


UNIVERZITA KARLOVA V PRAZE

**Přírodovědecká fakulta**

Katedra aplikované geoinformatiky a kartografie



**Kateřina Jupová**

***Využití objektové klasifikace dat DPZ  
pro monitorování rozptýlené zeleně v krajině***

(Diplomová práce)


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

PRAHA 2007

## **Prohlášení**

Prohlašuji, že jsem předkládanou diplomovou prací s názvem „*Využití objektové klasifikace dat DPZ pro monitorování rozptýlené zeleně v krajině*“ vypracovala samostatně. Použitou literaturu a prameny uvádím v příloženém seznamu.

V Praze dne 1.5.2007

Handwritten signature in black ink, reading "K. Jurek". The signature is written in a cursive style and is positioned above a horizontal dotted line.

podpis studenta

## **Poděkování**

Na tomto místě bych chtěla poděkovat Doc. Ing. Janu Kolářovi, CSc. za odborné vedení práce a cenné rady a připomínky, firmě GISAT a jejím zaměstnancům za poskytnutí družicových dat a umožnění práce se softwarem Definiens Professional a ing. Filipovi Hájkovi za trpělivé odpovědi na moje otázky týkající se objektové klasifikace.

**Vysoká škola:** Univerzita Karlova v Praze

**Fakulta:** Přírodovědecká

**Katedra:** Aplikované geoinformatiky a kartografie

**Školní rok:** 2006 / 2007

# Zadání diplomové práce

**pro** Kateřinu Jupovou

**obor** Kartografie a geoinformatika

**Název tématu:** *Využití objektové klasifikace dat DPZ pro monitorování rozptýlené zeleně v krajině*

## Zásady pro vypracování

Předmětem práce je ověřování možností automatické objektové klasifikace VHR dat DPZ v SW Definiens Professional pro účely mapování prvků rozptýlené zeleně v krajině.

Cílem je nalezení a ověření vhodného klasifikačního postupu pro určování prvků rozptýlené zeleně na podkladu VHR dat.

V průběhu práce budou pomocí softwaru Definiens Professional hledány a testovány specifické příznaky (spektrální, texturální atd.) pro jednotlivé identifikovatelné prvky rozptýlené zeleně. Na základě výsledků budou stanovena pravidla pro hierarchickou klasifikaci. Vytvořená znalostní báze klasifikace bude aplikována na družicový snímek modelového území. Výsledek klasifikace a navržený postup bude posouzen z hlediska efektivnosti a srovnán s jinými způsoby klasifikace.

**Rozsah grafických prací:** 5 - 10 stran

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

**Seznam odborné literatury:**

BAATZ, M. and SCHAPE, A. (2000): Multiresolution Segmentation - An Optimization Approach For High Duality Multi-Scale Image Segmentation. *Angewandte Geographische Informationsverarbeitung XII*, Ed. J. Strobl et al. AGIT Symposium, Salzburg, Germany, 2000. pp. 12-23.

BENZ, U., HOFMANN, P., WILLHAUCK, G., LINGENFELDER, I. and M. HEYEN (2004): Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. In *ISPRS Journal of Photogrammetry and Remote Sensing* 58 (2004), 239-258

BLASCHKE, T., S. LANG and M.S.MÖLLER (2005): Object-based analysis of remote sensing data for landscape monitoring. Recent developments, *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*, Goiania, Brasil, 16-21 abril 2005, INPE, p. 2879-2885

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

MOSKAL, L. (2004): Historical landscape visualization of the wilson´s creek national battlefield based on object oriented tree detection method from ikonos imagery. *Proceedings of the ASPRS 2004 Annual Conference*, Denver, USA. May 23-28.

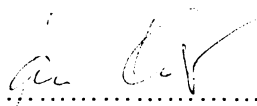
Obnova plošné a bodové zeleně v krajině (2001). *Sborník přednášek mezinárodního semináře*, Brno.

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

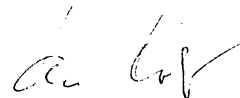
Konzultant diplomové práce: Doc. RNDr. Zdeněk Lipský, CSc.

Datum zadání diplomové práce: 12. 1. 2007

Termín odevzdání diplomové práce: 4. 5. 2007



.....  
Vedoucí diplomové práce



.....  
Vedoucí katedry

V Praze dne

## OBSAH

<b>1. Úvod</b>	<b>3</b>
1.1. Cíl práce	4
<b>2. Rozptýlená zeleň v krajině</b>	<b>5</b>
2.1. Rozptýlená zeleň	5
2.2. Ochrana a monitorování rozptýlené zeleně	6
<b>3. Objektová analýza dat DPZ</b>	<b>7</b>
3.1. Princip objektové analýzy	7
3.2. Vývoj zájmu o objektovou analýzu	8
3.3. Problematika objektové analýzy dat v literatuře	9
3.3.1. Literatura věnovaná objektové klasifikaci obecně	9
3.3.2. Čeští autoři věnující se objektové klasifikaci	11
3.3.3. Projekty využívající objektovou klasifikaci k detekci stromové a keřové zeleně	12
3.4. Přínosy objektové analýzy dat	13
<b>4. Segmentace obrazu</b>	<b>15</b>
4.1. Multiměřítková segmentace	16
4.1.1. Literatura věnující se algoritmu multiměřítkové segmentace	16
4.1.2. Charakteristika multiměřítkové segmentace	17
4.1.3. Definice heterogenity pro proces multiměřítkové segmentace	18
4.1.4. Segmentační parametry	20
4.1.5. Změna heterogenity při spojení dvou objektů	22
<b>5. Klasifikace objektů</b>	<b>24</b>
5.1. Princip klasifikace	24
5.2. Specifika objektové klasifikace	24
5.3. Klasifikační postupy realizované v softwaru Definiens Professional	25
5.3.1. Klasifikace pomocí funkcí příslušnosti	25
5.3.2. Klasifikační metoda nejbližšího souseda	26
<b>6. Data a metody</b>	<b>27</b>
6.1. Vstupní data	27
6.2. Modelová oblast	28
6.3. Charakteristika prvků rozptýlené zeleně z hlediska klasifikace dat DPZ	29
6.4. Příprava pro automatickou klasifikaci	30

6.4.1. Vytvoření masky lesů, zastavěných ploch a vodních ploch	30
6.4.2. Vizuální interpretace dat	31
6.5. Automatická klasifikace	32
6.5.1. Segmentace snímku	33
6.5.2. Srovnávací klasifikace metodou nejbližšího souseda	34
6.5.3. Klasifikace pomocí funkcí příslušnosti	37
6.5.4. Hodnocení přesnosti klasifikace	38
<b>7. Vlastní práce</b>	<b>40</b>
7.1. Vizuální interpretace dat	40
7.2. Automatická klasifikace	41
7.2.1. Chování algoritmu multiměřítkové segmentace	42
7.2.2. Vliv hodnot parametrů segmentace na přesnost srovnávací klasifikace pomocí metody nejbližšího souseda	48
7.2.3. Klasifikace pomocí funkcí příslušnosti	53
<b>8. Výsledky</b>	<b>62</b>
8.1. Optimální segmentační parametry	63
8.2. Dosažená klasifikační přesnost	63
8.2.1. Zdroje klasifikačních nepřesností	65
8.3. Srovnání použitých klasifikačních metod	66
8.4. Srovnání vizuální interpretace a automatické objektové klasifikace pro účely monitorování prvků rozptýlené zeleně v krajině	66
<b>9. Diskuse</b>	<b>67</b>
<b>10. Závěr</b>	<b>69</b>
<b>Seznam použitých zkratk</b>	<b>70</b>
<b>Seznam literatury</b>	<b>71</b>
<b>Seznam internetových zdrojů</b>	<b>75</b>
<b>Seznam obrázků</b>	<b>76</b>
<b>Abstrakt</b>	<b>78</b>

# 1 ÚVOD

Rozptýlená zeleň zastává v krajině mnoho důležitých funkcí. Významně se podílí na utváření krajinného rázu a současně je přínosná pro ekologickou hodnotu krajiny. V minulosti byly prvky rozptýlené zeleně přehlíženy, často i rušeny na úkor produkční hodnoty krajiny. Docházelo k rozorávání mezí, rušení krajinných prvků a kácení stromů. V současné době je již v zákoně zanesena povinnost zachovávání těchto prvků a jejich rušení je trestáno finančním postihem. Kontrola dodržování těchto nařízení ovšem vyžaduje přehled o množství, lokalizaci a stavu těchto prvků. To je důvod, proč se objevují požadavky na monitorování rozptýlené zeleně v krajině. Jejich sledování dosud probíhalo pouze na úrovni terénního šetření, případně vizuální interpretace leteckých fotografií. Časová i finanční náročnost těchto způsobů monitorování vede k požadavkům na hledání jiných, efektivnějších metod.

Využití dat dálkového průzkumu Země pro účely sledování krajiny má bohatou tradici. Se zvyšováním prostorového rozlišení družicových dat dochází i k rozšiřování okruhu aplikací, pro které je možno tato data použít. V současnosti již běžně dostupná data vysokého rozlišení umožňují sledovat objekty na zemském povrchu v mnohem detailnějším měřítku. Tradiční pixelové klasifikační přístupy nejsou však již pro takto vysoce texturovaná data dostačující. Proto dochází k jejich nahrazování novými klasifikačními přístupy. Takovým přístupem je právě v současnosti hojně používaná metoda objektové klasifikace.



## 1.1 Cíl práce

Předmětem této práce je ověření možnosti využití objektové klasifikace družicových dat vysokého rozlišení pro účely monitorování prvků rozptýlené zeleně v krajině.

K tomuto účelu je využit software Definiens Professional a v něm integrované segmentační a klasifikační algoritmy.

Cílem je nalezení vhodného postupu pro monitorování prvků rozptýlené zeleně v krajině na podkladu dat vysokého rozlišení (v tomto případě snímku družice IKONOS). Na základě charakteristiky prvků rozptýlené zeleně jsou na výřezu snímku hledány optimální segmentační parametry a následně specifické příznaky využitelné pro klasifikaci. Vytvořená znalostní báze klasifikace bude aplikována na družicový snímek modelového území o rozloze  $10 \times 10 \text{ km}^2$ .

Takto vytvořený klasifikační postup by měl být maximálně automatizovaný a metoda použitelná i pro jiné podobné typy dat. Postup bude zhodnocen z hlediska využitelnosti a efektivity pro případné reálné monitorování prvků rozptýlené zeleně a srovnán s dosud používanou metodou vizuální interpretace dat.

Aplikace vzniklé klasifikační metody na družicová data zachycující území většího rozsahu by měla vést k získání dosud neexistujícího přehledu o prvcích rozptýlené zeleně v krajině na území ČR a umožnit sledování případných změn, které mohly nastat v rozmístění těchto prvků v čase.

## 2 ROZPTÝLENÁ ZELEŇ V KRAJINĚ

### 2.1 Rozptýlená zeleň

Rozptýlená zeleň je termín používaný v územním a krajinném plánování. Zahnuje jednotlivé dřeviny nebo jejich porosty rostoucí rozptýleně ve volné krajině – ať už na zemědělské či nezemědělské půdě.

Prvky rozptýlené zeleně mají různý původ – zeleň může v krajině růst spontánně, či být záměrně vysazená. (Obnova plošné a bodové zeleně v krajině, 2001). Mohou mít rozmanitý půdorys, prostorovou podobu a druhovou skladbu. V katastru nemovitostí nejsou zapsány jako les ani jako zemědělská půda.

Ve starší odborné literatuře můžeme pro tyto porosty nalézt označení nelesní nebo také mimolesní, roztroušená, rozvinutá, mozaikovitá či vysoká zeleň. V novější literatuře se místo toho můžeme setkat s termínem dřevinné vegetační prvky. A v současnosti platné legislativě, tedy zákoně 114/1992 Sb., o ochraně přírody a krajiny a jeho prováděcí vyhlášce č. 395/1992 Sb., jsou tyto prvky označeny jako dřeviny rostoucí mimo les. (URL4)

Prvky rozptýlené zeleně představují charakteristickou součást krajinné struktury, která vznikala v závislosti na způsobu dlouhodobého využívání území. Jsou nezbytnou součástí mnoha procesů probíhajících v krajině a úzce navazují na jiné přírodní i člověkem vytvořené prvky v území. Ovlivňují estetickou i biologickou úroveň krajiny, mají vliv na mikroklimatický režim, hygienické podmínky v krajině, její obyvatelnost či rekreační hodnotu. Funkčnost těchto prvků přitom závisí zejména na jejich prostorovém uspořádání v území, na druhové skladbě a věku, výškové struktuře, kvalitě a množství. (URL4) Nacházejí se ve všech typech krajiny, přičemž v každém krajinném typu jsou jiné nároky na jejich optimální zastoupení. (Obnova plošné a bodové zeleně v krajině, 2001)

## 2.2 Ochrana a monitorování rozptýlené zeleně

Během druhé poloviny dvacátého století nebyl na prvky rozptýlené zeleně brán ohled. Docházelo k jejich rušení v zájmu rozšiřování ploch orné půdy a zvyšování zemědělské produkce. Potřeba zachování prvků rozptýlené zeleně začala být sledována teprve v nedávné minulosti. Se vzrůstajícím důrazem kladeným na ekologické hodnoty a ochranu přírody a krajiny se objevila i potřeba sledovat krajinu v jejím nejdetailnějším měřítku – včetně prvků rozptýlené zeleně.

V současnosti je ochrana rozptýlené zeleně v České republice ošetřena zákonem č. 114/1992 Sb., o ochraně přírody a krajiny, ve znění pozdějších předpisů. Tento zákon zajišťuje obecnou ochranu všech druhů planě rostoucích rostlin a volně žijících živočichů a také ochranu dřevin rostoucích mimo les. V paragrafu 8 tohoto zákona jsou definovány podmínky k získání povolení ke kácení dřevin rostoucích mimo les. Za nedodržení těchto podmínek hrozí právnickým i fyzickým osobám při výkonu podnikatelské činnosti pokuta až do výše 500 000 Kč. Zemědělci, kteří pobírají finanční podporu v rámci jednotné platby na plochu zemědělské půdy dle nařízení vlády č. 144/2005 Sb., ve znění pozdějších předpisů, musí na dotčených pozemcích hospodařit v souladu s dobrými zemědělskými a environmentálními podmínkami. Jednou z podmínek poskytnutí této platby na plochu je mimo jiné i nerušení krajinných prvků – mezi které patří například meze, terasy a větrolamy. (Rozptýlená zeleň v krajině a zemědělská dotační politika, 2006)

Dlouhotrvající absence zájmu o rozptýlenou zeleň je příčinou toho, že v ČR zatím nebyly krajinné prvky monitorovány. Proto neexistuje přehled o jejich množství, rozloze a případně dalších charakteristikách. Pro účely kontroly dodržování podmínek stanovených zákonem je nutné takový přehled získat.

K získání přehledu o prvcích rozptýlené zeleně v krajině a možnosti zachycení případných změn v rozmístění či kvantitě těchto prvků v čase by mohla vést právě aplikace metod objektové klasifikace na data vysokého rozlišení DPZ.

## 3 OBJEKTOVÁ ANALÝZA DAT DÁLKOVÉHO PRŮZKUMU ZEMĚ

### 3.1 Princip objektové analýzy

Jak je patrné již z názvu, objektově orientovaná analýza obrazových dat je založena na tzv. obrazových objektech, tedy lokálních skupinách pixelů. Tyto objekty jsou základní jednotkou obrazu, nesoucí informaci potřebnou k jeho analýze.

Objektová analýza sestává z primární segmentace dat do obrazových objektů a následné klasifikace těchto objektů. V současnosti tato metoda představuje nejpoužívanější postup v oblasti klasifikace dat dálkového průzkumu Země. (URL3)

Většina aplikací využívajících tento klasifikační postup je spojena s programem Definiens Professional (dříve eCognition) ve kterém je tato metoda implementována. Zmíněný software je také spojen s patentovaným segmentačním algoritmem multiměřítkové segmentace.

Tento způsob analýzy je vhodný zejména pro vysoce texturované typy dat, jakými jsou družicová data vysokého rozlišení, radarová data či letecké fotografie. Spojování jednotlivých pixelů do homogenních objektů s sebou nese řadu výhod. Informační hodnota těchto objektů je vyšší než u jednotlivých pixelů. Ke spektrální informaci přibývá informace o vnitřní textuře objektu, o jeho prostorových vlastnostech či informace kontextuální. Tato klasifikační metoda zároveň umožňuje vytvářet hierarchie. Taková hierarchie je vytvořena z několika měřítkových úrovní objektů, z nichž každá obsahuje objekty jiné průměrné velikosti. Právě tento postup je vhodný pro monitorování krajiny typické svou hierarchičností a různou velikostí zájmových objektů pro různé aplikace.

Objektová analýza navíc představuje jakési propojení tradičních pixelových klasifikačních metod založených na spektrálních příznacích a metod GIS. Vzniklé obrazové objekty ve formě vektorových polygonů jsou propojeny s databází, která nese informace o jejich vlastnostech a umožňuje provádět např. prostorové analýzy na úrovni těchto polygonů.

### 3.2 Vývoj zájmu o objektovou analýzu dat

První zmínky o potřebě zahrnout do analýzy obrazu dálkového průzkumu Země prostorový kontext se objevily již v sedmdesátých letech. Kettig a Landgrebe (1976) předpokládali, že specifickou spektrální distribuci třídy lze vystihnout pomocí lokální skupiny pixelů. K možnosti úspěšné realizace této myšlenky bylo však nejdříve nutné vyřešit otázku segmentace obrazu.

V nastoleném směru výzkumu pokračovali Cross a Mason (1988), kteří k segmentaci použili techniku quad tree. Gorte (1998) upozorňuje na závažný nedostatek pozornosti věnovaný potenciálu segmentace v tehdejší odborné literatuře týkající se zpracování dat dálkového průzkumu a zejména pak literatuře pro výukové účely v této oblasti.

Konec devadesátých let je provázen výrazným nárůstem zájmu o techniky segmentace obrazu a databázové (SQL) aplikace založené na obrazových objektech. (de Kok et al. (1999))

Od roku 1995 se v Mnichově soustředil tým Delphi2 e-Cognition na vývoj softwaru pro objektově orientovanou analýzu obrazu. Vyvíjený software měl kombinovat vylepšenou segmentační techniku s databází hierarchicky propojených obrazových objektů. (de Kok et al. (1999)). Právě komerční rozšíření tohoto softwaru nazvaného eCognition přispělo k rozšíření počtu aplikací využívajících objektovou klasifikaci dat dálkového průzkumu Země.

Během posledních dvou desetiletí zaznamenaly objektově orientované analýzy dat dálkového průzkumu Země velký pokrok. De Kok et al. (1999) vyjadřuje přesvědčení, že tato strategie není jen krátkodobá módní záležitost, ale naopak bude v blízké budoucnosti dominovat v oblasti výzkumu zpracování dat dálkového průzkumu.

### **3.3 Problematika objektové analýzy dat v literatuře**

Problematika objektově orientované analýzy dat dálkového průzkumu Země je poměrně nového data. První práce věnované výhradně této tematice se objevují koncem devadesátých let. První z nich se zaměřují především na popis této nové klasifikační metody, jejích výhod ve srovnání s dosud používanou klasifikací pixelovou.

#### **3.3.1 Literatura věnovaná objektové klasifikaci obecně**

Tuto novou klasifikační metodu vyvinutou Delphi2 Creative Technologies použitou v softwaru pro objektově orientované analýzy dat představují Baatz a Schäpe (1999). Vysvětlují důležitost a princip propojení DPZ a GIS, které sebou tato metoda nese. Specifičnost metody podle nich spočívá ve třech charakteristikách – orientaci na objekty, poskytování informace současně ve více měřítcích a popisu a analýze obrazové informace ve smyslu významové sítě. Vyzdvihují skutečnost, že se metoda skládá ze dvou základních kroků: segmentace vytvářející hierarchickou síť objektů a následné klasifikace. Článek vznikl ještě před uvedením softwaru eCognition na trh – autoři zde uvádějí, že software využívající metody objektové klasifikace bude na trhu dostupný v lednu 2000.

Na nedostatečnost pixelové klasifikace založené na spektrálních příznacích pro popis komplexních reálných systémů upozorňují Blaschke a Strobl (2001). Zmiňují skutečnost, že metoda pixelové klasifikace vznikla současně s vypuštěním první družice Landsat na oběžnou dráhu v roce 1972 se od té doby v podstatě nevyvíjela. Podle nich je nutné do klasifikačního přístupu více zahrnout i kontextuální informace, jako jsou poloha, vzdálenost či sousedství. Dále uvádějí, že jedním z hlavních důvodů snahy o rozdělení obrazu na relativně homogenní regiony je skutečnost, že data dálkového průzkumu mají charakteristickou texturu, se kterou se většina klasifikátorů využívajících pouze spektrální příznaky nedokáže ideálně vypořádat.

Princip objektové klasifikace a vytváření klasifikačních pravidel pomocí zásad fuzzy logiky popisují Benz et al. (2004). Studie vyzdvihuje zejména přínos kontextuální informace obsažené v hierarchické síti obrazových objektů pro analýzu dat dálkového průzkumu Země.

Význam objektové klasifikace dat dálkového průzkumu pro monitorování krajiny diskutují Blaschke et al. (2005). Autoři opět vyzdvihují důležitost kontextuální informace při sledování krajiny na základě dat dálkového průzkumu. Právě tento kontext podle nich umožňuje určit nejen třídu krajinného pokryvu (land cover), ale i způsob využití půdy (land use). Druhou výhodou, kterou Blaschke et al. vidí v objektové klasifikaci, je možnost porovnání objektů na různých měřítkových úrovních. Komplexní systémy vyskytující se v krajině jsou typické svou hierarchičností, mají tedy několik měřítkových úrovní. Proto je neskutné nalézt jedno ideální měřítko vhodné ke sledování krajiny. Tento úkol je neřešitelný pro pixelovou klasifikaci, limitovanou úrovní pixelu jako jedinou možnou měřítkovou úrovní pro klasifikaci krajiny. Naopak objektová klasifikace je schopna právě tuto víceúrovňovost či hierarchičnost dobře postihnout.

Autorem četných studií popisujících metodu objektové analýzy dat je de Kok. Tento autor se zabývá principy metody objektové analýzy dat obecně a současně i aplikacemi této metody pro účely klasifikace krajiny (de Kok et al., 1999, de Kok et al., 2000).

### 3.3.2 Čeští autoři věnující se objektové klasifikaci

Práce českých autorů zabývajících se objektovou klasifikací nejsou příliš četné. Ve většině případů se jedná o diplomové práce.

Seznámení s metodou objektové klasifikace nabízí článek Halounové (2002). Autorka zde představuje tuto novou klasifikační metodu a podrobněji se zabývá softwarem eCognition a jeho funkcemi. Jedná se v podstatě o jediný ucelenější popis metody objektové klasifikace v češtině. Přínosem je též překlad specifických termínů používaných v oblasti objektové analýzy obrazu do češtiny. Halounová v tomto příspěvku také zmiňuje dvě diplomové práce řešené na katedře mapování a kartografie ČVUT, v první z nich se Štolba (2001) zabývá klasifikací využití území v oblasti Severočeské hnědouhelné pánve na podkladu dat družice Landsat, v druhé práci Žambochová (2001) využívá metodu objektové analýzy ke klasifikaci černobílých leteckých snímků. Problematice objektové klasifikace městské zeleně se ve své diplomové práci věnuje Komrska (2006), který současně detailně popisuje funkci softwaru eCognition.

Soustavně se z českých autorů zabývá objektovou klasifikací dat DPZ pouze Hájek, který využívá metodu objektové klasifikace a software eCognition (Definiens Professional) pro aplikace lesnického managementu, konkrétně klasifikaci druhové skladby lesa na základě dat družice IKONOS (Hájek 2006). Jeho práce jsou ale většinou psané v angličtině. Hájek (2006) řeší úlohy klasifikace druhové skladby lesa pomocí rozšiřování příznakového prostoru o přídavné kanály (např. texturální kanály, IHS transformace, Sobelův detektor hran, medianové filtry). Využívá hierarchie objektů o třech měřítkových úrovních, jednotlivé klasifikační třídy popisuje pomocí příslušnostních funkcí založených na principech fuzzy logiky.

Klasifikaci družicových dat s využitím metod objektové analýzy se věnuje i Tuček (2002, 2005). Tento slovenský autor se zabývá extrakcí korun jednotlivých stromů v lese na základě dat vysokého prostorového rozlišení.



### 3.3.3 Projekty využívající objektovou klasifikaci k detekci stromové a keřové zeleně

Pro tuto práci jsou stěžejní úlohy zaměřené na specifický druh zájmových objektů klasifikace, tedy stromovou a keřovou zeleň. Literatura řešící detekci těchto objektů zeleně pomocí objektové klasifikace se v naprosté většině případů zabývá zelení ve městech. Nicméně poznatky z těchto prací lze uplatnit pro detekci zeleně obecně.

Metodu objektové klasifikace dat dálkového průzkumu Země pro detekci stromů v krajině úspěšně využila Moskal (2004). Ve své práci aplikovala tyto klasifikační metody na historické letecké fotografie i současná družicová data IKONOS.

Problematice detekce stromové a keřové zeleně v prostoru městské zástavby pomocí objektové klasifikace VHR dat dálkového průzkumu se věnují následující autoři.

Zhang a Feng (2005) klasifikují městskou zeleň na podkladu pansharpovaných dat družice IKONOS. Detekce stromové zeleně probíhá ve dvou krocích. Nejprve dochází k odlišení vegetačních objektů od ostatních, ve druhém kroku pak rozlišují travu a stromy. Pro každý krok je využita jiná měřítková úroveň a jiný klasifikační příznakový prostor. Rozdělení vegetačních a nevegetačních objektů proběhlo s užitím měřítkového parametru 5 a příznakového prostoru skládajícího se ze spektrálních příznaků. K odlišení stromové vegetace byl pak použit měřítkový parametr 100 a ke klasifikaci směrodatné odchylky ve spektrálních pásmech, reprezentující vnitřní texturu objektů. Obě klasifikace probíhají pomocí klasifikační metody nejbližšího souseda. Bylo dosaženo velmi vysoké klasifikační přesnosti. Producentská přesnost u třídy tráva přesahuje 91%, u třídy stromů pak dokonce 98%. Klasifikace však problíhala pouze na malém výřezu snímku (800 x 900 pixelů).

Klasifikační metodu nejbližšího souseda využívá k detekci městské zeleně také Mathieu (2005). I on používá dvě různé měřítkové úrovně, z nichž každá je vhodná pro jinou velikost cílových objektů. Ze 17 klasifikačních tříd bylo úspěšně odlišeno 10. Dosažená celková klasifikační přesnost byla 92%, kappa koeficient 89%. Příznakový prostor byl složen ze spektrálních příznaků, jejich směrodatných odchylek a kompaktnosti objektů. K oddělení různě velkých objektů byly použity dva různé hodnoty měřítkového parametru: 22 a 40.

Klasifikací městské zeleně na podkladu digitálních leteckých fotografií se zabývá Zhang (2001). Vyzdvihuje zvýšení klasifikační přesnosti, ke kterému vedlo zahrnutí texturních příznaků do příznakového prostoru.

### 3.4 Přínosy objektové analýzy dat

Na přínosech objektové klasifikace a nutnosti jejího zavedení do oblasti analýz obrazových dat dálkového průzkumu Země se shoduje řada autorů.

Významnou roli má objektová analýza zejména v dnes stále početnějších aplikacích využívajících data vysokého prostorového rozlišení. Letecké fotografie a družicová data vysokého rozlišení umožňují sledovat povrch Země na velmi detailní úrovni – prostorové rozlišení takových dat se může pohybovat na úrovni několika desítek centimetrů. Pixelové klasifikační metody s úspěchem používané pro klasifikaci dat nízkého a středního rozlišení, jsou však pro takto vysoce texturovaná data (mající tendenci k salt and pepper efektu) často nedostačující. Analýza takových dat může být v mnoha případech úspěšná pouze pokud je obraz před klasifikací rozdělen (segmentován) do smysluplných homogenních oblastí. (Baatz, Schäpe, 2000) Na problematiku smíšených pixelů zejména u dat vysokého rozlišení upozorňují i de Kok et al. (1999) – i oni vidí řešení tohoto problému v analýze spektrálních vlastností objektů, nikoli jednotlivých pixelů. Carleer (2005) zmiňuje konkrétně skutečnost, že nárůst variability spektrálních hodnot pixelů v rámci jedné třídy land cover vede ke snížení statistické separability mezi třídami ve spektrálním příznakovém prostoru, což má za následek snížení klasifikační přesnosti při použití tradičních pixelových metod.

Kromě zmíněné eliminace vlivu textury obrazu a lokálních rozdílů spektrálních hodnot pixelů jedné třídy s sebou objektová klasifikace nese především zvýšení informační hodnoty, kterou má základní klasifikační jednotka.

Pixelová analýza zachází se třemi základními příznaky jednotlivých pixelů – polohou, velikostí a hodnotou. Důležitou prostorovou informací lze získat pouze pomocí filtrovacích operací, kdy je výsledná hodnota připsána centrálnímu pixelu. Podle de Koka et al. (1999) lze objekt považovat za jakýsi čtvrtý atribut pixelu, nesoucí informaci o jeho prostorovém kontextu – tedy o tom ke které prostorové skupině pixelů náleží.

Vytvoření dalších příznaků souvisejících s vnitřní texturou, tvarem a polohou objektů ve snímku vyzdvihuje také Carleer (2005). Tento nárůst počtu příznaků umožňujících rozlišení jednotlivých tříd pomáhá kompenzovat nevýhodu VHR dat spočívající jejich v poměrně nízkém spektrálním rozlišení a zvýšit klasifikační přesnost u spektrálně heterogenních tříd.

Baatz a Schäpe (2000) upozorňují na velký význam sémantiky obrazu pro interpretaci obrazových dat DPZ. Zejména u dat vysokého rozlišení není ve většině případů informace potřebná ke správnému pochopení významu obrazu obsažena v jednotlivých pixelech, ale ve smysluplných objektech a jejich vzájemných vztazích.

Mnozí autoři jako např. Gorte (1998) a de Kok et al. (1999) vyzdvihují také možnost propojení tradičních metod klasifikace rastrových dat a GIS, kterou s sebou objektová analýza nese.

Propojení obrazových objektů s databází (obsahující informace o veškerých attributech objektů, včetně atributů týkajících se sousedství, hierarchie atd.) umožňuje GIS analýzy. Podle de Koka et al. (1999) je integrace těchto dvou typů zpracování dat v současnosti téměř nutností. Stejný autor navíc připomíná, že objektová klasifikace umožňuje zahrnout do jedné analýzy data z různých zdrojů a rozdílného rozlišení, a stejně tak i data různých formátů.

V neposlední řadě s sebou přechod k objektové klasifikaci nese snížení rozsahu datových sad (Haberäcker, 1995) a tedy i kratší dobu zpracování dat. To je v případě rozsáhlých datových sad typických pro data dálkového průzkumu Země velmi vítaná skutečnost.

Jak uvádí např. de Kok (1999), je objektově orientovaný přístup bližší lidskému vnímání a napomáhá správnému pochopení obrazových dat.

Nevýhodou objektové analýzy dat je podle Zhanga (2006) skutečnost, že kvalita výsledné klasifikace je velmi závislá na znalostech a zkušenostech uživatele, který definuje parametry pro segmentaci. Na tuto nevýhodu upozorňují také Schiewe et al. (2001), kteří vyzdvihují časovou náročnost hledání těchto optimálních parametrů, probíhajícího většinou metodou pokus omyl. Znalost zájmových objektů a vlastností senzoru ze strany uživatele vyžaduje i stanovení příznaků vhodných pro klasifikaci. (Hay et al., 2003; De Kok, 1999)

## 4 SEGMENTACE OBRAZU

Prvním a zásadním krokem procesu objektové klasifikace je segmentace obrazových dat. Segmentací se obecně nazývají procesy rozdělení spojitého rastrového obrazu do oddělených regionů (objektů). Takto získané obrazové objekty by měly v ideálním případě co nejvíce odpovídat reálným objektům na zemském povrchu.

Úspěšná segmentace obrazu je nezbytnou podmínkou pro jeho objektově orientované zpracování (Baatz, Schäpe, 2000). Kvalita segmentace je jedním z hlavních faktorů ovlivňujících výslednou klasifikaci.

Existuje nesčetné množství způsobů, jak daný obraz na tyto subregiony rozdělit. Segmentační algoritmy jsou již mnoho let jedním z hlavních předmětů výzkumu v oblasti analýzy dat dálkového průzkumu. Během této doby bylo vyvinuto velké množství rozmanitých segmentačních přístupů. Nicméně jen málo z nich vede ke kvalitativně přesvědčivým výsledkům, a zároveň je použitelných pro širokou škálu typů dat a řešených problémů.

Mnohé z používaných algoritmů byly vyvinuty pro automatickou extrakci objektů zájmu z obrazu a jsou vhodné jen pro specifický druh aplikací. Takové strategie zahrnují využití značného množství sémantické informace, která je ve většině případů potřebná k získání kvalitního finálního výsledku. Často vedou k vytvoření vysoce specifických algoritmů aplikovatelných pouze na omezený okruh řešených problémů a typů obrazových dat. (Baatz, Schäpe, 2000)

## **4.1 Multiměřítková segmentace (*multiresolution segmentation*)**

Delphi2 Creative Technologies GmbH vyvinula segmentační algoritmus určený k vytvoření homogenních obrazových objektů. Tento algoritmus využívaný v softwaru Definiens Professional, dříve eCognition, se nazývá multiměřítková segmentace (*multiresolution segmentation*).

### **4.1.1 Literatura věnující se algoritmu multiměřítkové segmentace**

Segmentačnímu algoritmu multiměřítkové segmentace je věnována velká pozornost v literatuře spojené s objektovou klasifikací obecně. Tato segmentační metoda je podrobně popsána v úvodu některých prací využívajících metody objektové analýzy dat (např. Benz et al., 2004).

Výhradně algoritmu multiměřítkové segmentace se ve své studii věnují Baatz a Schäpe (2000). Rozebírají zde požadavky na výsledek segmentace, definici heterogenity a diskutují kvalitu metody.

Algoritmus multiměřítkové segmentace používaný v Definiens Professional je popsán i v manuálu pro software eCognition verze 4 (Definiens Imaging 2004). Ten se zabývá jak principem tohoto segmentačního algoritmu, tak i významem segmentačních parametrů definovatelných v softwaru, jejichž nastavením může uživatel zásadně ovlivnit vlastnosti obrazových objektů vzniklých při segmentaci a tedy i kvalitu výsledné klasifikace.

#### 4.1.2 Charakteristika multiměřítkové segmentace

Multiměřítková segmentace je neřízený univerzální segmentační algoritmus, použitelný pro širokou škálu typů dat a aplikací. Umožňuje segmentaci obrazu nezávisle na jeho rozlišení a je schopen se velmi kvalitně vypořádat s lokálními kontrasty v obraze. Proces může probíhat simultánně na libovolném množství kanálů. Metoda je vhodná zejména pro vysoce texturovaná data, jakými jsou právě data VHR. (Definiens Imaging 2004)

Výsledné obrazové objekty vzniklé pomocí tohoto algoritmu nelze ve většině případů ztotožnit s reálnými objekty nacházejícími se na zemském povrchu. Jedná se spíše o obrazové primitivy, tedy jakési základní jednotky obrazu obsahující informaci potřebnou pro další analýzu a sloužící jako výchozí materiál pro následnou klasifikaci, případně další segmentaci či postklasifikační úpravy. (Baatz, Schäpe, 2000) Z tohoto pohledu jsou ideálním výsledkem segmentace objekty, které poskytují optimální informaci pro další zpracování. (Definiens Imaging 2004) Objekty by měly být maximálně homogenní a jejich velikost srovnatelná. Průměrná velikost objektů závisí na účelu požadované aplikace.

Multiměřítková segmentace je proces spojování regionů začínající na úrovni pixelů. Menší objekty jsou v postupných krocích slučovány do objektů větších. Během tohoto procesu dochází k *minimalizaci vážené heterogenity* výsledných obrazových objektů. V každém kroku segmentace dochází ke sloučení dvou sousedních segmentů tak, aby byl nárůst heterogenity provázející tento proces minimální. Pokud tento minimální nárůst heterogenity překročí předem stanovený práh (definovaný uživatelem pomocí měřítkového parametru), dojde k zastavení procesu.

Multiměřítková segmentace je zároveň procedura lokální optimalizace. Aby byly vzniklé objekty podobné velikosti a tedy navzájem srovnatelné, simuluje algoritmus při každém kroku simultánní růst objektů na všech místech scény a také konečnou podobu výsledku. (Definiens Imaging 2004)

### 4.1.3 Definice heterogenity pro proces multiměřítkové segmentace

Zásadní pro proces multiměřítkové segmentace je definice výše zmíněné heterogenity, charakterizující jednotlivé objekty a současně i stav v celém obraze.

#### *Spektrální heterogenita*

Pro popis spektrální heterogenity je použita suma směrodatných odchylek spektrálních hodnot v každém spektrálním pásmu vážená vahami pro dané pásmo. Heterogenita pro spektrální pásmo  $c$  je tedy definována následovně:

$$h = \sum_c w_c \cdot \sigma_c$$

(Definiens Imaging 2004)

Přičemž  $w_c$  je váha pro spektrální pásmo  $c$  stanovená uživatelem a  $\sigma_c$  směrodatná odchylka spektrálních hodnot v tomto pásmu.

Zejména v případě použití vysoce texturovaných dat s velkými lokálními rozdíly spektrálních hodnot pixelů, jakými jsou i VHR družicová data, vede výhradní minimalizace spektrální heterogenity často k vytváření rozvětvených segmentů s fraktálně tvarovanou hranicí. To je hlavní důvod pro zavedení tvarového (prostorového) kritéria omezujícího tuto spektrální heterogenitu.

## *Tvarová heterogenita*

Tento ukazatel heterogenity vyjadřuje odchylku objektů od ideálního tvaru.

Pro řízení procesu multiměřítkové segmentace jsou používány dva různé druhy vyjádření tvarové heterogenity.

### *Odchýlení od kompaktního tvaru*

V první případě je tvarová heterogenita definována jako odchylka od kompaktního tvaru. Míra odchylky od kompaktního tvaru objektu je vyjádřena podílem délky hranice objektu a druhé odmocniny z velikosti objektu:

$$h = \frac{l}{\sqrt{n}}$$

(Definiens Imaging 2004)

Přičemž  $l$  je délka hranice objektu a  $n$  počet pixelů tvořících tento objekt.

### *Odchýlení od hladkého tvaru*

Druhou možností pro popis tvarové heterogenity je její vyjádření mírou odchýlení od ideálně hladkého tvaru. To je realizováno pomocí podílu skutečné délky hranice objektu a nejkratší možné délky hranice objektu dané obvodem čtverce ohraničujícího objekt se stranami rovnoběžnými s rastrem.

$$h = \frac{l}{b}$$

(Definiens Imaging 2004)

Kde  $l$  je opět délka skutečné hranice objektu a  $b$  je obvod čtverce ohraničujícího objekt.

Objekty vzniklé segmentací s použitím kombinace kritérií pro tvarovou a spektrální heterogenitu nemusí být tolik homogenní spektrálně, ale mohou být přijatelnější pro lidské oko. (Definiens Imaging 2004)



#### 4.1.4 Segmentační parametry

Jak již bylo řečeno, multiměřítková segmentace je neřízený segmentační proces, spočívající v minimalizaci celkové heterogenity všech objektů v segmentovaném obraze. Univerzálnost algoritmu, umožňující jeho využití pro různé typy dat a aplikací, vede však zákonitě k potřebě tuto celkovou heterogenitu uživatelsky korigovat.

To se děje pomocí omezení hodnoty maximální přípustné změny heterogenity, ke které smí dojít při spojení dvou obrazových objektů.

Uživatel ovlivňuje jednak míru této heterogenity, jednak podíl její spektrální a tvarové složky. Toto ovlivnění je v softwaru Definiens Professional realizováno pomocí několika parametrů. Hodnoty těchto parametrů mají zásadní vliv na podobu výsledných obrazových objektů a tedy i na kvalitu následné klasifikace. Stanovení hodnot parametrů závisí jednak na vlastnostech použitých dat a jednak na účelu klasifikace – tedy na vlastnostech zájmových objektů, které chce uživatel pomocí klasifikace detekovat.

##### *Měřítkový parametr*

Hlavním parametrem pro segmentaci, vyjadřujícím maximální přípustnou změnu heterogenity, která může nastat při spojení dvou obrazových objektů, je tzv. *měřítkový parametr*. Měřítkový parametr je vyjádřením pro změnu celkové heterogenity – tedy pro součet její spektrální ( $h_{color}$ ) a tvarové ( $h_{shape}$ ) složky:

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

(Definiens Imaging 2004)

Hodnota funkce  $f$  vyjadřuje celkovou změnu heterogenity,  $w$  je váha pro spektrální složku heterogenity.

Hodnota zadaná uživatelem jako měřítkový parametr je přitom v softwaru interně umocněna na druhou. Při porovnávání skutečného nárůstu heterogenity vzniklého při spojení dvou objektů a maximálního přípustného nárůstu je tedy uvažována druhá mocnina měřítkového parametru. Již z názvu parametru je patrné, že jeho hodnota rozhoduje o velikosti obrazových objektů vytvořených při segmentaci.

### ***Tvarový faktor***

Tento parametr udává váhu pro tvarovou složku heterogenity, tedy podíl tvarové složky na celkové heterogenitě.

Hodnota tvarového faktoru se pohybuje v rozmezí od 0 do 0.9. Segmentace tedy nemůže pracovat pouze na základě tvarové složky heterogenity – je nutné brát alespoň minimální ohled na heterogenitu spektrální.

### ***Kompaktnost / hladkost***

Třetí parametr pro segmentační algoritmus představuje podíl složky kompaktnosti a hladkosti (definovaných v kapitole 4.1.3) na tvarovém faktoru. Váha zadávaná uživatelem přitom vyjadřuje podíl kompaktnosti.

#### 4.1.5 Změna heterogenity při spojení dvou objektů

Při spojení dvou objektů ( $o_1, o_2$ ) do objektu  $o_{merge}$  dojde ke změně celkové heterogenity.

Počáteční stav před spojením každých dvou objektů je charakterizován hodnotami heterogenity těchto původních objektů –  $h_1, h_2$ . Celková heterogenita před spojením objektů je tedy  $h_1 + h_2$ . Výsledný objekt vzniklý spojením je charakterizován heterogenitou  $h_{merge}$ . Heterogenity objektů před i po spojení jsou přitom váženy velikostí objektů v pixelech.

**Změnu celkové heterogenity**, ke které dojde při spojení dvou objektů lze proto vyjádřit takto:

$$dh = n_{merge} \cdot h_{merge} - (n_1 \cdot h_1 + n_2 \cdot h_2)$$

bez ohledu na kompozici celkové heterogenity.

**Změna spektrální heterogenity** ( $h_{color}$ ) ke které dojde při spojení dvou objektů je vyjádřena následovně:

$$h_{color} = \sum_c w_c \left( n_{Merge} \cdot \sigma_c^{Merge} - \left( n_{Obj1} \cdot \sigma_c^{Obj1} + n_{Obj2} \cdot \sigma_c^{Obj2} \right) \right)$$

(Definiens Imaging 2004)

Přičemž  $w_c$  je váha pro spektrální pásmo,  $\sigma_c$  směrodatná odchylka hodnot pixelů v tomto spektrálním pásmu a  $n$  je počet pixelů v objektech.

Změna tvarové heterogenity ( $h_{shape}$ ) je vyjádřena pomocí změny heterogenity složek *kompaktnosti* ( $h_{cmpct}$ ) a *hladkosti* ( $h_{smooth}$ ) popsaných následujícími dvěma vztahy:

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

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

(Definiens Imaging 2004)

Kde  $l$  je délka skutečné hranice objektu,  $b$  je obvod čtverce ohraničujícího objekt a  $n$  počet pixelů tvořících tento objekt.

*Celková změna tvarové heterogenity* je tedy vyjádřena následovně:

$$h_{shape} = w_{cmpct} \cdot h_{cmpct} + (1 - w_{cmpct}) \cdot h_{smooth}$$

(Definiens Imaging 2004)

Přičemž  $w$  zde představuje uživatelem definovanou váhu pro kompaktnost.

## 5 KLASIFIKACE OBJEKTŮ

### 5.1 Princip klasifikace

Klasifikací rozumíme proces přiřazování objektů do tříd na základě jejich vlastností (příznaků). Každý objekt je přiřazen do klasifikační třídy podle toho, jakou hodnotu mají jeho příznaky – respektive kde se nachází v příznakovém prostoru.

Příznakovým prostorem se rozumí n rozměrný prostor, ve kterém je poloha daného objektu určena hodnotami jednotlivých příznaků. Lze také říci, že je příznakový prostor rozdělen do určitých regionů a každý objekt je na základě tohoto rozdělení přiřazen k určité třídě, případně k žádné z nich.

### 5.2 Specifika objektové klasifikace

Klasifikace v pojetí objektové analýzy dat je založena na podobných principech jako tradiční pixelové klasifikační metody. Předmětem klasifikace ovšem nejsou jednotlivé pixely, ale obrazové objekty.

Oproti tradičním klasifikačním metodám dochází k rozšiřování příznakového prostoru – tedy ke zvyšování počtu příznaků. Kromě spektrálních příznaků objektů lze využít i příznaky texturální, vyjádřené např. směrodatnou odchylkou spektrálních hodnot pixelů v rámci objektu, příznaky související s tvarem a polohou objektu a zejména kontextuální příznaky založené na významových souvislostech a nebo pozici objektu v klasifikační hierarchii.


## 5.3 Klasifikační postupy realizované v softwaru Definiens Professional

### 5.3.1 Klasifikace pomocí funkcí příslušnosti

V případě, že lze třídu popsat pomocí jednoho či několika málo příznaků, lze využít tzv. *funkcí příslušnosti*. Jedná se o jednoduché jednorozměrné funkce několika typů, které vyjadřují závislost pravděpodobnosti příslušnosti objektu k dané třídě na hodnotě vybraného příznaku. Třidu lze popsat pomocí jedné či kombinací více takových funkcí spojených logickými operátory. Pomocí takové kombinace funkcí lze popsat vícerozměrný příznakový prostor, nicméně takovýto popis nemusí být vždy dostačující ke správné klasifikaci. (Definiens Imaging 2004)

Funkce příslušnosti mohou mít podobu fuzzy funkcí nebo prahování. Ukázky těchto dvou typů příslušnostních funkcí v uživatelském rozhraní softwaru Definiens Professional jsou vidět na *Obrázku 1*.

*Obr. 1 – Ukázka funkcí příslušnosti v uživatelském rozhraní softwaru Definiens Professional.*



Fuzzy přístup je založen na principu neurčitosti. Příslušnost objektu k určité třídě není vyjádřena striktně hodnotami 0 či 1, jako v případě prahování, ale spojitou škálou hodnot pohybujících se v intervalu od 0 do 1 a vyjadřujících pravděpodobnost příslušnosti objektu k dané třídě. Na *Obrázku 1* je jsou vidět dva různé typy funkcí

příslušnosti. První graf představuje fuzzy funkci, druhý prahování. Na ose x je vynesena hodnota příznaku, na ose y pravděpodobnost příslušnosti ke klasifikační třídě, pohybující se v intervalu od 0 do 1.

### **5.3.2 Klasifikační metoda nejbližšího souseda**

V případě, že je popis třídy pomocí kombinací několika jednorozměrných příslušnostních funkcí problematický, je výhodnější využít klasifikátor nejbližšího souseda. Tento klasifikátor je založen na poloze klasifikovaného objektu ve vícerozměrném příznakovém prostoru, respektive na jeho vzdálenosti od vzorku některé ze tříd.

Jako trénovací množiny nejsou použity skupiny pixelů, ale obrazové objekty (vzorky), vybrané uživatelem. V Definiens Professional je realizováno fuzzy provedení klasifikátoru nejbližšího souseda. Ten na základě vlastností vzorků automaticky vygeneruje vícerozměrné příslušnostní funkce popisující rozložení objektů jednotlivých tříd v definovaném vysoko-rozměrném příznakovém prostoru.

Hodnoty příslušnosti objektů ke třídám jsou určeny přiřazením hodnot v intervalu 0 (nulová příslušnost k dané třídě) až 1 (plná příslušnost k dané třídě). Čím blíže se klasifikovaný objekt v příznakovém prostoru nachází ke vzorku třídy, tím vyšší je míra pravděpodobnosti příslušnosti objektu k této třídě. (Definiens Imaging 2004)

## 6 DATA A METODY

### 6.1 Vstupní data

Vstupní data pro tuto práci představují družicová data vysokého prostorového rozlišení pořízené družicí IKONOS v červnu 2005.

Družice IKONOS snímá ve čtyřech spektrálních kanálech v prostorovém rozlišení 4m a v panchromatickém kanálu v metrovém rozlišení.

Přítomnost multispektrálních pásem a zejména NIR pásma umožňuje získat informaci o druhu a stavu snímané vegetace. Vysoké rozlišení panchromatického pásma poskytuje dostatečně kvalitní přídavnou texturální informaci důležitou pro správnou interpretaci některých jevů na zemském povrchu. (URL1)

Pro účel klasifikace prvků rozptýlené zeleně byla použita georeferencovaná a pansharpovaná data ve formátu TIFF v barevné hloubce 8bitů ve všech čtyřech spektrálních pásmech. Pansharpening výrazně zvyšuje interpretabilitu snímku, neboť umožňuje kombinovat barevnou informaci nesenou spektrálními kanály s vysokým prostorovým rozlišením kanálu panchromatického (URL1). Takto upravená data poskytují dostatečnou spektrální i prostorovou informaci pro účely klasifikace prvků rozptýlené zeleně.

Kromě družicových dat byla použita i vektorová data ZABAGED, poskytnutá Českým úřadem zeměměřičským a katastrálním, který je vlastníkem a zároveň pořizovatelem (zpracovávatelem) těchto dat. Přesnost dat odpovídá přesnosti Základní mapy České republiky v měřítku 1:10 000 (ZM10). Vektory databáze jsou opatřeny příslušnými popisnými a kvalitativními atributy. (URL2)


Data ve formátu DGN byla poskytnuta pro celou modelovou oblast 10x10km.



## 6.2 Modelová oblast

Klasifikace probíhala na modelové oblasti o rozloze 10x10 km<sup>2</sup>, situované jihovýchodně od města Vrchlabí v Podkrkonoší. Jedná se o oblast charakterizovanou extenzivním typem zemědělství, hojně zalesněnou, s převahou luk a pastvin nad ornou půdou. Sídla jsou vesnického typu, mají rozptýlený charakter a malou velikost. Rozptýlená zeleň v krajině je poměrně hojná a má rozmanitý charakter.

Obr. 2 – Poloha modelové oblasti v rámci ČR.




Stanovení klasifikačního postupu – tj. hledání optimálních segmentačních parametrů a klasifikačních příznaků probíhalo na testovacím výřezu (*výřez 1*) o velikosti 2150 x 2150 pixelů. Pro posouzení úspěšnosti byly nalezené klasifikační metody aplikovány na jiný srovnávací výřez (*výřez 2*) stejného snímku o velikosti 1800 x 1700 pixelů.

Pravidla stanovená na těchto dvou výřezích jsou následně aplikována na celou modelovou oblast.

### 6.3 Charakteristika prvků rozptýlené zeleně z hlediska klasifikace dat DPZ

Objekty představující prvky rozptýlené zeleně (viz *Obr. 3*) jsou charakterizovány vysokou spektrální variabilitou vnitřních pixelů. Velký podíl těchto vnitřních pixelů reprezentuje stíny. Právě tyto pixely mají nízkou odrazivost ve všech čtyřech spektrálních pásmech - jeví se tedy tmavší než okolí.

*Obr. 3 – Prvek rozptýlené vegetace na snímku IKONOS (barevná syntéza spektrálních pásem v pořadí 432).*



Vzhledem k vysoké spektrální variabilitě pixelů uvnitř objektů představujících prvky rozptýlené zeleně je zřejmé, že pixelový klasifikační přístup založený na spektrálních příznacích není pro klasifikaci tohoto typu objektů vhodný.

Segmentační algoritmus multiměřítkové segmentace má tendenci spojovat právě tyto vysoce texturované lokální skupiny pixelů do menších objektů a oddělovat je od sousedních relativně homogenních oblastí. Takto vzniklé objekty jsou charakterizovány vysokou směrodatnou odchylkou hodnot pixelů ve všech spektrálních pásmech a relativně nízkou světlostí (způsobenou právě hojným výskytem pixelů představujících stíny).

Oddělení těchto objektů od nevegetačních ploch na základě spektrálních pásem nepředstavuje z hlediska klasifikace dat dálkového průzkumu Země velký problém. Mnohem složitější je jejich odlišení od ostatních vegetačních objektů, zejména od objektů představujících louky či pole s vysokou vegetací.

## 6.4 Příprava pro automatickou klasifikaci


### 6.4.1 Vytvoření masky lesů, zastavěných ploch a vodních ploch

Prvním přípravným krokem pro automatickou klasifikaci bylo vytvoření *masky lesů, zastavěných ploch a vodních ploch*.

K tomuto účelu byla využita vektorová data ZABAGED. Formát DGN (nepropojené linie) byl pomocí softwaru ArcMap převeden do polygonové vrstvy ve formátu SHP. Polygony byly tematicky oklasifikovány na základě atributu užívání půdy. Okolo polygonů představujících lesy, vodní plochy a zastavěné plochy byl vytvořen buffer široký 15 metrů a sloučen s vnitřními polygony.

Takto vytvořené polygony byly použity jako maska. Následná manuální interpretace i automatická klasifikace dat probíhala pod touto maskou – zobrazenou na *Obr. 4*.

*Obr. 4 – Maska lesů, zastavěných ploch a vodních ploch vytvořená na základě vektorové vrstvy ZABAGED.*



## 6.4.2 Vizuální interpretace dat


Přípravou pro automatickou klasifikaci byla vizuální interpretace dat provedená pro celou modelovou oblast. Účelem bylo získat referenční klasifikaci rozptýlené zeleně v oblasti.

Vizuální interpretace a tvorba vektorové vrstvy probíhala v softwaru ArcView na podkladu družicového snímku IKONOS. Interpretace dat probíhala pod maskou lesů, zastavěných ploch a vodních ploch, vzniklé na základě databáze ZABAGED.

Za prvky rozptýlené zeleně byla považována veškerá stromová a keřová zeleň mimo les a zastavěné plochy, tedy v klasifikačním prostoru vymezeném zmíněnou maskou (viz. Obr. 5).

Výsledkem této etapy je polygonová vrstva ve formátu SHP představující veškeré prvky rozptýlené zeleně v modelové oblasti. Tato vrstva byla v další práci použita jako referenční pro hodnocení přesnosti automatické klasifikace.

*Obr. 5 – Klasifikační prostor pro vizuální interpretaci dat a vektorizaci prvků rozptýlené zeleně (barevná syntéza spektrálních pásem družice IKONOS v pořadí 321 a 432).*



## 6.5 Automatická klasifikace

Stanovení zásad a parametrů automatické klasifikace bylo stěžejním bodem této práce. Klasifikace probíhala s využitím metod objektové analýzy dat.

Veškerá klasifikace probíhala pod maskou lesů, zastavěných ploch a vodních ploch.

Úkolem klasifikace bylo rozdělit zbylý klasifikační prostor do dvou tříd:

***prvek rozptýlené vegetace / jiný objekt***

Prvky rozptýlené zeleně představují stromy a keře, zatímco ostatní objekty v sobě slučují všechny další třídy krajinného pokryvu vyskytující se v klasifikačním prostoru (tj. louky, orná půda, cesty a jiné povrchy bez vegetačního pokryvu).

Proces automatické klasifikace probíhal ve dvou krocích. Prvním úkolem byla segmentace obrazových dat. Pro tento krok bylo klíčové stanovení optimálních segmentačních parametrů. Výsledkem segmentace jsou obrazové objekty (segmenty), které byly následně klasifikovány tj. rozděleny do dvou výše stanovených tříd.

### 6.5.1. Segmentace snímku

Segmentace probíhala na základě všech čtyř pansharpovaných spektrálních pásem družice IKONOS. Všem čtyřem spektrálním pásmům byla přidělena stejná váha 1.

#### *Stanovení optimálních segmentačních parametrů*

Úkolem této části práce bylo stanovení optimální kombinace segmentačních parametrů pro danou aplikaci. Na malém výřezu snímku byly sledovány vlastnosti obrazových objektů v závislosti na parametrech segmentace. Na základě vizuálního posouzení výsledků jednotlivých segmentací byl stanoven interval přípustných hodnot měřítkového parametru.

Vhodnost konkrétní kombinace segmentačních parametrů pro danou aplikaci byla ověřována empiricky na testovacím výřezu snímku (*výřez1*) a sice na základě srovnání klasifikačních přesností dosažených pro jednotlivé kombinace parametrů.

Srovnávací klasifikace probíhala pomocí klasifikační metody nejbližšího souseda.

Postupně byly testovány všechny kombinace následujících hodnot měřítkového parametru a tvarového faktoru:

**Měřítkový parametr:** 20, 25, 30 a 35

**Tvarový faktor:** 0.1, 0.3, 0.5 a 0.7

Pro kombinaci měřítkového parametru a tvarového faktoru s nejvyšší dosaženou klasifikační přesností byla vyzkoušeny tři různé hodnoty podílu kompaktnosti na tvarové složce míry heterogenity.

**Hodnoty kompaktnosti:** 0, 0.5 a 1

## 6.5.2 Srovnávací klasifikace metodou nejbližšího souseda

Klasifikační metoda nejbližšího souseda byla použita k testování vhodnosti kombinací segmentačních parametrů.

Výběr příznaků pro klasifikaci byl uskutečněn pomocí interního nástroje softwaru Definiens Professional *Optimalizace příznakového prostoru* (feature space optimization) fungujícího na základě hledání vzdálenosti vzorků tříd v mnohorozměrném příznakovém prostoru. Obrazové objekty byly rozděleny do dvou tříd – *prvky rozptýlené zeleně* a *jiné objekty*.

Jako trénovací množiny pro klasifikaci metodou nejbližšího souseda byly použity výsledky vizuální interpretace stejných dat. Pro každou kombinaci segmentačních parametrů byl proveden překryv výsledných obrazových objektů s výřezem tématické vrstvy vzniklé na základě vizuální interpretace dat. Objekty s minimálním překrytem 75% s objektem jedné ze tříd *rozptýlená zeleň / jiný objekt* – byly použity jako vzorky (ekvivalent pro trénovací množinu v terminologii manuálu Definiens) odpovídající třídy.

Pro tyto vzorky byl nalezen optimální *příznakový prostor*, a sice výběrem z následujících 14 příznaků:

- **Střední hodnota** pixelů v objektu v červeném, zeleném, modrém a blízkém infračerveném spektrálním pásmu.
- **Světlost** (průměr středních hodnot čtyř spektrálních pásem dělený počtem těchto pásem).
- **Směrodatná odchylka** hodnot pixelů v objektu v červeném, zeleném, modrém a blízkém infračerveném pásmu.
- **Podíl směrodatné odchylky a světlosti** pro všechna 4 spektrální pásma.
- **Podíl součtu směrodatných odchylek ve všech čtyřech spektrálních pásmech a světlosti.**

**Jednotlivé výše uvedené příznaky jsou definovány následovně:**

### ***Střední hodnota***

Střední hodnota objektu v daném spektrálním pásmu  $c_L$  je vypočítána z hodnot tohoto spektrálního pásma ve všech  $n$  pixelech tvořících tento objekt  $c_{Li}$ .

$$\bar{c}_L = \frac{1}{n} \cdot \sum_{i=1}^n c_{Li}$$

(Definiens Imaging 2004)

Rozmezí hodnot závisí na barevné hloubce dat. Pro 8 bitová data použitá v této práci se hodnoty pohybují v intervalu [0; 255]

### ***Světlost (brightness)***

Tento příznak vyjadřuje průměrnou spektrální hodnotu objektu. Světlost je definovaná součtem hodnot ve všech spektrálních pásmech děleným počtem spektrálních pásem (v tomto případě 4).

$$b = \frac{1}{n_L} \cdot \sum_{i=1}^{n_L} \bar{c}_i$$

(Definiens Imaging 2004)

### ***Směrodatná odchylka***

Vypočtená ze spektrálních hodnot všech pixelů tvořících daný objekt následovně:

$$\sigma_L = \sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (c_{Li} - \bar{c}_L)^2}$$

(Definiens Imaging 2004)

Směrodatná odchylka vyjadřuje vnitřní variabilitu souboru, v tomto případě variabilitu spektrálních hodnot pixelů v rámci obrazového objektu. Charakterizuje tedy texturu uvnitř objektu.



### *Uživatelské příznaky (customized features)*

Byly vypočteny *podíly směrodatných odchylek v každém ze čtyř spektrálních pásmech a světlosti* objektu. Dále pak *podíl sumy směrodatných odchylek ve všech čtyřech pásmech a světlosti*.

Tyto příznaky byly použity vzhledem k charakteru zájmových objektů, tedy prvků rozptýlené zeleně. Pro tyto prvky je charakteristická vysoká spektrální heterogenita (zde vyjádřena směrodatnou odchylkou v jednotlivých spektrálních pásmech) a relativně nízká světlost objektu.

Přesnost klasifikací s použitím jednotlivých kombinací segmentačních parametrů byla hodnocena pomocí nástrojů pro hodnocení přesnosti aplikovaných v softwaru Definiens Professional (popsaných v kapitole 6.5.4). Segmentace s nejvyšší klasifikační přesností byla vyhodnocena jako nejvhodnější pro daný účel a použita pro klasifikaci.

### 6.5.3 Klasifikace pomocí funkcí příslušnosti

Na objekty vzniklé segmentací s optimálními parametry stanovenými v předchozím kroku byla aplikována klasifikace pomocí funkcí příslušnosti. V tomto případě bylo použito jednoduché prahování.

Výběr příznaků pro klasifikaci a jejich prahových hodnot probíhal na základě sledování vlastností cílových objektů a pomocí analýzy hodnot příznaků vzorků jednotlivých tříd v Excelu. Pro sledování hodnot příznaků byly použity stejné vzorky, jako předtím pro výběr příznakového prostoru pro klasifikaci metodou nejbližšího souseda.

S použitím vybraných příznaků a jejich prahů byla vytvořena klasifikační hierarchie.

Všechny třídy použité v této hierarchii byly na konci klasifikace sloučeny do dvou významových tříd: *prvek rozptýlené zeleně / jiný objekt*

Přesnost výsledné klasifikace byla opět vyhodnocena pomocí nástrojů pro hodnocení přesnosti klasifikace v softwaru Definiens Professional.

Oba druhy klasifikací byly aplikovány na srovnávací výřez (výřez 2) o rozměrech 1800x1700 pixelů z jiné části modelové oblasti a následně na snímek celé modelové oblasti.

Výsledná přesnost byla porovnána a klasifikace vyhodnoceny.

#### 6.5.4 Hodnocení přesnosti klasifikace

Hodnocení přesnosti klasifikací probíhalo pomocí nástroje pro hodnocení přesnosti integrovaného v softwaru Definiens Professional.

Přesnost výsledné klasifikace je zde hodnocena na základě překrytu s referenční klasifikací. V této práci byl jako referenční klasifikace použit výsledek vizuální interpretace dat.

Byly sledovány následující **ukazatele přesnosti**:

**Celková přesnost** klasifikace (*overall accuracy*) vyjadřuje podíl správně zaklasifikovaných pixelů na celkovém počtu obrazových pixelů. Jedná se o poměrně hrubý ukazatel přesnosti, který nevypovídá o tom, s jakou přesností jsou klasifikovány jednotlivé třídy. (Definiens Imaging 2004) Tato míra přesnosti je vhodnější pro aplikace s vyšším počtem klasifikačních tříd, které mají navzájem srovnatelnou rozlohu. Může nastat situace, kdy bude většina tříd klasifikovaných špatně a jediná cílová velmi přesně – to už ovšem tato míra nepostihuje. Pro účel této práce, kdy byly klasifikovány pouze dvě třídy navíc s velmi rozdílnou celkovou rozlohou, se jedná spíše o ukazatel orientační.

Další dvě použité míry přesnosti mají jako referenční nikoli rozlohu celého výřezu, ale rozlohu jedné vybrané třídy, v tomto případě rozlohu třídy *prvky rozptýlené zeleně*.

Jedná se o tzv. *producentickou* a *uživatelskou přesnost*.

**Producentická přesnost** (*producer accuracy*) třídy prvků rozptýlené zeleně. Vyjadřuje podíl pixelů náležících reálným prvkům rozptýlené zeleně, které byly klasifikací zařazeny do této třídy na celkovém počtu pixelů třídy rozptýlené zeleně v referenční klasifikaci. Tj. vyjadřuje pravděpodobnost, že byl pixel třídy rozptýlené zeleně v referenční klasifikaci správně klasifikován.

**Uživatelská přesnost** (*users accuracy*) třídy prvků rozptýlené zeleně pak vyjadřuje podíl pixelů, které jsou klasifikované jako rozptýlená zeleň a skutečně představují reálné prvky rozptýlené zeleně.

Dále byly použity dva koeficienty vyjadřující kombinaci producentské a uživatelské přesnosti. Jednalo se o Helldenův a Shortův koeficient, definované následovně:

### *Helldenův koeficient přesnosti*

$$HA(class_i) = \frac{2}{\frac{1}{PA(class_i)} + \frac{1}{UA(class_i)}} \quad (\text{Definiens Imaging 2004})$$

### *Shortův koeficient*

$$SA(class_i) = \frac{1}{\frac{1}{PA(class_i)} + \frac{1}{UA(class_i)}} - 1 \quad (\text{Definiens Imaging 2004})$$

Kde  $PA(class_i)$  a  $UA(class_i)$  jsou zkratky pro producentskou a uživatelskou přesnost třídy  $i$ .

Kromě tohoto hodnocení přesnosti proběhla analýza překryvu dvou klasifikací – referenční a získané automaticky – v softwaru ArcGIS. Byl sledován podíl počtu prvků rozptýlené zeleně nalezených automatickou klasifikací na celkovém počtu prvků rozptýlené zeleně v oblasti.


Toto hodnocení neuvažuje v úrovni plochy, ale na úrovni objektů. Pokud nejsou hranice prvku určeny přesně, jedná se z hlediska monitoringu prvků rozptýlené zeleně o méně závažnou chybu než v případě, že prvek nebyl vůbec nalezen.

## 7 VLASTNÍ PRÁCE

### 7.1 Vizuální interpretace dat

Výsledkem vizuální interpretace je polygonová vektorová vrstva ve formátu SHP, obsahující 2262 polygonů představujících **prvky rozptýlené zeleně** v modelové oblasti. Ukázka této vrstvy na podkladu družicového snímku je vidět na *Obrázku 6*.

*Obr. 6 – Výsledek vizuální interpretace dat – zeleně jsou vyznačeny polygony ohraničující prvky rozptýlené zeleně.*



Vizuální interpretace je metoda časově náročná a poměrně subjektivní, ale nepřilíš náročná na znalosti interpretátora. Při delineaci hranic prvků rozptýlené zeleně se projevuje sklon generalizovat linie.

## 7.2 Automatická klasifikace

V této části práce byl sledován vliv hodnot segmentačních parametrů na vlastnosti obrazových objektů a na přesnost klasifikace metodou nejbližšího souseda. Byl stanoven interval použitelných hodnot měřítkového parametru a následně probíhal výběr optimální kombinace segmentačních parametrů na základě srovnání přesnosti klasifikace metodou nejbližšího souseda. Objekty vzniklé segmentací s použitím stanovené optimální kombinace parametrů byly dále oklasifikovány pomocí příslušnostních funkcí.

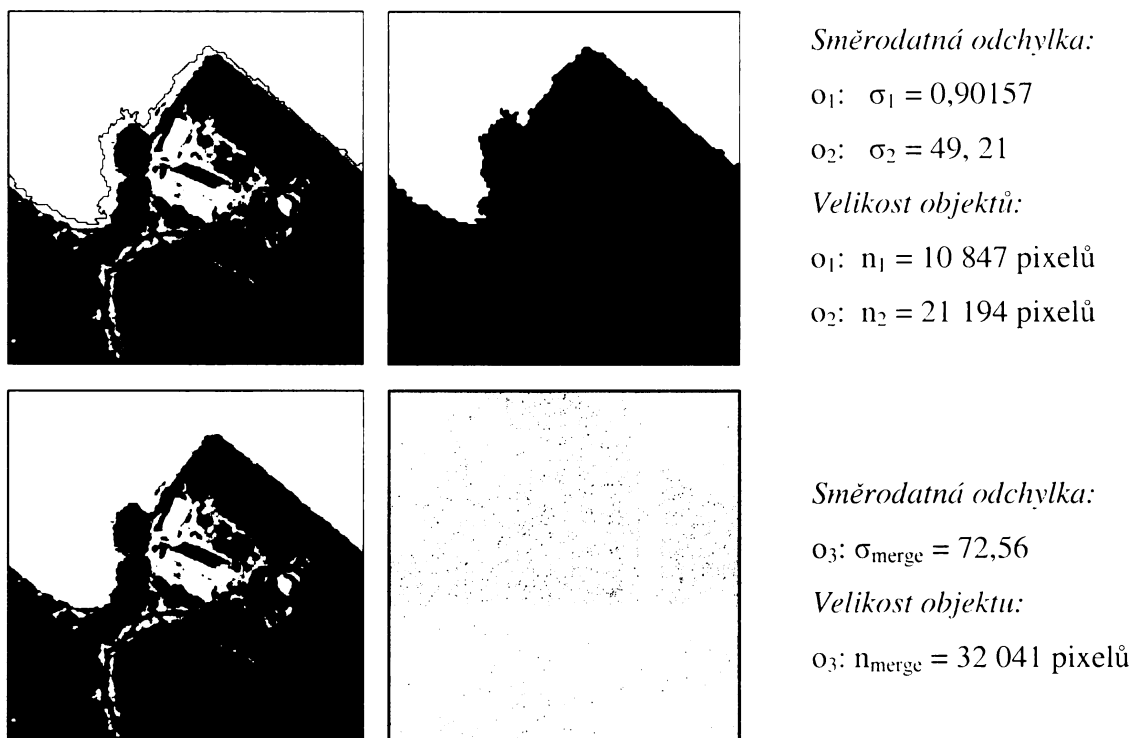
## 7.2.1 Chování algoritmu multiměřítkové segmentace

V této části práce bylo sledováno chování algoritmu multiměřítkové segmentace v softwaru Definiens Professional a vliv hodnoty segmentačních parametrů na vlastnosti výsledných obrazových objektů.

### *Vliv hodnoty měřítkového parametru na spojení objektů*

Obrázek 7 ukazuje vliv hodnoty měřítkového parametru na výslednou podobu obrazových objektů. Hodnota tohoto parametru rozhoduje o tom, zda dojde či nedojde ke spojení dvou původních objektů. V tomto případě byla použita pouze spektrální složka heterogenity. K segmentaci je použito jedno (zde zelené) spektrální pásmo. V prvním případě byl použit měřítkový parametr 1127 a došlo k vytvoření dvou objektů, ve druhém případě parametr 1128 a byl vytvořen pouze jeden objekt.

*Obr. 7 - Vliv hodnoty měřítkového parametru na spojení objektů.*



Při použití hodnoty měřítkového parametru 1127 se obraz rozdělí na 2 objekty ( $o_1$ ,  $o_2$ ), při zvýšení hodnoty parametru na 1128 se již vytvoří pouze jeden objekt. Důvodem

této změny v podobě výsledku segmentačního procesu je, že nárůst heterogenity provázející spojení těchto dvou objektů je vyšší než povoluje měřítkový parametr 1127 (tedy než  $1127^2$ ). Proto se v prvním případě objekty nespojí. Pokud se měřítkový parametr zvýší na 1128, ke spojení objektů již dojde. Hodnota maximální přípustné míry heterogenity se v tomto případě pohybuje právě mezi těmito dvěma hodnotami (1127 a 1128). Při rozhodování přitom proběhl výpočet změny heterogenity provázející spojení dvou sousedních objektů podle následujícího vztahu:


$$h_{color} = \sum_c w_c \left( n_{Merge} \cdot \sigma_c^{Merge} - \left( n_{Obj1} \cdot \sigma_c^{Obj1} + n_{Obj2} \cdot \sigma_c^{Obj2} \right) \right)$$

(Definiens Imaging 2004)

### *Segmentace s použitím různých spektrálních pásem*

Pokud segmentace probíhá na základě více spektrálních pásem, pak měřítkový parametr udává odmocninu z průměrné hodnoty maximální přípustné změny heterogenity v jednom spektrálním pásmu. Přitom je možné, aby nárůst heterogenity v některém z pásem (i více) překročil tuto průměrnou hodnotu, pokud bude v jiných pásmech nárůst nižší a průměr těchto hodnot nepřekročí druhou mocninu měřítkového parametru. Výsledek segmentace s měřítkovým parametrem 0 s použitím jednotlivých pásem ukazuje *Obrázek 8*. Opět byla použita pouze spektrální složka heterogenity.

*Obr. 8 – Segmentace podle jednotlivých spektrálních pásem (v pořadí R,G,B a NIR) s použitím měřítkového parametru 0.*

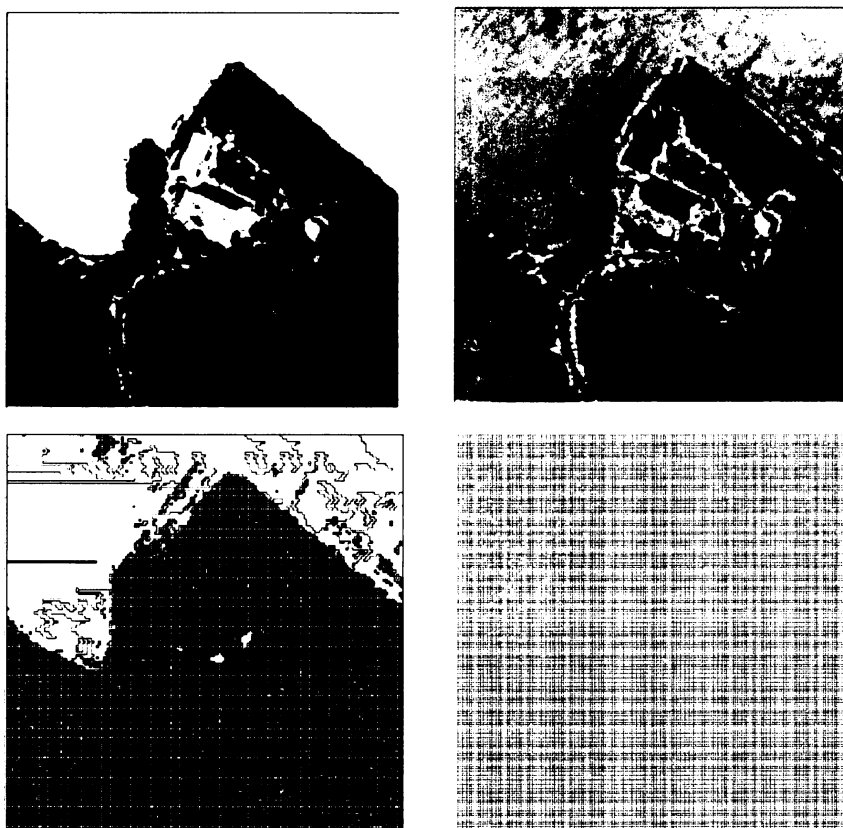




Při použití měřítkového parametru 0 nesmí při spojení dvou sousedních objektů dojít k nárůstu spektrální heterogenity. Spojeny jsou tedy pouze sousední pixely se stejnou hodnotou v daném spektrálním pásmu. Výsledky segmentace ve třech pásmech viditelného spektra jsou podobné, segmentace podle blízkého infračerveného pásma je naprosto odlišná. Také je zřejmé, že prvky zeleně mají nízkou odrazivost ve všech 4 pásmech spektra.

Obrázek 9 pak ukazuje výsledky segmentace s měřítkovým parametrem 0 při použití tří spektrálních pásem současně. Do objektu jsou opět spojeny pouze ty pixely, které mají stejnou spektrální hodnotu v jako jejich pixely sousední. Tato podmínka však musí být zachována v každém ze spektrálních pásem použitých pro segmentaci.

*Obr. 9 – Výsledek segmentace při použití tří spektrálních pásem současně (v prvním případě R,G,B a ve druhém NIR, R,G) s použitím měřítkového parametru 0.*




V prvním případě odpovídá výsledek segmentace tomu co vidíme na obrázku – tedy barevné syntéze tří viditelných spektrálních pásem – v horní části obrazu jsou velké objekty, které mají stejnou hodnotu všech pixelů ve všech pásmech viditelného spektra. Ve druhém případě dojde k rozsegmentování obrazu téměř na úroveň pixelu, protože

i když si dvě viditelná pásma odpovídají, hodnoty blízkého infračerveného pásma mají v rámci výřezu zcela jiné prostorové rozložení.

### *Vliv hodnoty měřítkového parametru na výslednou podobu segmentů*

Hodnota měřítkového parametru má vliv na míru heterogenity obrazových objektů a na jejich velikost. *Obrázek 10* ukazuje závislost velikosti segmentů na hodnotě měřítkového parametru. Byly použity měřítkové parametry 10, 20, 30 a 40 a segmentace probíhala na základě všech čtyř spektrálních pásem IKONOSu. Podíl pro tvarovou složku heterogenity byla 0.5, pro kompaktnost i hladkost také.

*Obr. 10 – Výsledek segmentace s použitím měřítkového parametru 10, 20, 30 a 40.*



V prvním případě je obraz rozsegmentován do malých spektrálně vysoce homogenních objektů. S narůstajícím měřítkovým parametrem se zvyšuje průměrná velikost objektů a snižuje jejich spektrální homogenita. Navíc lze sledovat tendence vytváření větších homogennějších objektů (třídy tráva) a menších heterogennějších objektů (představujících třídu rozptýlené zeleně). V případě měřítkového parametru 40 je již maximální přípustná heterogenita objektů příliš vysoká, což se projevuje spojováním různých (vizuálně rozlišitelných) tříd do jednoho obrazového objektu.

### *Vliv tvarové složky heterogenity na výslednou podobu segmentů*

V případě že chce uživatel ovlivnit tvar výsledných obrazových objektů, zadává hodnotu tvarového faktoru. Pokud je hodnota tohoto parametru ponechána nulová, je do změny heterogenity při spojení dvou objektů započítána pouze heterogenita ve spektrálních vrstvách.

Tvarový faktor vyjadřuje podíl tvarové složky heterogenity na celkové změně heterogenity. Čím vyšší hodnotu tohoto faktoru uživatel definuje, tím více by se měl tvar výsledných objektů blížit ideálnímu – tedy kompaktnímu či hladkému tvaru. Tento faktor ovšem funguje na úkor heterogenity spektrální.

Vliv míry podílu tvarové složky heterogenity na výslednou podobu segmentů s použitím stejného měřítkového parametru je vidět na *Obrázku 11*.

*Obr. 11 – Výsledek segmentace s použitím hodnot tvarového faktoru 0, 0.5 a 0.9 při stejné hodnotě měřítkového parametru a podílu kompaktnosti i hladkosti tvaru 0.5.*




V prvním případě je při výpočtu heterogenity brána v úvahu pouze spektrální informace. Objekty tedy vzniknou na základě minimalizace spektrální heterogenity bez ohledu na jejich výsledný tvar. To vede ke vzniku objektů složitého tvaru často fraktálního charakteru. To má za následek jednak pro lidské oko nepřehledný tvar objektu, a jednak prodloužení výpočetních operací softwaru. Na posledním obrázku je vidět výsledek segmentace s použitím maximálního důrazu na tvar objektů na úkor spektrální homogenity – je zřejmé, že v tomto případě již dochází ke slučování vizuálně odlišitelných tříd. Objekty tohoto charakteru jsou pro klasifikační účely nepoužitelné.

### ***Vliv podílu složky kompaktnosti a hladkosti na výslednou podobu segmentů***

Pokud je užit tvarový faktor větší než nula, pak může uživatel definovat, kterému tvaru se mají objekty blížit – zda kompaktnímu či hladkému.

Hladké objekty v tomto smyslu se vyznačují dlouhými hranami bez výběžků – tvar tedy může být čtvercový, ale stejně dobře i protáhlý, což naopak přiklonění ke kritériu kompaktnosti omezuje. Vysoký podíl vlivu kompaktnosti má za následek vytváření objektů blízkých kruhovým. Použití vysokého podílu parametru hladkosti je vhodné zejména u aplikací zaměřených na delineaci protáhlých objektů minimální spektrální heterogenity (např. stíny na okraji lesů atd.) *Obrázek 12* ukazuje výsledek segmentací s různým podílem tvarové složky heterogenity.

*Obr. 12 – Výsledek segmentace s použitím různého podílu vlivu kompaktnosti na tvarovou složku heterogenity (kompaktnost 1, 0.5, 0).*



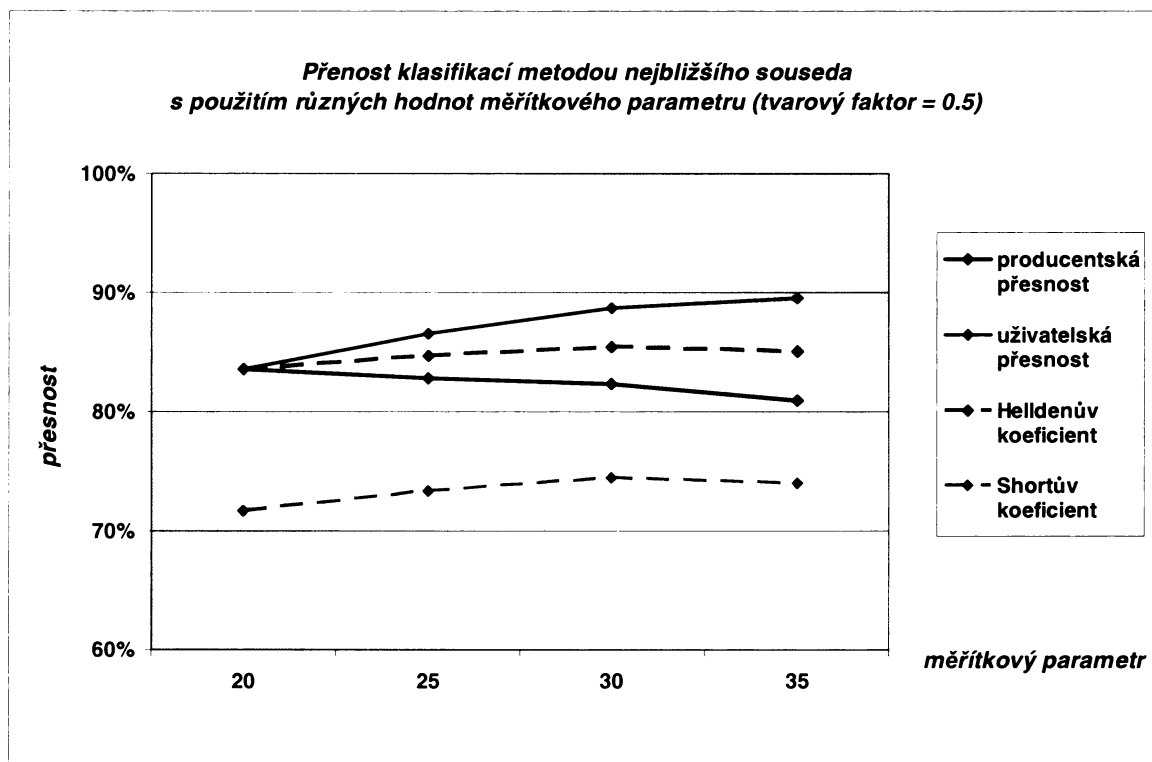
Na prvním obrázku je použita pro definici tvaru pouze kompaktnost. Výsledné objekty mají sklon blížit se maximálně kompaktnímu tvaru. Na třetím obrázku je naopak pro definici tvaru použita pouze hladkost. Je zde zřejmá tendence vytváření protáhlých tvarů. Pro ukázkou byla použita maximální váha pro tvarovou složku heterogenity (tvarový faktor 0.9), aby vynikla změna tvaru. Při použití nižší váhy pro tvar nebude docházet k tak markantnímu slučování dvou vizuálně odlišitelných tříd do jednoho objektu.

## 7.2.2 Vliv hodnot parametrů segmentace na přesnost srovnávací klasifikace pomocí metody nejbližšího souseda

### *Měřtkový parametr*

Graf na *Obrázku 13* ukazuje vliv hodnoty měřtkového parametru (a tedy velikosti výsledných obrazových objektů) na přesnost klasifikace. Hodnoty klasifikačních přesností jsou udávány pro třídu rozptýlená zeleň.

*Obr. 13 – Přesnost klasifikace při použití různých hodnot měřtkového parametru.*



Uživatelská přesnost klasifikace roste s narůstající hodnotou měřítkového parametru.

Tento vývoj je logický, protože se zvyšováním měřítkového parametru a tedy průměrné velikosti objektů se zvyšuje i separabilita mezi třídami. Snižuje se tedy možnost zařazení objektu do špatné třídy. Je vysoce pravděpodobné, že takto vzniklé velké objekty klasifikované jako rozptýlená zeleň budou skutečně reálné objekty rozptýlené zeleně.

Naopak při použití nižších hodnot měřítkového parametru dochází ke vzniku menších objektů a „překlasifikovanosti“ třídy rozptýlené zeleně. Do této třídy jsou zařazeny i objekty, které tam nepatří, např. tmavé části orné půdy. Tato „překlasifikovanost“ je vyjádřena snížením uživatelské přesnosti.

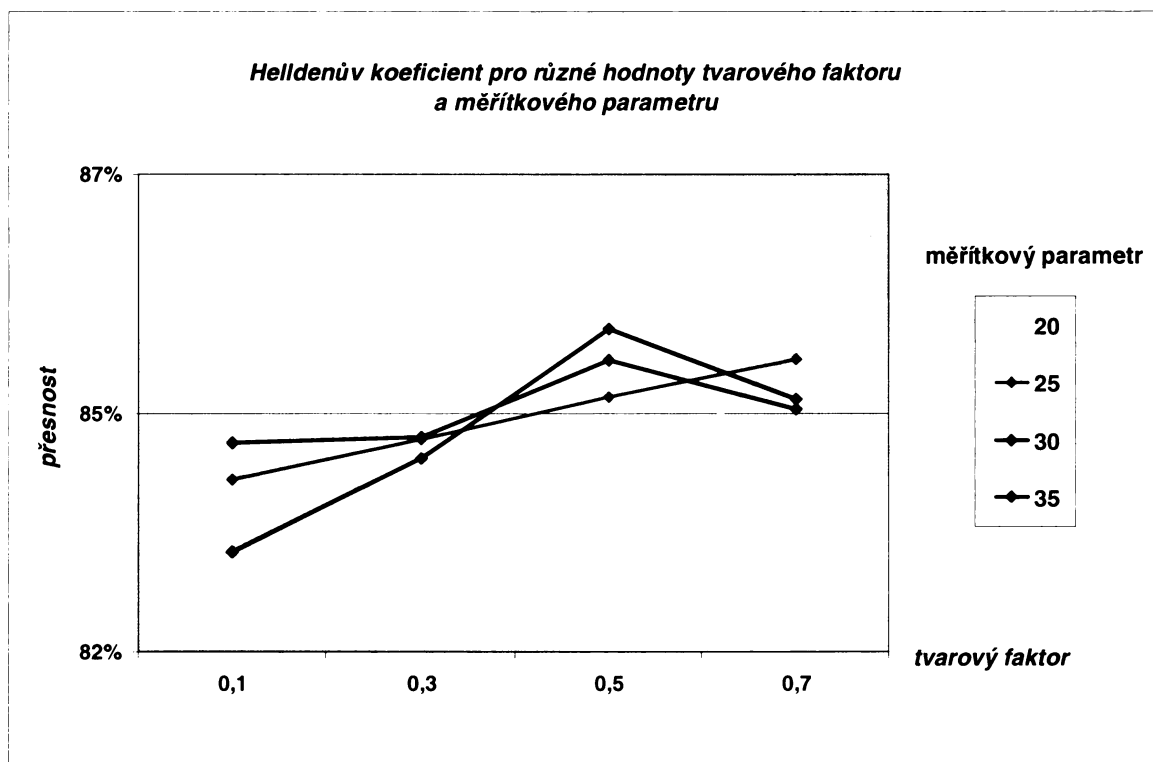
Naproti tomu producentská přesnost s nárůstem hodnoty měřítkového parametru klesá. Tj. klesá pravděpodobnost, že bude skutečná rozptýlená zeleň klasifikací nalezena. Důvodem tohoto poklesu je zřejmě skutečnost, že dochází ke slučování více reálných tříd do jednoho objektu – který je potom zaklasifikován jako jiný prvek. To je případem zejména malých (bodových) prvků zeleně, jako jsou jednotlivé stromy či keře.

Helldenův a Shortův koeficient vyjadřují kombinaci producentské a uživatelské přesnosti. Hodnoty těchto koeficientů se se změnou měřítkového parametru příliš nemění. Nicméně nejvyšší hodnoty dosahují při použití měřítkového parametru 30. Tato hodnota měřítkového parametru byla tedy vyhodnocena jako optimální pro danou aplikaci a použita pro klasifikace.

## *Tvarový faktor*

Vliv podílu tvarové složky heterogenity na přesnost výsledné klasifikace ukazuje graf na *Obrázku 14*. Jako ukazatel přesnosti je zde zvolen Helldenův koeficient, představující kombinaci producentské a uživatelské přesnosti. Hodnoty koeficientu jsou opět udávány pro třídu rozptýlené zeleně.

*Obr. 14 – Přesnost klasifikace při použití různých kombinací segmentačních parametrů.*



Pro měřítkový parametr 20 a 25 byly nejvyšší přesnosti dosaženy za použití vysokého podílu tvaru na celkové heterogenitě. Naopak při použití nízkého vlivu tvaru na celkovou heterogenitu je výsledná přesnost klasifikace relativně nejnižší. Důvodem je skutečnost, že spektrálně vysoce heterogenní třída prvků rozptýlené zeleně obsahuje místa spektrálními i texturálními vlastnostmi blízká trávě. Při použití nízkého vlivu tvarové složky pro segmentaci dojde k separaci právě těchto relativně světlých a spektrálně homogenních oblastí od sousedních částí rozptýlené zeleně. Takto vzniklé objekty jsou potom nesprávně zaklasifikovány do třídy jiný objekt.

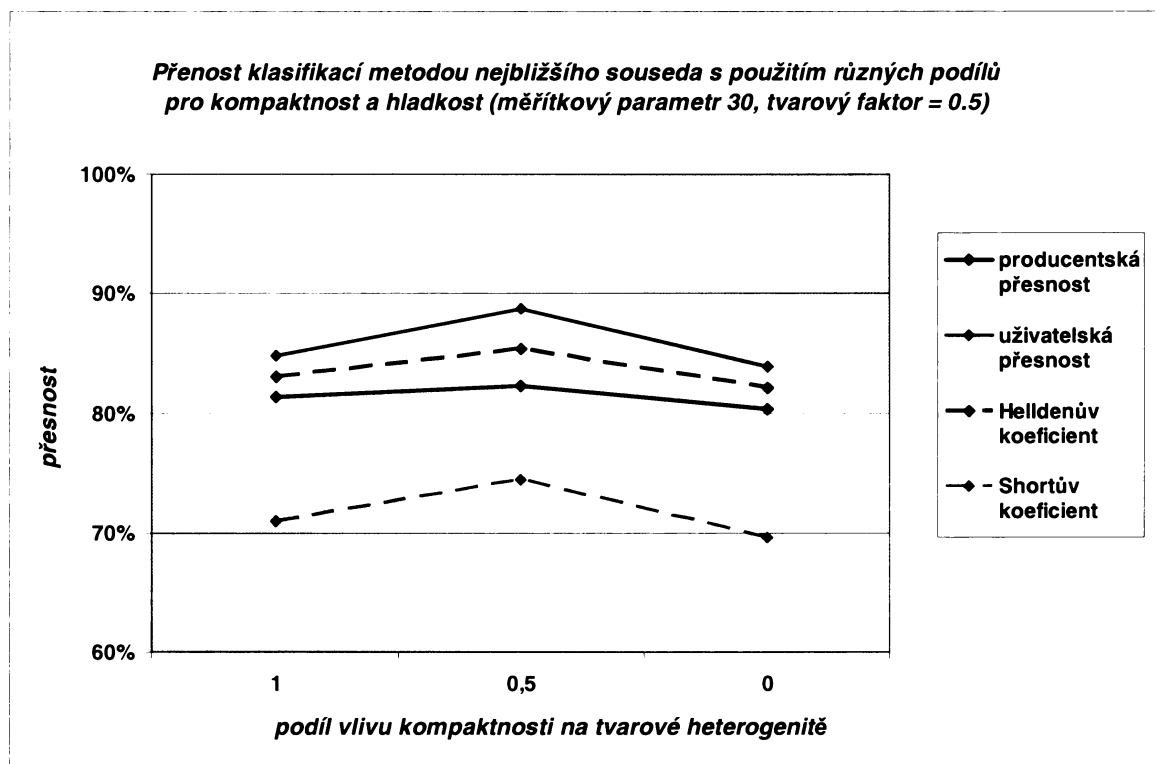
Pro vyšší hodnoty měřítkového parametru byla maximální přesnost dosažena s použitím 50%ho podílu tvarové složky heterogenity. Při použití vyšších hodnot měřítkového parametru již dochází k nerespektování rozdílnosti spektrálních vlastností pixelů a slučování dvou reálných tříd do jednoho obrazového objektu. Takový objekt potom způsobuje chybu, nezávisle na tom, do které třídy je zaklasifikován.

Absolutně nejvyšší přesnost klasifikace byla dosažena při použití kombinace měřítkového parametru 30 a tvarového faktoru 0.5. Tato kombinace je tedy použita pro klasifikace.

### ***Podíl vlivu kompaktnosti a hladkosti***

Graf na *Obrázku 15* ukazuje hodnoty klasifikačních přesností třídy prvků rozptýlené zeleně při použití různého podílu vlivu kompaktnosti a hladkosti na určení tvarové heterogenity. Všechny hodnoty jsou pro stejnou kombinaci měřítkového parametru 30 a tvarového faktoru 0.5.

*Obr. 15 – Přesnost klasifikace při použití různého podílu vlivu kompaktnosti a hladkosti na tvarové složce heterogenity.*





Výrazná preference jedné formy tvarové homogenity vede ke snížení klasifikační přesnosti. Při použití vyšší váhy pro kompaktnost se objevuje tendence vytváření kompaktních objektů kruhového tvaru na úkor jejich spektrální homogenity. Naopak při vyšší váze pro hladkost vznikají objekty protáhlého tvaru. Jako optimální se ukázalo použití stejné váhy pro kompaktnost i hladkost.

**Maximální přesnost klasifikace pomocí metody nejbližšího souseda byla dosažena s použitím měřítkového parametru 30, tvarového faktoru 0.5 a podílu kompaktnosti a hladkosti 1:1. Tato kombinace segmentačních parametrů byla stanovena jako optimální pro účel monitorování prvků rozptýlené zeleně v krajině.**

### *Optimální příznakový prostor*

Optimalizace příznakového prostoru stanovila jako příznaky s nejlepší separační vzdáleností následující příznaky:

- *Podíl součtu směrodatných odchylek ve všech 4 spektrálních pásmech a světlosti*
- *Podíl směrodatné odchylky v modrém pásmu a světlosti.*
- *Podíl směrodatné odchylky v červeném pásmu a světlosti.*
- *Střední hodnota objektu v červeném pásmu.*
- *Světlost (součet středních hodnot 4 spektrálních pásem dělený počtem těchto pásem)*

Pořadí příznaků s nejlepší separační vzdáleností je však velmi závislé na konkrétním výběru vzorků tříd. Obecně lze říci, že nejlepší separace dvou klasifikačních tříd byla vyhodnocena pro příznakový prostor obsahující všech 14 příznaků zadaných k výběru.


Klasifikace metodou nejbližšího souseda s použitím stanovených optimálních parametrů pro segmentaci byla dále aplikována na srovnávací výřez 2 a na snímek celého modelového území. Přesnost této klasifikace je vyhodnocena v kapitole 8.2.

### 7.2.3 Klasifikace pomocí funkcí příslušnosti

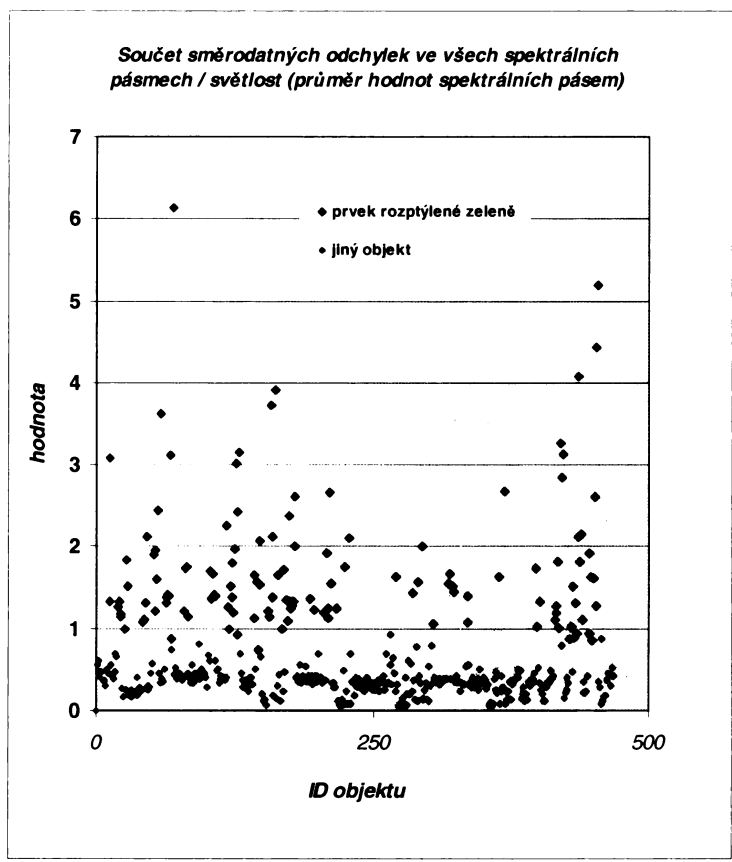
Klasifikace pomocí prahování probíhala na základě sledování příznaků objektů vybraných dvou tříd a hledání prahů.

Jako příznak s nejlepší separační vzdáleností při klasifikaci metodou nejbližšího souseda byl vyhodnocen *podíl směrodatných odchylek všech spektrálních hodnot a světlosti objektů*. Tento příznak byl také použit pro první hrubé oddělení možných prvků rozptýlené zeleně a jiných objektů. Hodnoty tohoto příznaku pro objekty jsou znázorněny na *Obr. 16*. Prahová hodnota pro oddělení tříd byla stanovena na základě rozložení hodnot příznaku pro vzorky tříd rozptýlené zeleně a jiných objektů. Toto rozložení znázorňuje graf na *Obr. 17*.

*Obr. 16 - Podíl směrodatných odchylek všech spektrálních hodnot a světlosti objektů v testovacím výřezu 1. Hodnoty jsou znázorněny pomocí stupňů šedi. Světlejší objekty mají vyšší hodnotu tohoto příznaku.*




Obr. 17 – Hodnoty příznaku podíl směrodatných odchylek všech spektrálních hodnot a světlosti pro vzorky tříd prvek rozptýlené zeleně a jiný objekt.



Jak je patrné z grafu na Obr. 17, příznak podíl směrodatných odchylek všech spektrálních hodnot a světlosti umožňuje rozlišit vzorky (471 objektů) obou tříd velmi dobře. Při vizuální kontrole klasifikace provedené pouze na základě tohoto příznaku bylo však zjištěno, že ne všechny objekty v rámci testovacího výřezu 1 (5932 objektů) jsou zaklasifikovány správně. Proto byly hledány další příznaky pro oddělení těchto dvou tříd a zpřesnění klasifikace.

Rozdělení objektů v testovacím výřezu 1 po tomto prvním klasifikačním kroku do klasifikačních tříd *možné prvky rozptýlené zeleně* a *ostatní objekty* je vidět na *Obrázku 18*.

*Obr. 18 – Klasifikace objektů pomocí příznaku podíl směrodatných odchylek všech spektrálních hodnot a světlosti.*




- ☐ ● klasifikační prostor
- ⊕ ● možné prvky rozptýlené zeleně
- ⊕ ● ostatní objekty

Bylo zjištěno, že nedošlo k dostatečnému oddělení některých objektů povrchu bez vegetace, jako např. cest. Třída *možné prvky rozptýlené zeleně* byla tedy dále rozdělena na základě střední hodnoty v červeném spektrálním pásmu do tříd *možné prvky rozptýlené zeleně1* a *objekty bez vegetace*.


Hodnoty příznaku střední hodnota v červeném spektrálním pásmu ve stupních šedi pro jednotlivé obrazové objekty a následná klasifikace objektů na základě tohoto příznaku jsou vidět na *Obrázku 19*.

Obr. 19 – Hodnoty příznaku střední hodnota v červeném spektrálním pásmu ve stupních šedi a následná klasifikace objektů na základě tohoto příznaku.



Výsledek následné klasifikace pro celý testovací výřez 1 je vidět na Obrázku 20.

Obr. 20 - Výsledek klasifikace ve druhé fázi hierarchické klasifikace.




- ▣ ● klasifikační prostor
- ▣ ● možné prvky rozptýlené zeleně
- objekty bez vegetace
- ⊕ ● možné prvky rozptýlené zeleně1
- ⊕ ● ostatní objekty

V této fázi klasifikace docházelo k častému zařazení objektů představujících trávu do třídy *možné prvky rozptýlené zeleně 1*. Proto bylo dále provedeno rozdělení této třídy na základě příznaku *podíl směrodatné odchylky v modrém spektrálním pásmu a světlosti* objektů. Hodnoty tohoto příznaku a následná klasifikace je vidět na *Obrázku 21*.


Vznikly dvě další klasifikační třídy: *ostatní objekty 2* a *prvky rozptýlené zeleně 1*. Objekty náležící do druhé ze zmíněných tříd byly již považovány za správně zaklasifikované prvky rozptýlené zeleně.

*Obr. 21 – Hodnoty příznaku podíl směrodatné odchylky v modrém spektrálním pásmu a světlosti objektů ve stupních šedi a následná klasifikace objektů na základě tohoto příznaku.*




Tímto krokem došlo k úspěšnému oddělení těchto dvou tříd a značnému zvýšení klasifikační přesnosti. To dokumentuje i *Obrázek 22* ukazující následnou klasifikaci celého testovacího výřezu.

Obr. 22 - Výsledek klasifikace ve třetí fázi hierarchické klasifikace.



V této fázi klasifikace docházelo v podstatě již jen k jedinému zásadnímu druhu chyby. A sice k chybnému zařazení relativně světlejších segmentů s nepříliš vysokou texturou představující části korun stromů do klasifikačních tříd. Tento problém byl eliminován pomocí kontextuálního příznaku sousedství k již správně zaklasifikovaným objektům třídy *prvky rozptýlené zeleně1*. Pro objekty třídy *ostatní objekty2* byl použit příznak relativní hranice se sousedním objektem třídy *prvky rozptýlené zeleně1*. Příklad objektů zařazených do správné třídy v tomto posledním klasifikačním kroku je vidět na *Obrázku 23*. Třída *ostatní objekty 2* byla tímto krokem rozdělena do tříd *ostatní objekty3* a *světlé části uvnitř zeleně*.

Obr. 23 – Části korun stromů přiřazené ke třídě rozptýlené zeleně pomocí kontextuálního příznaku relativní hranice k sousednímu objektu dané třídy.



Výsledek hierarchické klasifikace pomocí prahování je vidět na Obrázku 24.

Obr. 24 – Výsledek hierarchické klasifikace na testovacím výřezu 1.

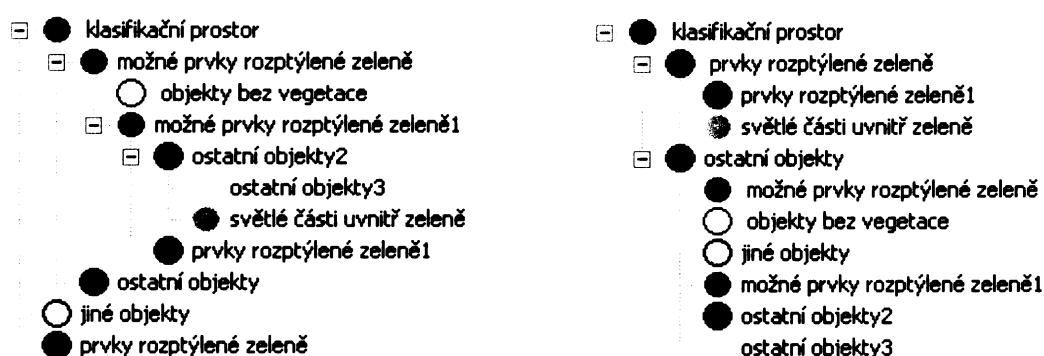


- ☐ ● klasifikační prostor
- ☐ ● možné prvky rozptýlené zeleně
- objekty bez vegetace
- ☐ ● možné prvky rozptýlené zeleně1
- ☐ ● ostatní objekty2
- ● ostatní objekty3
- světlé části uvnitř zeleně
- prvky rozptýlené zeleně1
- ostatní objekty



Posledním krokem klasifikace bylo rozdělení všech vzniklých tříd klasifikační hierarchie do dvou významových skupin – *prvek rozptýlené zeleně* a *jiný prvek*. Tento krok neznamena změnu v popisu jednotlivých tříd, ale pouze změnu v uspořádání klasifikační hierarchie na základě sémantické informace. Tuto změnu zachycuje *Obrázek 25*.

*Obr. 25 – Dvě podoby klasifikační hierarchie – vlevo hierarchie založená na dědičnosti příznaků mateřských tříd, vpravo pak hierarchie stejné klasifikace uspořádaná na základě významu jednotlivých tříd.*



Výslednou podobu klasifikace na testovacím výřezu se třídami uspořádanými podle významu do dvou nadřazených tříd – *prvek rozptýlené zeleně* a *jiné objekty* ukazuje *Obrázek 26*.

Stejná klasifikace byla následně aplikována i na druhý výřez a poté na celou modelovou oblast.

Výsledné klasifikace byly vyexportovány do formátu SHP. Kromě těchto vrstev představujících klasifikace byly uloženy i posloupnosti klasifikačních procesů ve formátu **.dcp** zachycující jednotlivé postupné kroky objektové klasifikace a klasifikační hierarchie obsahující popis tříd. V případě klasifikace nejbližšího souseda obsahuje tato posloupnost procesů i charakteristiky vzorků a použitý příznakový prostor. Takovou posloupnost procesů lze aplikovat na jinou oblast snímku bez opětovného výběru vzorků.

Obr. 26 – Výsledná podoba klasifikace metodou prahování na testovacím výřezu 1 – třídy jsou podle významu uspořádány do dvou nadřazených tříd – prvky rozptýlené zeleně a jiné objekty.



● prvky rozptýlené zeleně  
○ jiné objekty




0 300 600 m

## 8 VÝSLEDKY

Výsledkem práce je vytvoření dvou různých klasifikačních postupů využívajících metody objektové analýzy dat. Znalostní báze těchto klasifikací jsou využitelné pro monitorování prvků rozptýlené zeleně na základě dat družice IKONOS. Ukázka výsledné klasifikace je vidět na *Obrázku 27*.

*Obr. 27 – Ukázka výsledku klasifikace prvků rozptýlené zeleně na podkladu dat družice IKONOS (barevná syntéza spektrálních pásem v pořadí 321 a 432).*



## 8.1 Optimální segmentační parametry

Pomocí porovnání přesnosti klasifikací metodou nejbližšího souseda za použití různých kombinací segmentačních parametrů byla stanovena optimální kombinace těchto parametrů pro účely monitorování prvků rozptýlené zeleně. Jedná se o následující kombinaci:

Měřítkový parametr      30

Tvarový faktor            0.5

Podíl vlivu kompaktnosti na tvarový faktor      0.5

## 8.2 Dosažená klasifikační přesnost

Přesnosti klasifikací dosažené při použití obou klasifikačních metod ukazuje *Tabulka 1*. Uvedeny jsou přesnosti dosažené při aplikaci stejných klasifikací na tři různé části snímku – testovací výřez 1, ze kterého pochází vzorky, dále kontrolní výřez 2 z jiné části scény a nakonec celou modelovou oblast.

*Tab. 1 – Přesnosti klasifikací metodou nejbližšího souseda a metodou prahování pro testovací výřez 1, kontrolní výřez 2 a celou modelovou oblast s použitím optimálních segmentačních parametrů (30;0.5;0.5).*

<b>Přesnost klasifikace metodou nejbližšího souseda</b>			
	<i>výřez 1</i>	<i>výřez 2</i>	<i>modelová oblast 10x10km</i>
<b>Producentická přesnost</b>	0,823	0,895	0,766
<b>Uživatelská přesnost</b>	0,887	0,777	0,782
<b>Helldenův koeficient</b>	0,854	0,832	0,774
<b>Shortův koeficient</b>	0,745	0,712	0,632
<b>Celková přesnost</b>	0,980	0,986	0,979

<b>Přesnost klasifikace pomocí prahování</b>			
	<i>výřez 1</i>	<i>výřez 2</i>	<i>modelová oblast 10x10km</i>
<b>Producentická přesnost</b>	0,839	0,876	0,718
<b>Uživatelská přesnost</b>	0,948	0,840	0,838
<b>Helldenův koeficient</b>	0,890	0,857	0,773
<b>Shortův koeficient</b>	0,802	0,750	0,630
<b>Celková přesnost</b>	0,978	0,989	0,980

Celková přesnost klasifikace se pohybuje okolo hranice 98 % pro obě klasifikační metody a to i při aplikaci na celou modelovou oblast.

Směrodatné pro hodnocení kvality klasifikace jsou hodnoty obou koeficientů – Helldenova či Shortova – zde je patrný pokles přesnosti při přenesení klasifikačních metod na kontrolní *výřez 2* a ještě větší pokles při aplikaci klasifikace na celou modelovou oblast.


Vyšší hodnoty přesnosti na testovacím *výřezu 1* ve srovnání s *výřezem 2* a celou modelovou oblastí jsou dány skutečností, že součástí tohoto *výřezu 1* byly všechny vzorky pro klasifikační třídy. V případě klasifikace pomocí prahování byla na testovacím *výřezu 1* vytvářena znalostní báze pro hierarchickou klasifikaci. Tento proces probíhal pomocí identifikace chybně zaklasifikovaných objektů a na základě jejich vlastností byla zpřesňována klasifikační pravidla pro jednotlivé třídy. *Výřez 2* byl použit již pouze pro ověření použitelnosti znalostní báze vytvořené na *výřezu 1* pro jinou oblast. Na jiných částech snímku může dojít k častějšímu výskytu objektů dané třídy, jejichž vlastností nejsou postihnuty pomocí klasifikačních pravidel vytvořených na základě statistického vzorku objektů z testovacího výřezu. To je příčina snižování přesnosti klasifikací s posunem či rozšířením klasifikované oblasti.

Kromě hodnocení klasifikační přesnosti na základě plošného překryvu pixelů referenční klasifikace a klasifikace automatické byla úspěšnost klasifikace vyhodnocena také analýzou v softwaru ArcGIS. Bylo zjištěno, že automatická klasifikace našla téměř 100% prvků rozptýlené zeleně, a to jak v případě jednotlivých výřezů, tak i pro celou modelovou oblast 10x10 km. V případě, že prvek nebyl nalezen, se většinou jednalo o velmi malý keř. I tyto případy jsou však početně zanedbatelné.

### 8.2.1 Zdroje klasifikačních nepřesností

Důvodem snížení klasifikační přesnosti je zejména polohová nepřesnost hranic (viz Obr. 28) objektů představujících prvky rozptýlené zeleně, pramenící z různého způsobu delineace hranic. V případě vizuální interpretace nerespektuje hranice prvků rozptýlené zeleně hrany obrazových pixelů. Kromě toho se projevuje sklon hranici co nejvíce generalizovat – výsledek je potom přijatelnější pro lidské oko a zároveň se zkracuje čas potřebný pro klasifikaci. Naproti tomu hranice vzniklé při automatické klasifikaci jsou dány přesnou polohou hran obrazových pixelů.

*Obr. 28 – Rozdílná delineace hranic prvků rozptýlené zeleně při použití vizuální interpretace a automatické klasifikace.*



### **8.3 Srovnání použitých klasifikačních metod**

Hodnoty uvedené v *Tabulce 1* ukazují, že obě použité klasifikační metody – tedy metoda nejbližšího souseda a metoda prahování jsou z hlediska přesnosti klasifikace srovnatelné.

Klasifikace metodou nejbližšího souseda je citlivá na výběr vzorků – výběr nevhodného objektu může podstatně ovlivnit výsledek klasifikace. Je nutné vybrat dostatečný počet vzorků, které reprezentují všechny druhy objektů vyskytujících se v dané třídě. Což je vzhledem k rozmanitosti objektů náležejících do třídy prvků rozptýlené zeleně poměrně problematické. Nevýhodou této klasifikační metody je nedostatečná možnost kontroly průběhu klasifikačního procesu ze strany uživatele. Následkem toho může být problematické i nalézání příčin případných chyb v přiřazení objektů do tříd a jejich odstraňování. Při vysokém počtu vzorků pro jednotlivé třídy navíc dochází ke zvyšování doby potřebné pro samotnou klasifikaci.

Klasifikace pomocí prahování je z hlediska uživatele velmi dobře kontrolovatelná. Rozhraní softwaru *Definiens Professional* nabízí přehledné zpracování nastavení klasifikačních pravidel. Pokud dojde k zařazení objektu do nesprávné klasifikační třídy, lze jednoduše nalézt příčinu této chybné klasifikace pomocí kontroly hodnot příznaků použitých ke klasifikaci. Samotný proces klasifikace je velmi rychlý a to i pro velké množství obrazových objektů. Nicméně hledání příznaků vhodných pro odlišení jednotlivých tříd a jejich prahových hodnot může být časově poměrně náročné.

### **8.4 Srovnání vizuální interpretace a automatické objektové klasifikace pro účely monitorování prvků rozptýlené zeleně v krajině**

Vizuální interpretace družicových dat pro účely mapování rozptýlené zeleně v krajině je metoda nepříliš náročná na znalosti interpretátora a velmi náročná na čas.

Naproti tomu automatická objektová klasifikace klade vysoké nároky na stanovení znalostní báze klasifikace. Nicméně pokud je znalostní báze již jednou stanovena, dochází ke značnému urychlení procesu detekce prvků rozptýlené zeleně. Tento přínos je zvláště patrný při zpracování velkého množství obrazových dat.

## 9 DISKUSE

Těžištěm této práce bylo vytvoření klasifikačního postupu využívajícího metody objektové analýzy dat pro účel monitorování prvků rozptýlené zeleně v krajině.

Metoda objektové analýzy byla vybrána s ohledem na vlastnosti zájmových objektů – tedy prvků rozptýlené zeleně.

Tyto prvky jsou vzhledem ke své malé rozloze detekovatelné pouze na základě družicových dat vysokého prostorového rozlišení – jakými jsou i v této práci použítá data družice IKONOS.

Mnoho autorů poukazuje na nedostatečnost pixelové klasifikace a naopak vhodnost objektově orientované analýzy pro účely klasifikace právě takto vysoce texturovaných dat. Například Baatz a Schäpe, (2000) či de Kok et al. (1999) spatřují řešení tohoto problému v analýze celých obrazových objektů, ne pouze jednotlivých pixelů.

Třída prvků rozptýlené zeleně se navíc vyznačuje vysokou variabilitou spektrálních hodnot pixelů. Jak uvádí Carleer (2005), má tato variabilita v rámci jedné klasifikační třídy za následek snížení klasifikační přesnosti v případě použití tradičních pixelových klasifikačních metod, založených pouze na spektrálních vlastnostech.

Objektová klasifikace je také typická rozšířením příznakového prostoru, tedy zvýšením počtu a typů příznaků, které nese základní klasifikační jednotka, v tomto případě obrazový objekt. Tuto skutečnost vyzdvihují například de Kok et al. (1999) či Carleer (2005). Přínos zmíněného rozšíření příznakového prostoru se potvrdil i v této práci. Ke klasifikaci rozptýlené zeleně byly použity nejen různé spektrální příznaky objektů, ale i příznaky texturální a prostorový kontext.

Nejdůležitějšími kroky při stanovování klasifikačního postupu bylo určení hodnot segmentačních parametrů, zejména měřítkového parametru, a nalezení příznaků vhodných k odlišení třídy rozptýlené zeleně od jiných objektů.

Jako klíčové příznaky pro popis třídy rozptýlené zeleně se ukázaly podíly směrodatných odchylek ve spektrálních pásmech a světlosti objektů. Směrodatné odchylky ve spektrálních pásmech jakožto ukazatel vnitřní textury objektů použili pro klasifikace městské zeleně Mathieu (2005) i Zhang a Feng (2005).

Podíl směrodatné odchylky a světlosti se ukázal jako výhodnější k separaci třídy prvků rozptýlené zeleně od třídy jiných objektů, než samotné směrodatné odchylky.



Důvodem je skutečnost, že objekty představující rozptýlenou zeleň obsahují vysoký podíl pixelů představujících stíny – vyznačujících se nízkou odrazivostí ve všech čtyřech spektrálních pásmech - a tedy nízkou hodnotou příznaku světlosti.

Lze tedy říci, že objekty představující prvky rozptýlené zeleně jsou charakterizovány vysokou vnitřní texturou – čili vysokou směrodatnou odchylkou spektrálních hodnot pixelů a nízkou průměrnou odrazivostí ve spektrálních pásmech.

Jako optimální měřítkový parametr pro segmentaci – podstatný pro velikost obrazových objektů a míru jejich vnitřní heterogenity, byl stanoven parametr s hodnotou 30. Tato hodnota se blíží hodnotám které použil Mathieu (2005) pro účel klasifikace městské zeleně na podkladu dat družice IKONOS. V jeho práci jsou využity dvě měřítkové úrovně obrazových objektů s hodnotami měřítkového parametru 22 a 40, podle autora je každá z nich vhodná pro jinou velikost objektů. Mathieu ale řešil i rozlišení jednotlivých druhů stromové vegetace. Navíc v prostoru městské zástavby se vyskytuje více různých druhů objektů než v krajině po odmaskování zastavěných ploch.

Pro účel pouhého odlišení stromové vegetace od ostatní vegetace se zdá být jedna měřítková úroveň objektů segmentovaná pomocí parametru 30 dostačující.

Stanovení ideální hodnoty měřítkového parametru je však značně problematické. Důvodem je zejména to, že velikost prvků rozptýlené zeleně představuje spojitou škálu hodnot. Není tedy možné pro každou velikost vymezit samostatnou měřítkovou úroveň. Stanovení jakékoli hodnoty měřítkového parametru je tedy vždy do jisté míry kompromisem.

Právě tato neurčitost ve smyslu existence optimální kombinace segmentačních parametrů představuje nevýhodu objektové klasifikace. Hledání vhodných segmentačních parametrů je navíc poměrně časově náročné a většinou probíhá metodou pokus omyl – jak podotýká např. Schiewe at al. (2001).

Dosažená klasifikační přesnost a vizuální přesvědčivost výsledku klasifikace vede k závěru, že metoda objektové klasifikace družicových snímků VHR je vhodným postupem pro monitorování prvků rozptýlené zeleně.

Dalším krokem v této oblasti by měla být jednak snaha vytvořit klasifikační pravidla pro celý snímek bez masky a jednak přenesení nebo spíše modifikace vytvořeného klasifikačního postupu na letecké fotografie. To by umožnilo sledovat vývoj charakteru prvků rozptýlené zeleně krajině v časových řadách.

## 10 ZÁVĚR

Úkolem této diplomové práce bylo ověřit možnosti využití metody objektové klasifikace družicových dat vysokého rozlišení pro účel monitorování rozptýlené zeleně v krajině.

V úvodu práce je popsána problematika prvků rozptýlené zeleně v krajině, jejich ochrany a monitorování. Dále práce poskytuje přehled o problematice objektové klasifikace a shrnutí literatury věnující se této metodě analýzy dat. Velká pozornost je věnována zejména algoritmu multiměřítkové segmentace a vlivu segmentačních parametrů na podobu výsledných obrazových objektů. Právě hodnoty těchto uživatelem definovatelných parametrů mají zásadní vliv na kvalitu výsledku objektové klasifikace.

Hlavní část práce, tedy sestavování klasifikačního postupu vhodného pro monitorování prvků rozptýlené zeleně, byla realizována pomocí softwaru Definiens Professional. Tento software je úzce spojen s většinou aplikací využívajících metod objektové analýzy dat dálkového průzkumu Země.

Na základě vlastností zájmových objektů, tedy prvků rozptýlené zeleně v krajině, byly nejprve stanoveny optimální segmentační parametry a vybrán vhodný příznakový prostor pro klasifikaci. Byly vytvořeny dva různé klasifikační postupy pro klasifikaci objektů vzniklých pomocí algoritmu multiměřítkové segmentace – klasifikace pomocí metody nejbližšího souseda a klasifikace pomocí funkcí příslušnosti.

Vytvořené znalostní báze obou klasifikací obsahující hodnoty optimálních segmentačních parametrů a vybraných příznaků byly aplikovány i na jinou oblast snímku a na snímek celého modelového území.

Na základě posouzení klasifikačních přesností byla vyhodnocena úspěšnost klasifikace a využitelnost této klasifikační metody pro účely monitorování prvků rozptýlené zeleně v krajině.

Výsledky práce dokazují, že metoda objektové klasifikace družicových dat vysokého prostorového rozlišení je vhodná pro účely monitorování prvků rozptýlené zeleně.

## Seznam použitých zkratek

<b>DCP</b>	<b>Data Code Page</b> (datový formát obsahují proces či posloupnost procesů)
<b>DGN</b>	<b>Design</b> (datový formát pro uložení technické dokumentace)
<b>DPZ</b>	<b>Dálkový průzkum Země</b>
<b>GIS</b>	<b>Geografický informační systém</b>
<b>SHP</b>	<b>Shape file</b> (vektorový datový formát)
<b>SQL</b>	<b>Structured Query Language</b>
<b>VHR</b>	<b>Very High Resolution</b>

## Seznam literatury

- [1] Baatz, M., Schäpe, A., (1999): **Object-oriented and multi-scale image analysis in semantic networks**. In: Proceedings of the 2nd International Symposium on Operationalization of Remote Sensing, August 16–20th, International Institute for GeoInformation Science and Earth Observation, Enschede.
- [2] Baatz, M., Schäpe, A., (2000): **Multiresolution Segmentation – an optimization approach for high quality multi-scale image segmentation**. In: Strobl, J. et al., Angewandte Geographische Informationsverarbeitung XII, Karlsruhe, pp. 12–23.
- [3] Benz, U., Hofmann, P., Willhauck, G., Lingenfelder, I. and M. Heyen (2004): **Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information**. In ISPRS Journal of Photogrammetry and Remote Sensing 58 (2004), 239-258.
- [4] Blaschke, T., Lang, S. and Möller, M.S. (2005): **Object-based analysis of remote sensing data for landscape monitoring**. Recent developments. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 2879-2885.
- [5] Blaschke, T., Strobl, J. (2001): **What's wrong with pixels? Some recent developments interfacing remote sensing and GIS**. GIS Zeitschrift für Geoinformationssysteme 14(6), 12-17, 2001.
- [6] Carleer, A., Wolff, E. (2005): **The VHR data region-based classification possibilities in the framework of Control with Remote Sensing of European CAP**. Institute de Bestiin de l'Environnement et d'Aménagement du Territoire, Université Libre de Bruxelles, Belgium.
- [7] Cross, A. M., Mason, D. C. (1988): **Segmentation of remote-sensed images by split-and-merge process**. Int. J. Remote Sensing, 9(8): 1329-1345.

- [8] DEFINIENS IMAGING (2004): **eCognition Professional User Guide v4**. Definiens Imaging, München, Germany. 485 p.
- [9] de Kok, R; Schneider, T., Ammer, U. (1999): **Object based classification and applications in the Alpine forest environment**. In: procc. Joint ISPRS/EARSeL Workshop "Fusion of sensor data, knowledge sources and algorithms, Valladolid, Spain, June 3-4, 1999.
- [10] de Kok, R., Buck, A., Schneider, T., Ammer, U. (2000): **Advanced Classification of Remote Sensing Imagery**. In: GIM International, December 2000, Volume 14 Number 12: 77-79.
- [11] Gorte, B. (1998): **Probabilistic segmentation of remotely sensed images**. ITC, publication 63, PhD Thesis, ITC, Enschede.
- [12] Haberäcker, P. (1995): **Praxis der Digitalen Bildverarbeitung und Mustererkennung**. Hanser, München.
- [13] Hájek, F. (2006): **Object-oriented classification of Ikonos satellite data for the identification of tree species composition**, Faculty of Forestry and Environment, Czech University of Agriculture in Prague, Prague, Czech Republic.
- [14] Halounová, L.(2002): **Zkušenosti s programem eCognition pro klasifikaci urbanizovaného území z leteckých černobílých snímků a snímků TM**, GIS Ostrava.
- [15] Hay, G., Blaschke, T., Marceau, D., and Bouchard, A. (2003). **A Comparison of Three Image-Object Methods for the Multiscale Analysis of Landscape Structure**. ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 57, No. 5-6, pp. 327-345.

- [16] Kettig, R. L., Landgrebe, D. A. (1976): **Computer Classification of Remotely Sensed Multispectral Image Data by Extraction and Classification of Homogeneous Objects**. IEEE Transactions on Geoscience Electronics, Volume GE-14, No. 1, pp. 19-26, January 1976.
- [17] Komrska, V. (2006): **Detekce městské vegetace s využitím objektově orientované klasifikace**, Diplomová práce, PřF UK Praha.
- [18] Mathieu, R., Aryal, J. (2005) **Object-oriented classification and Ikonos multispectral imagery for mapping vegetation communities in urban areas**. In Proceedings: Seventeenth Annual Colloquium of the Spatial Information Research Centre. P.A. Whigham (Ed). 24 - 25 Nov, Dunedin, New Zealand. University of Otago, ISBN 1-877139-90-4, pp.181-188.
- [19] Moskal, M. (2004): **Historical landscape visualization of the wilson's creek national battlefield based on object oriented tree detection method from ikonos imagery**. Proceedings of ASPRS 2004 Annual Conference, Denver, USA. May 23-28.
- [20] **Obnova plošné a bodové zeleně v krajině** (2001). Sborník přednášek mezinárodního semináře, Brno.
- [21] **Rozptýlená zeleň v krajině a zemědělská dotační politika** (2006), MŽP 2006.
- [22] Schiwe, J., Tufte, L., Ehlers, M. (2001). **Potential and Problems of Multi-Scale Segmentation Methods in Remote Sensing**. GeoBIT/GIS, Vol.6, pp.34-39.
- [23] Štolba, R.(2001): **Posouzení možností klasifikace využití půdy z družicových dat pomocí nového software eCognition a určení vývoje okresu mezi lety 1975 – 1994**, Diplomová práce, Fakulta stavební ČVUT Praha.

- [24] Tuček, J (2002): **Príspevok k identifikácii individuálnych korún stromov z materiálov DPZ s vysokou priestorovou rozlišovanou schopnosťou alebo nove impulzy v dpz?** Medzinárodné vedecké sympóziu „Nové trendy v zisťovaní a monitorovaní stavu lesa, 16. –17. september 2002, Poľana.
- [25] Tuček, J. (2005): **Digitálna segmentácia a klasifikácia obrazu v prostredí eCognition: Vegetácia vysokých polôh z údajov CIR a Ikonos**, In: Enviro I Forum 2005, Zborník referátov, Slovenská agentúra životného prostredia Banská Bystrica, 2005, 212-218.
- [26] Zhang, Y. (2001): **A spectral and spatial information integrated approach for object extraction from high-resolution digital imagery**. Digital Earth 2001: Beyond Information Infrastructure, Fredericton, N.B., 24-28 June.
- [27] Zhang, X., Feng, X. (2005): **Detecting urban vegetation from IKONOS data using an object-oriented approach**. In: International Geoscience And Remote Sensing symposium, Harmony between Man and Nature, Seoul, Korea.
- [28] Zhang, Y. and T. Maxwell (2006): **A trained segmentation technique for optimization of object-oriented classification**. ISPRS Commission VII, Mid-Term Symposium, Enschede, the Netherlands, May 8-11.
- [29] Žambochová, K. (2001): **Posouzení možnosti automatické klasifikace a vizuální interpretace leteckých měřických snímků několika časových úrovní pro určení vývoje města Chomutova**, Diplomová práce, Fakulta stavební ČVUT Praha.

## Seznam internetových zdrojů

[URL1] **Arcdata Praha**

<http://www.arcdata.cz/data/druzicova/ikonos>

[URL2] **Český úřad zeměměřičský a katastrální**

[www.cuzk.cz](http://www.cuzk.cz)

[URL3] **Gisat**

[www.gisat.cz](http://www.gisat.cz)

[URL4] **Nadace Partnerství**

<http://www.nadacepartnerstvi.cz/p-1249354321&exp=male9>



## Seznam obrázků

- Obr. 1: Ukázka funkcí příslušnosti v uživatelském rozhraní softwaru Definiens Professional
- Obr. 2: Poloha modelové oblasti v rámci ČR
- Obr. 3: Prvek rozptýlené vegetace na snímku IKONOS (barevná syntéza spektrálních pásem v pořadí 432).
- Obr. 4: Masky lesů, zastavěných ploch a vodních ploch vytvořená na základě vektorové vrstvy ZABAGED.
- Obr. 5: Klasifikační prostor pro vizuální interpretaci dat a vektorizaci prvků rozptýlené zeleně (barevná syntéza spektrálních pásem družice IKONOS v pořadí 321 a 432).
- Obr. 6: Výsledek vizuální interpretace dat – zeleně jsou vyznačeny polygony ohraničující prvky rozptýlené zeleně.
- Obr. 7: Vliv hodnoty měřítkového parametru na spojení objektů
- Obr. 8: Segmentace podle jednotlivých spektrálních pásem (v pořadí R,G,B a NIR) s použitím měřítkového parametru 0.
- Obr. 9: Výsledek segmentace při použití tří spektrálních pásem současně (v prvním případě R,G,B a ve druhém NIR, R,G) s použitím měřítkového parametru 0.
- Obr. 10: Výsledek segmentace s použitím měřítkového parametru 10, 20, 30 a 40.
- Obr. 11: Výsledek segmentace s použitím hodnot tvarového faktoru 0, 0.5 a 0.9 při stejné hodnotě měřítkového parametru a podílu kompaktnosti i hladkosti tvaru 0.5.
- Obr. 12: Výsledek segmentace s použitím různého podílu vlivu kompaktnosti na tvarovou složku heterogenity (kompaktnost 1, 0.5, 0).
- Obr. 13: Přesnost klasifikace při použití různých hodnot měřítkového parametru.
- Obr. 14: Přesnost klasifikace při použití různých kombinací segmentačních parametrů.
- Obr. 15: Přesnost klasifikace při použití různého podílu vlivu kompaktnosti a hladkosti na tvarové složce heterogenity.
- Obr. 16: Podíl směrodatných odchylek všech spektrálních hodnot a světlosti objektů v testovacím výřezu 1. Hodnoty jsou znázorněny pomocí stupňů šedi. Světlejší objekty mají vyšší hodnotu tohoto příznaku.
- Obr. 17: Hodnoty příznaku podíl směrodatných odchylek všech spektrálních hodnot a světlosti pro vzorky tříd prvek rozptýlené zeleně a jiný objekt.

- Obr. 18: Klasifikace objektů pomocí příznaku podíl směrodatných odchylek všech spektrálních hodnot a světlosti.
- Obr. 19: Hodnoty příznaku střední hodnota v červeném spektrálním pásmu ve stupních šedi a následná klasifikace objektů na základě tohoto příznaku.
- Obr. 20: Výsledek klasifikace ve druhé fázi hierarchické klasifikace.
- Obr. 21: Hodnoty příznaku podíl směrodatné odchylky v modrém spektrálním pásmu a světlosti objektů ve stupních šedi a následná klasifikace objektů na základě tohoto příznaku.
- Obr. 22: Výsledek klasifikace ve třetí fázi hierarchické klasifikace.
- Obr. 23: Části korun stromů přiřazené ke třídě rozptýlené zeleně pomocí kontextuálního příznaku relativní hranice k sousednímu objektu dané třídy.
- Obr. 24: Výsledek hierarchické klasifikace na testovacím výřezu 1.
- Obr. 25: Dvě podoby klasifikační hierarchie – vlevo hierarchie založená na dědičnosti příznaků mateřských tříd, vpravo pak hierarchie stejné klasifikace uspořádaná na základě významu jednotlivých tříd.
- Obr. 26: Výsledná podoba klasifikace metodou prahování na testovacím výřezu 1 – třídy jsou podle významu uspořádány do dvou nadřazených tříd – prvky rozptýlené zeleně a jiné objekty.
- Obr. 27: Ukázka výsledku klasifikace prvků rozptýlené zeleně na podkladu dat družice IKONOS (barevná syntéza spektrálních pásem v pořadí 321 a 432).
- Obr. 28: Rozdílná delineeace hranic prvků rozptýlené zeleně při použití vizuální interpretace a automatické klasifikace.

## **Abstrakt**

Tato diplomová práce se zabývá využitím objektové analýzy družicových dat vysokého rozlišení pro účely monitorování prvků rozptýlené zeleně v krajině.

Úvod práce je věnován problematice prvků rozptýlené zeleně v krajině, jejich ochraně a monitorování. Teoretická část popisuje metody objektové analýzy dat, uvádí přehled literatury zabývající se touto problematikou, diskutuje přínosy objektové analýzy. Zvláštní pozornost je věnována algoritmu multiměřítkové segmentace.

V praktické části práce jsou metody objektové analýzy aplikovány na data družice IKONOS. Pomocí softwaru Definiens Professional jsou hledány optimální segmentační parametry pro danou aplikaci a dále testovány specifické příznaky vhodné pro určení prvků rozptýlené zeleně. Byly stanoveny optimální parametry segmentace a vytvořeny dva klasifikační postupy využívající metody nejbližšího souseda a metody prahování. Dosažená uživatelská i producentská přesnost obou provedených klasifikací se pohybovala okolo hranice 80%.

Výsledky práce potvrzují vhodnost využití objektové klasifikace družicových dat vysokého rozlišení pro účely monitorování prvků rozptýlené zeleně v krajině.

## **Abstract**

This diploma thesis deals with the application of VHR satellite data object-oriented classification for landscape scattered vegetation monitoring. The thesis includes an introduction to scattered vegetation preservation and monitoring in the Czech Republic. The theoretical part describes object-oriented methods of image data analysis, presents appropriate bibliography and discuss the benefits of this method. Special attention is paid to multiresolution segmentation algorithm.

In practical part these methods were applied on IKONOS data, using Definiens Professional software. Optimal combinations of segmentation parameters and specific features for determination of scattered vegetation units have been found. Two different classification methods were applied – nearest neighbor classifier and thresholding. Producer and user accuracy achieved using both methods were about 80%.

The results of this research have shown the suitability of VHR satellite data object-oriented classification on purpose of the scattered vegetation monitoring.