníky
- Stromy
- Zpevněné povrchy / Zastavěné území
- Vodní plochy
- Nezastavěně území



0 750 1 500 m

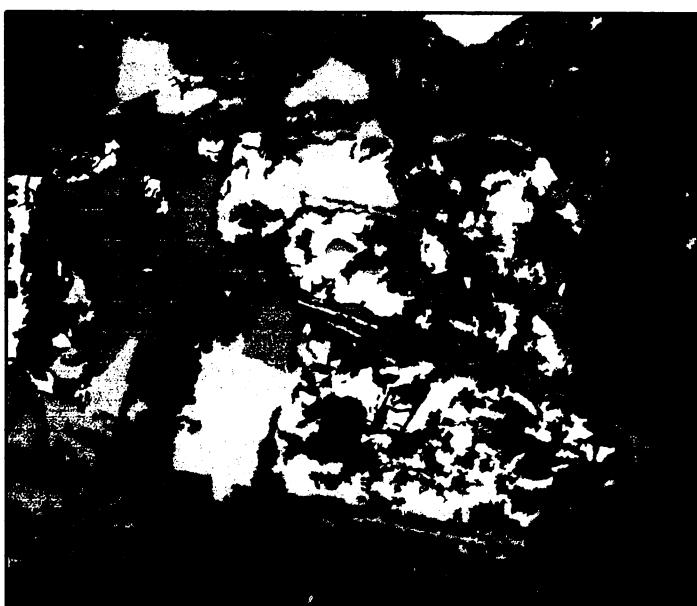


Příloha C.5: Land cover a detail chybně oklasifikované plochy lomu - lokalita 3



Legenda:

- Třída LC
- Červené střechy
 - Světlé střechy
 - Stíny
 - Zpevněné povrchy
 - Stromy
 - Trávníky a travnatá sportoviště
 - Holá půda
 - Vegetace
 - Lesy
 - Vodní plochy



0 125 250 500 m

