

Univerzita Palackého v Olomouci

Přírodovědecká fakulta

Katedra geoinformatiky

Eva TÖGELOVÁ

**POROVNÁNÍ PER-PIXEL KLASIFIKÁTORŮ PRO
IDENTIFIKACI ZÁSTAVBY**

Bakalářská práce

Vedoucí práce: RNDr. Jakub Miřijovský

Olomouc 2011

Čestné prohlášení

Prohlašuji, že jsem bakalářskou práci bakalářského studia oboru Geoinformatika a geografie vypracovala samostatně pod vedením RNDr. Jakuba Miřijovského.

Všechny použité materiály a zdroje jsou citovány s ohledem na vědeckou etiku, autorská práva a zákony na ochranu duševního vlastnictví.

Všechna poskytnutá i vytvořená digitální data nebudu bez souhlasu školy poskytovat.

V Olomouci dne 24. května 2011

Děkuji vedoucímu práce RNDr. Jakobovi Miřijovskému za podněty a připomínky při vypracování práce.

Za poskytnutá data děkuji Vojenskému geografickému a hydrometeorologickému úřadu v Dobrušce, firmě GEODIS BRNO spol. s r. o., agentuře NASA za projekt NASA Landsat Program a Marylandské univerzitě, jejímž prostřednictvím byla data získána.

Vložený originál **zadání** bakalářské/magisterské práce (s podpisy vedoucího katedry, vedoucího práce a razítkem katedry). Ve druhém výtisku práce je vevázána fotokopie zadání.

OBSAH

SEZNAM POUŽITÝCH ZKRATEK	7
ÚVOD.....	8
1 CÍLE PRÁCE.....	9
2 POUŽITÉ METODY A POSTUPY ZPRACOVÁNÍ	10
2.1 Použitá data	10
2.2 Použité programy	10
2.3 Postup zpracování	11
3 DÁLKOVÝ PRŮZKUM ZEMĚ A DIGITÁLNÍ ZPRACOVÁNÍ OBRAZU	12
3.1 Definice DPZ	12
3.2 Fyzikální podstata DPZ.....	12
3.3 Digitální zpracování obrazu	12
3.4 Klasifikace obrazu.....	13
3.4.1 Řízená klasifikace	14
3.5 Klasifikátory.....	14
3.5.1 Klasifikátor minimální vzdálenosti.....	15
3.5.2 Klasifikátor pravoúhelníků (tzv. paralelepipedů)	17
3.5.3 Klasifikátor maximální pravděpodobnosti	18
3.5.4 Klasifikátor Mahalanobisovy vzdálenosti	21
3.6 Úprava a hodnocení klasifikace	21
3.6.1 Klasifikační chybová matice.....	22
3.6.2 Kappa koeficient.....	23
3.7 Identifikace zástavby.....	23
4 VLASTNÍ ŘEŠENÍ	25
4.1 Příprava dat	25
4.2 Tvorba trénovacích ploch.....	27
4.3 Výpočet statistických charakteristik vstupních dat	28
4.4 Klasifikační etapa a hodnocení přesnosti klasifikace.....	31
4.4.1 Barevný letecký snímek.....	32
4.4.2 Černobílý letecký snímek	36
4.4.3 Multispektrální družicový snímek	39
4.5 Úprava výsledků klasifikace	43
4.6 Klasifikace plošně rozsáhlého území	44

5 DISKUZE	47
6 ZÁVĚR	48
POUŽITÁ LITERATURA	
INFORMAČNÍ ZDROJE	
SUMMARY	
SEZNAM PŘÍLOH	

SEZNAM POUŽITÝCH ZKRATEK

Zkratka	Význam
AOI	area of interest
DN	digital number
DPZ	dálkový průzkum Země
ENVI	Environment for Visualizing Images
ERDAS	Earth Resources Data Analysis System
ESRI	Environmental System Research Institute
ETM+	Enhanced Thematic Mapper Plus
GLCF	Global Land Cover Facility
CHO	chyba z opomenutí
CHZ	chyba z nesprávného zařazení
NASA	National Aeronautics and Space Agency
PO	přesnost dosažitelná čistě náhodným zařazením pixelů do jednotlivých tříd
PP	přesnost pozorovaná
PU	přesnost z hlediska uživatele
PZ	přesnost z hlediska zpracovatele
S-JTSK	souřadnicový systém jednotné trigonometrické sítě katastrální
SO	směrodatná odchylka
VGHMÚř	Vojenský geografický a hydrometeorologický úřad

ÚVOD

Metody dálkového průzkumu Země (dále jen DPZ) a digitálního zpracování obrazu dnes nabízejí rozsáhlé možnosti studia socioekonomických a fyzicko-geografických jevů prostřednictvím analýzy leteckých a družicových snímků. Jedním z oborů, kde se tyto metody dají využít je i urbanismus, mezi jehož potřeby patří například identifikace zástavby, kterou se mimo jiné zabývá tato práce.

Potřebné informace je z leteckých a družicových snímků možné získat různými způsoby. Jedním z nich je klasifikace obrazu, což je proces zařazení všech obrazových prvků do stanovených tříd reprezentujících konkrétní druhy povrchu. Třídění probíhá na základě určitých rozhodovacích pravidel. Těmito pravidly jsou i per-pixel klasifikátory, které jsou předmětem studia této práce. Jedná se o klasifikační algoritmy vyhodnocující jednotlivé obrazové prvky bez ohledu na okolní pixely. Pro správný výběr klasifikátorů je třeba se s nimi dobře seznámit a provést jejich testování. Kvalitu výstupů v podobě klasifikovaných snímků lze posoudit výpočtem statistických hodnot reprezentujících přesnost a množství vyprodukovaných chyb. Konečným výsledkem práce by mělo být zhodnocení vhodnosti jednotlivých klasifikátorů k identifikaci zástavby pro konkrétní druhy dat a jejich vzájemné srovnání. Všechny tyto informace pak mohou být dále využity v urbanistických studiích, jako je například sledování změn rozlohy zastavěného území v daném časovém horizontu.

1 CÍLE PRÁCE

Cílem bakalářské práce je porovnat vybrané per-pixel klasifikátory pro identifikaci zástavby. V rámci pracovního postupu bude vytvořen podrobný popis jednotlivých klasifikátorů a na vybraných datech bude provedeno jejich testování. Testovanými algoritmy budou klasifikátory minimální vzdálenosti, pravoúhelníků, maximální pravděpodobnosti a Mahalanobisovy vzdálenosti. U klasifikátoru s proměnnou (v tomto případě u klasifikátoru pravoúhelníků) bude vyzkoušeno vícero možností. Provede se statistické hodnocení přesnosti klasifikace, a to formou vytvoření chybové matice a výpočtu Kappa koeficientu. Chybová matice bude obsahovat procentuální hodnoty vypočtených přesností a zastoupení chyb. Podle těchto údajů bude dále provedeno slovní zhodnocení jednotlivých klasifikátorů s výběrem nejvhodnějšího pro konkrétní druh dat. Dalším úkolem je provést s nejvhodnějším klasifikátorem pro vybranou datovou sadu identifikaci zástavby ve větším plošném rozsahu.

Hlavním výstupem práce by tedy mělo být slovní i statistické zhodnocení a vzájemné srovnání vybraných klasifikátorů. Na základě klasifikovaných leteckých a družicových snímků by se měla posuzovat rovněž kvalita a vhodnost provedené klasifikace pro identifikaci zástavby. Dalšími předpokládanými výstupy jsou klasifikované snímky upravené majoritním filtrem a zklasifikovaná datová sada zachycující území ve větším plošném rozsahu.

2 POUŽITÉ METODY A POSTUPY ZPRACOVÁNÍ

V této bakalářské práci je použito velké množství metod a postupů zpracování. Pracovní plán je zahájen nastudováním problematiky vztahující se k tématu. Čerpáno je zejména z knižních publikací, dále pak z webových stránek a periodik. Dalším krokem je sepsání rešerše, která má za úkol vysvětlit základní pojmy související s DPZ a digitálním zpracováním obrazu, podrobně popsat druhy testovaných klasifikátorů a zhodnotit současný stav metodiky využívané pro účely identifikace zástavby. Hlavními zdroji jsou práce *Dálkový průzkum Země, Digitální zpracování obrazu* (Dobrovolný, 1998), *Remote Sensing Digital Image Analysis: An Introduction* (Richards, Jia, 2006) a *Remote Sensing of Urban and Suburban Areas: Remote Sensing and Digital Image Processing* (Rashed a Jürgens, 2010). Při vlastním praktickém řešení se kromě těchto zmiňovaných publikací hodně čerpá také z *ERDAS Field Guide* (1995).

2.1 Použitá data

Vstupními daty jsou tři druhy snímků, které byly pořízeny metodami DPZ. Jako první je postup testování jednotlivých klasifikátorů vyzkoušen na barevném leteckém snímku pocházejícím z datové sady poskytnuté firmou GEODIS Brno (obr. 6). Celá datová sada je využita pro identifikaci plošně rozsáhlého území. Barevné záznamy byly vytvořeny v roce 2007 a mají měřítko 1 : 20 000. Následuje úprava a klasifikace černobílého leteckého snímku z datové sady pořízené roku 1985, jež byla získána z VGHMÚř (Vojenský geografický a hydrometeorologický úřad) v Dobrušce (obr. 7). Snímek má měřítko 1 : 27 220. Nakonec je zpracován multispektrální družicový snímek z roku 2005 s prostorovým rozlišením 30 m a velikostí scény 183 x 173 km. Snímek vznikl v rámci projektu NASA Landsat Program a byl opatřen na webových stránkách GLCF (Global Land Cover Facility): Earth Science Data Interface Marylandské univerzity (obr. 8).

2.2 Použité programy

Příprava dat formou georeferencování je prováděna v ESRI softwaru ArcGIS 10. Tento program byl vybrán na základě předchozích pracovních zkušeností. Pro samotný proces testování a následného hodnocení per-pixel klasifikátorů je zvolen program ERDAS IMAGINE 9.1, který byl získán jako 30-ti denní demoverze z webových stránek firmy ERDAS.

2.3 Postup zpracování

Pracovní postup je zahájen nastudováním problematiky a tvorbou rešerše. Text se zaměřuje na vysvětlení základních poznatků z oblasti DPZ, digitálního zpracování obrazu, klasifikace a identifikace zástavby. Nejdůležitější částí je pak podrobný popis vybraných klasifikátorů doplněný matematickými definicemi a ilustracemi.

Vlastní řešení zadání je započato přípravou dat. Letecké snímky jsou georeferencovány v programu ArcGIS 10 do souřadnicového systému S-JTSK. Pro potřeby klasifikace plošně rozsáhlého území, což je jeden z cílů práce, je nutné vytvořit z jednotlivých snímků mozaiku, se kterou je možné zacházet jako s jediným snímkem. Tento krok je proveden pomocí nástroje Mosaic Tool v programu ERDAS IMAGINE 9.1. V tomto softwaru se budou odehrávat všechny další práce. Multispektrální družicový snímek pořízený přístrojem ETM+ družice Landsat je poskytnut po jednotlivých pásmech, ze kterých je třeba vytvořit barevnou kompozici. K tomuto účelu slouží nástroj Layer Stack. Takto upravená vstupní data jsou připravena na další fázi.

Samotné klasifikační etapě předchází několik kroků. Jedná se zejména o tvorbu trénovacích ploch. Tyto plochy zastupují dvě stanovené třídy, kterými jsou Zastavěné území a Ostatní. Výběr trénovacích ploch provádí manuálně sám uživatel nebo si pomůže nástrojem Region Grow, který vytvoří tzv. seed pixel, podle nějž jsou vybírány spektrálně podobné pixely. Pro tvorbu trénovacích ploch jsou definována určitá pravidla, kterých je třeba se držet. Důležité je například vyhýbat se okrajovým pixelům, které často nesou smíšenou spektrální informaci. Z trénovacích ploch jsou následně vytvořeny signatury, ze kterých se vypočtou statistické charakteristiky, které popisují kvalitu těchto dat. Vyjádřit kvalitu lze i graficky, a to například prostřednictvím histogramů a grafů korelačního pole DN (digital number) hodnot vizualizujících vztah dvou pásem multispektrálního prostoru. Mezi kvantitativní metodu hodnocení míry separability mezi dvěma třídami patří transformovaná divergence, která je automaticky vypočtena programem.

Testování klasifikátorů je prováděno na černobílém a barevném leteckém snímku a na multispektrálním družicovém snímku. Testují se klasifikátory minimální vzdálenosti, pravoúhelníků, maximální pravděpodobnosti a Mahalanobisovy vzdálenosti. Pro klasifikátor pravoúhelníků jsou vyzkoušeny tři možnosti nastavení hranic pravoúhelníků podle násobků směrodatné odchylky. Po vytvoření výstupů v podobě klasifikovaných snímků se přechází k hodnocení přesnosti. Ta obsahuje proces srovnání referenčních a klasifikovaných dat. Výsledkem je chybová matice, která interpretuje informace o přesnosti i chybách jednotlivých klasifikací za pomoci odlišných klasifikátorů. Tyto poznatky jsou slovně okomentovány a vybrané klasifikátory jsou vzájemně porovnány.

Na vybraném klasifikovaném snímku jsou vyzkoušeny postklasifikační úpravy v podobě majoritní filtrace. Pro konkrétní datovou sadu je provedena klasifikace plošně rozsáhlého území.

3 DÁLKOVÝ PRŮZKUM ZEMĚ A DIGITÁLNÍ ZPRACOVÁNÍ OBRAZU

Dálkový průzkum Země spolu s digitálním zpracováním obrazu v poslední době nabývají na významu, okruh jejich uživatelů se neustále rozšiřuje a uplatnění v nejrůznějších oborech a aplikacích dále stoupá. Proto je důležité se dálkovému průzkumu Země a digitálnímu zpracování obrazu nadále věnovat a posouvat hranice znalostí stále kupředu.

3.1 Definice DPZ

„Dálkový průzkum je věda i umění získávat užitečné informace o objektech, plochách či jevech prostřednictvím dat měřených na zařízení, která s těmito zkoumanými objekty, plochami či jevy nejsou v přímém kontaktu.“ (Lillesand, Kiefer, 1994)

„Dálkový průzkum je způsob získávání informací o zemském povrchu i vodních plochách s využitím snímků pořízených z ptačí perspektivy, využívá elektromagnetického záření v jednom nebo více intervalech spektra, toto záření je odráženo nebo emitováno ze zemského povrchu.“ (Campbell, 2002)

3.2 Fyzikální podstata DPZ

Všechny objekty nebo jevy na zemském povrchu o sobě vydávají informace prostřednictvím tzv. silových polí. Silové pole využívané v dálkovém průzkumu se nazývá elektromagnetické a jedním z jeho projevů je viditelné záření, které dokáže být vnímáno lidským okem. V dnešní době existují přístroje, které umožňují sledovat objekty a jevy v oblasti viditelného světla i mimo něj (Dobrovolný, 1998).

3.3 Digitální zpracování obrazu

Materiály pořízené metodami DPZ se dělí na analogové a digitální. Zpracování digitálního obrazu nabývá na významu od 70. let, zejména zásluhou dostupnosti digitálních dat pořizovaných družicemi Landsat a rozvoje výpočetní techniky. Díky obrazu uloženému v číslicové podobě a technickým možnostem byla zautomatizována a urychlena řada postupů. Dalšími výhodami jsou objektivita, přesnost a nižší náklady na zpracování (Dobrovolný, 1998).

3.4 Klasifikace obrazu

Klasifikací je rozuměn postup, kdy je jednotlivým pixelům dodán určitý informační význam. Výsledkem by pak mělo být nahrazení hodnot radiometrických charakteristik referenčního obrazu. Dochází také k hledání informačních tříd, které se na počátku klasifikace stanoví ve formě tzv. klasifikačního schématu (Dobrovolný, 1998).

Klasifikace obrazu je založena na použití klasifikátorů, což jsou určitá rozhodovací pravidla, na jejichž základě lze všechny obrazové prvky zařadit do určité třídy. Tyto klasifikační algoritmy se dají rozdělit na klasifikátory prostorového, časového a spektrálního chování. Nejvíce propracované a k automatické klasifikaci nejvyužívanější jsou klasifikátory spektrálního chování objektů. Takovými klasifikátory jsou například bodové („per-pixel“) klasifikátory (viz podkapitola 3.5). Předpokladem je, že každý pixel může náležet pouze do jedné třídy. Klasifikace se obecně dělí na řízenou (angl. supervised) a neřízenou (angl. unsupervised).

Rashed a Jürgens (2010) ve své práci zmiňují, že většina metod pro zpracování obrazu, rozvinutých od počátku sedmdesátých let dvacátého století až po současnost, je založena na klasifikaci jednotlivých pixelů seskupovaných ve vícerozměrném funkčním prostoru. Pixely nesou integrovaný radiometrický signál a jsou charakterizovány velikostí buňky (angl. cell size). Obrazové prvky vydávají velké množství informací o obrazu, který tvoří, nicméně práce s jednotlivými prvky má své limity, protože pixely jsou v prostorových souvislostech považovány za nezávislé vzorky (kterými však ve skutečnosti nejsou). Přestože byla rozvinuta řada sofistikovaných a dnes již dobře zavedených technik, aktuální požadavky komunity DPZ nejsou vzhledem k různým charakteristikám snímků s vysokým rozlišením zcela naplňovány. Nové senzory významně zvýšily třídní spektrální variabilitu a zároveň snížily potenciální přesnost pixelově založených přístupů ke klasifikaci. V důsledku toho byly algoritmy pro zpracování obrazu doplněny a někdy i nahrazeny novějšími klasifikačními metodami. Současný trend spočívá v zabývání se shluky pixelů jako prostorově souvislými a spektrálně homogenními skupinami prvků (spíše než samostatnými pixely), podporujíc tak geometrické, topologické a texturní vlastnosti. Dle Blaschke a Strobl (2001) tyto shluky slibují mnohem bohatší a mocnější pracovní prostředí v celém procesu klasifikace. Prostorové vztahy popisující hierarchické („vertikální“) nebo postranní sousedství pixelů mohou být během klasifikace plně brány v úvahu. Klasifikace využívající této metody se často označuje jako objektově založená (Rashed, Jürgens, 2010).

3.4.1 Řízená klasifikace

Řízená klasifikace je proces použití vzorků o známé identitě k zatřídění neznámých pixelů. Těmito vzorky jsou obrazové prvky lokalizované v trénovacích plochách. Úkolem zpracovatele je definovat trénovací data pro hledané druhy povrchů určením částí obrazů, jejichž identita je jasně známa. Následná klasifikace obrazu spočívá v použití vhodných algoritmů k zařazení pixelů do jednotlivých informačních tříd dle typu povrchu (Campbell, 2002).

Řízená klasifikace obvykle obsahuje následující kroky (Richards, Jia, 2006).

1. Stanovení počtu a druhu informačních tříd, do kterých mají být obrazové prvky rozříděny
2. Výběr reprezentačních pixelů pro každou stanovenou informační třídu. Tyto pixely jsou označovány jako trénovací data. Sady trénovacích dat pro každou třídu mohou být stanoveny na základě map, leteckých nebo satelitních snímků. Trénovací pixely pro danou třídu často leží ve stejné oblasti vymezené hranicí. Tato oblast se pak nazývá trénovací plocha
3. Použití trénovacích dat pro stanovení parametrů jednotlivých klasifikačních algoritmů, které mají být použity. Soubor parametrů se často nazývá signatura třídy
4. Zařazení každého pixelu do jedné z informačních tříd použitím klasifikátorů a trénovacích ploch. V tomto kroku je provedena samotná klasifikace všech zbývajících pixelů v daném zájmovém území, které nebyly stanoveny jako trénovací
5. Tvorba tabulkových a obrazových výstupů, které shrnují výsledky klasifikace
6. Zhodnocení přesnosti výstupů

3.5 Klasifikátory

Dle Dobrovolného (1998) jsou klasifikátory rozhodovací pravidla, na jejichž základě jsou pixely zařazovány do příslušné třídy. Předpokladem pro fungování klasifikačních algoritmů je shlukování pixelů představujících danou třídu v určité části vícerozměrného příznakového prostoru. Požadavkem je tedy nalezení rozhodovacího pravidla, které stanoví, ke kterému shluku každý pixel patří. Na následujících obrázcích ilustrujících jednotlivé klasifikátory jsou znázorněna dvě pásma a tři kategorie povrchů (A, B, C). Obrazové prvky každé z tříd tvoří shluky. Jejich středy (centroidy) jsou představovány křížkem (+). Všem obrazovým prvkům je nyní zapotřebí přiřadit význam jedné z tříd. Zatřídovaný pixel je prezentován značkou čtverečku (\square).

Per-pixel (bodové) klasifikátory používají k zatřídění pixelů do jednotlivých tříd pouze příznaků klasifikovaného pixelu, nezabývají se okolními obrazovými prvky. Kromě per-pixel klasifikátorů existují klasifikátory tzv. prostorového chování objektů, které provádí klasifikaci objektů na základě okolních pixelů. Klasifikační algoritmy se snaží odhalit skutečné spektrální a prostorové vlastnosti snímků, které indikují reálné jevy a procesy.

Mezi často používané per-pixel klasifikátory patří:

- klasifikátor minimální vzdálenosti,
- klasifikátor pravoúhelníků (tzv. paralelepiped),
- klasifikátor maximální pravděpodobnosti,
- klasifikátor Mahalanobisovy vzdálenosti.

3.5.1 Klasifikátor minimální vzdálenosti

Klasifikátor minimální vzdálenosti nebo přesněji minimální vzdálenosti středů shluků představuje algoritmus, který nepracuje s informacemi o kovarianci, ale závisí jen na pozici spektrální třídy v korelačním poli, neboť ta může být odhadnuta přesněji než kovariance. S tímto klasifikátorem jsou trénovací data použita pouze pro určení středů shluků; klasifikace se pak provádí umístováním pixelů do shluku s nejbližším středem. Potenciální problém pravidla minimální vzdálenosti je ten, že nebere v úvahu různou šířku rozptylu ve spektrálních vlastnostech dat, což může vést k chybné klasifikaci (Aronoff, 2005). Z tohoto důvodu se tento klasifikátor nepoužívá v případech, kdy jsou spektrální třídy v příznakovém prostoru poblíž sebe a mají velký rozptyl hodnot. Algoritmus minimální vzdálenosti je však atraktivní technikou z hlediska rychlosti. Klasifikace s jeho pomocí je rychlejší než klasifikace s klasifikátorem maximální pravděpodobnosti, nicméně vzhledem k tomu, že nepracuje s údaji o kovarianci, je tato metoda méně flexibilní než druhá výše zmíněná (Richards, Jia, 2006).

Richards a Jia (2006) popisují diskriminační funkci klasifikátoru minimální vzdálenosti středů shluků následovně.

Necht'

$$m_i, i = 1, \dots, M$$

jsou průměry tříd M určené z trénovacích dat.

Proměnná x je pozice klasifikovaného pixelu. Výpočet souboru Euklidovských vzdáleností neznámého pixelu ke každému středu shluku je definován ve vektorové formě jako:

$$\begin{aligned} d(x, m_i)^2 &= (x - m_i)^t (x - m_i) \\ &= (x - m_i) * (x - m_i), i = 1, \dots, M, \end{aligned}$$

z čehož se dále odvodí vztah

$$d(x, m_i)^2 = x * x - 2m_i * x + m_i * m_i.$$

Klasifikace se provádí za předpokladu, že

$$x \in w_i, \text{ jestliže } d(x, m_i)^2 < d(x, m_j)^2 \text{ pro všechna } j \neq i.$$

Je třeba si povšimnout, že $x * x$ je společné pro všechna $d(x, m_j)^2$, a proto může být odstraněno. Vhodnější, než provádět klasifikaci podle zbývajících výrazů, je obrátit znaménka a klasifikovat na základě

$$x \in w_i, \text{ jestliže } g_i(x) > g_j(x) \text{ pro všechna } j \neq i,$$

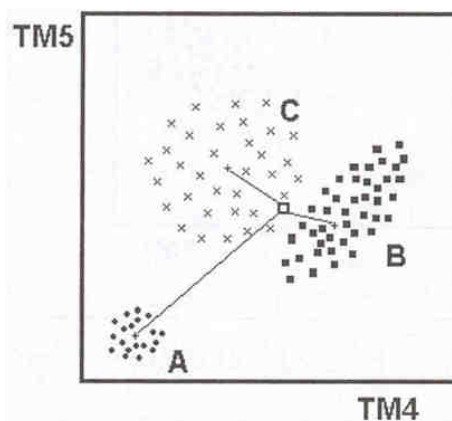
kde

$$g_i(x) = 2m_i * x - m_i * m_i, \text{ atd.}$$

Tato rovnice definuje diskriminační funkci pro klasifikátor minimální vzdálenosti.

Klasifikace může být provedena použitím i jiné než Euklidovské vzdálenosti (Wacker a Landgrebe, 1972). Nicméně většina softwarových produktů pro zpracování obrazu jako je Multispec, ENVI nebo ERMapper mají implementovány právě Euklidovské vzdálenosti.

Algoritmus minimální vzdálenosti středů shluků je graficky znázorněn na obr. 1. Vzdálenost neznámého pixelu (\square) od středů všech tří shluků je vyjádřena čarou. Podle klasifikátoru minimální vzdálenosti se neznámý pixel přiřadí ke shluku „B“. Pokud by byl uvažován také rozptyl shluků, potom by neznámý pixel náležel ke třídě „C“.




Obr. 1 Klasifikátor minimální vzdálenosti (Dobrovolný, 1998).

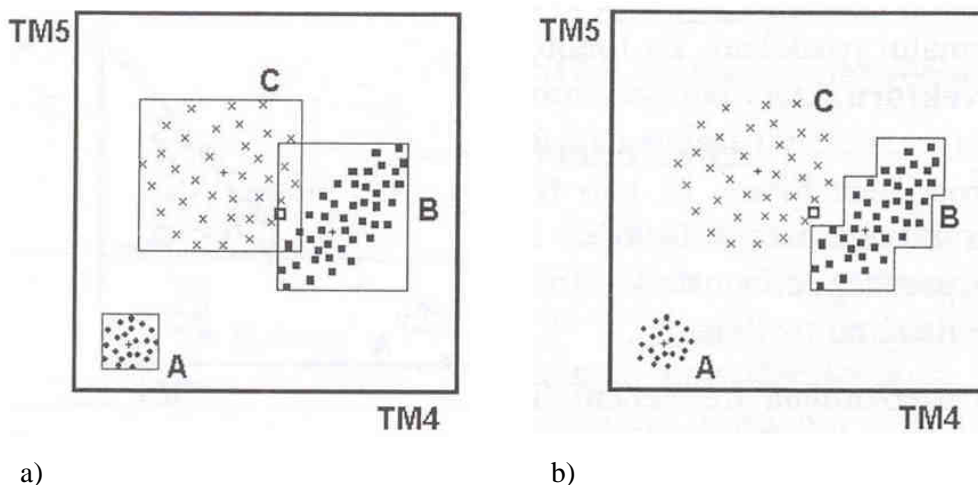
3.5.2 Klasifikátor pravoúhelníků (tzv. paralelepipedů)

Klasifikátor pravoúhelníků je velmi jednoduchý algoritmus, který v zásadě pracuje na principu sledování jednotlivých spektrálních složek histogramů vytvořených z dostupných trénovacích dat. Na obr. 2 jsou znázorněna dvourozměrná data v histogramech jedné spektrální třídy. Dolní i horní vyznačené meze jsou zde identifikovány a použity k popisu rozpětí hodnot třídy. Rozpětí ve všech pásmech jsou uvažována jako minimální a maximální hodnoty trénovacích pixelů a jsou popisována vícerozměrným polem nebo pravoúhelníkem. Pravoúhelník vznikne vedením rovnoběžné linie pixelů s právě těmito hodnotami v každém pásmu. Pokud jsou v procesu klasifikace pixely nalezeny v takovémto pravoúhelníku, jsou označeny jako patřící do dané třídy (obr. 3a). Citlivost na rozptyl hodnot všech tříd je u tohoto pravidla definována velikostí dané oblasti (Dobrovolný, 1998). V případě situace na obr. 4 by mohl být zařazený pixel (□) zařazen do třídy B i C, neboť jejich pravoúhelníky zabírají značnou část multispektrálního prostoru a nastává větší pravděpodobnost překrytu. Kromě velkého rozptylu může být překryv pravoúhelníků zapříčiněn rovněž vysokou korelací hodnot pixelů v klasifikovaných pásmech (shluk má „protáhlý“ tvar). Klasifikátor pravoúhelníků je algoritmicky jednoduchý a výpočetně rychlý, takže může být prakticky využit pro klasifikaci velkého počtu obrazových dat (Aronoff, 2005).

Kvalitu trénovací etapy dle Dobrovolného (1998) snižují především pixely odlehle. Většina programů umožňuje nastavit pro klasifikátor hranice každého pravoúhelníku nejen podle minimální a maximální hodnoty, ale také podle násobku směrodatné odchylky, což je vhodné pro odfiltrování obrazových prvků netypických pro danou třídu. Výsledkem je pak zvýšení přesnosti klasifikace. Objekty ve spektrálním prostoru se často vyznačují vzájemnou korelací. Klasifikátor je pak možné definovat pro každou třídu vymezením vhodných oblastí namísto rovnoběžníků (obr. 3b).



Obr. 2 Histogramy dvourozměrných sad trénovacích dat odpovídající jedné spektrální třídě. Horní a dolní meze (Upper a Lower threshold) jsou identifikovány jako hrany dvourozměrného pravoúhelníku (Richards, Jia, 2006).




Obr. 3 Klasifikátor pravoúhelníků a) jednoduchý, b) upravený (Dobrovolný, 1998).

3.5.3 Klasifikátor maximální pravděpodobnosti


Řízená klasifikace s pomocí klasifikátoru maximální pravděpodobnosti je častou a velmi oblíbenou metodou klasifikace snímků z DPZ. Jedná se o klasifikátor založený na stochastických mechanismech. V příznakovém prostoru často nastává situace, kdy se shluky jednotlivých tříd překrývají, což mnohdy znemožňuje správné rozřídění obrazových prvků v tomto prostoru. Klasifikátor maximální pravděpodobnosti však u natrénovaných shluků pixelů předpokládá normální rozdělení a hodnotí nejen rozptyl hodnot, ale také korelaci a kovarianci každé třídy. Pak je podle Dobrovolného (1998) pro každý shluk možné z tzv. průměrového vektoru a z kovarianční matice popisující míru variability, vytvořit frekvenční funkci normálního rozdělení (obr. 5), která spolu s horizontální osou vymezuje plochu o velikosti 1 (100 %). Pro všechny hodnoty na horizontální ose je možné vypočítat pravděpodobnost jejich výskytu.

Podle Rasheda a Jürgense (2010) je klasifikátor maximální pravděpodobnosti výpočetně nejnáročnější a je také velmi citlivý na nedostatky trénovacích dat. S kvalitními trénovacími daty však dosahuje nejlepších výsledků. Přesnost klasifikátorů maximální pravděpodobnosti se obecně zvyšuje, pokud existuje trvalý předpoklad normálního rozdělení. Avšak přesnost může být dramaticky narušena v případě, že je rozdělení reprezentující různé druhy povrchu daleko od normálu, jako je tomu v případě komplexního heterogenního městského prostředí. Navíc parametrické klasifikátory často nejsou schopné klasifikovat třídy s ohledem na známé vlastnosti ploch. Díky snaze překonat některé problémy, vedl výzkum k rozvoji neparametrických metod využívajících histogramů v šedé škále a hybridních metod, které spojují výhody parametrických i neparametrických přístupů. Použití klasifikátoru maximální pravděpodobnosti umožňuje mnoho softwarových balíčků (např. ERDAS IMAGINE, ENVI, IDRISI).



Obr. 4 Frekvenční funkce normálního rozdělení DN hodnot pro dva druhy povrchů „C“ a „B“ vypočtené z trénovacích ploch (Dobrovolný, 1998)

Obr. 4 zobrazuje frekvenční funkci pro dvě třídy pouze v jednom pásmu. Předpokladem je překryv frekvenční funkce obou tříd a hodnota radiometrické charakteristiky klasifikovaného pixelu z intervalu tohoto překrytu (např. 30). Pak je výpočtem možné pro daný obrazový prvek zjistit, ve které třídě má nejvyšší pravděpodobnost výskytu. Do této třídy bude pixel následně zařazen (Dobrovolný, 1998).



Obr. 5 Klasifikátor maximální pravděpodobnosti (Dobrovolný, 1998).

Klasifikátor maximální pravděpodobnosti je znázorněn na obr. 5. Spojením míst se stejnou pravděpodobností výskytu pixelu pro každý shluk se vytvoří izoliny, které často mívají tvar elipsy. Pixel (\square) bude podle tohoto klasifikátoru zařazen do třídy „C“.

Richards a Jia (2006) ve své práci uvedli následovné matematické vyjádření.

Nechť jsou spektrální třídy obrazu reprezentovány

$$w_i, i = 1, \dots, M,$$

kde M je celkový počet tříd. Snaha zjistit, do které třídy patří pixel na pozici x , je podmíněna pravděpodobností

$$p(w_i/x), i = 1, \dots, M.$$

Vektor x popisuje pixel jako bod v prostoru se souřadnicemi definovanými jasem. Pravděpodobnost $p(w_i/x)$ je takovou pravděpodobností, že správná třída pro pixel na pozici x je w_i . Klasifikace se provádí tak, že

$$x \in w_i, \text{ jestliže } p(w_i/x) > p(w_j/x) \text{ pro všechna } j \neq i.$$

Pixel na pozici x náleží do třídy w_i , jestliže je $p(w_i/x)$ největší. Toto intuitivní rozhodovací pravidlo je zvláštním případem obecnějšího pravidla, v němž může být rozhodnutí zkesleno podle různého stupně významu, jenž je přikládán nesprávné klasifikaci. Obecně se toto nazývá Bayesovská klasifikace.

I přes svou jednoduchost jsou $p(w_i/x)$ neznámé. Předpokládá se však, že odpovídající trénovací data jsou k dispozici pro každou kategorii povrchu. To může být použito pro odhad rozdělení pravděpodobnosti zastoupení druhu povrchu, které popisuje příležitost nalezení pixelu z třídy w_i na pozici x . Pro tento moment je distribuční funkce obecná a reprezentována symbolem $p(x/w_i)$. Existuje tolik $p(x/w_i)$, kolik existuje tříd druhů povrchu. Výpočet $p(w_i/x)$ je založen na Bayesovském teorému:

$$p(w_i/x) = p(x/w_i) p(w_i) / p(x)$$

Na levé straně se nachází pravděpodobnost, že pixel na pozici x bude klasifikací zařazen do třídy w_i . Pravá strana je odvozena z Bayesovského teorému, kde $p(x/w_i)$ je podmíněná pravděpodobnost výskytu vektoru x v dané třídě. Řízená klasifikace odvozuje tyto informace z trénovacích dat.

3.5.4 Klasifikátor Mahalanobisovy vzdálenosti

Některá omezení jednoduchého klasifikátoru minimální vzdálenosti mohou být překonány použitím Mahalanobisovi metriky. Především tak mohou být vyřešeny problémy způsobené vysokou korelací dat. Postup klasifikace s klasifikátorem Mahalanobisovy vzdálenosti je rychlý a zachovává stupeň citlivosti skrz kovarianční matici.

Hodnota r ve vzorci

$$r^2 = (x - m_x)' C_x^{-1} (x - m_x)$$

se nazývá Mahalanobisova vzdálenost a je vzdáleností mezi funkčním vektorem x a průměrovým vektorem m_x , kde C_x je kovarianční matice pro x (Duda, 1997). Klasifikátor Mahalanobisovy vzdálenosti zohledňuje chyby související s měřením (například šum) použitím funkce kovarianční matice C_x (Mery, Filbert, 2002).

3.6 Úprava a hodnocení klasifikace

Dobrovolný (1998) se ve své práci zabývá klasifikovanými obrazy, u nichž se velice často objevují osamocené pixely nebo skupiny pixelů, které byly zařazeny do jiné třídy než okolní obrazové prvky. To je způsobeno zatřídováním pixelu pouze na základě jeho hodnot, bez přihlédnutí na vlastnosti pixelů okolních. K úpravě obrazů slouží například nízkofrekvenční filtrace, která předpokládá, že osamocené pixely představují chyby. Nevýhodou těchto filtrů je, že hodnoty obrazových prvků berou jako kvantitativní, zatímco u klasifikovaných snímků jsou hodnoty kvalitativní (označují třídy). Pro úpravu těchto snímků se hodí tzv. majoritní filtry, například filtr modální. Ten vyhodnocuje centrální pixel ve filtrovacím okně podle označení kategorie, která je v okně nejčastěji zastoupena. Majoritní filtry také umožňují měnit váhu jednotlivých tříd nebo třídy z filtrace vyloučit. Filtrace dále dovolují stanovit minimální plochy, které budou ještě zahrnuty do výsledku. Menší plochy jsou pak odfiltrovány.

Před ukončením každé klasifikace je třeba zhodnotit její přesnost (Lillesand, Kiefer, 1994). Mezi nejpoužívanější metody hodnocení úspěšnosti klasifikace patří výpočet klasifikační chybové matice a výpočet tzv. Kappa koeficientu.

3.6.1 Klasifikační chybová matice

Klasifikační chybová matice porovnává pro všechny třídy výsledky klasifikace s referenčními daty. Počet jejích řádků a sloupců je stanoven počtem hodnocených tříd a je si roven, matice je tedy čtvercová. Chybovou matici, která porovnává klasifikovaný obraz (řádky matice) s původními daty (sloupce matice), zobrazuje tabulka 1.

Tab. 1 Chybová matice a procentuální hodnocení její přesnosti (Dobrovolný, 1998)

		Referenční data							
		třída	Voda	Les	Pole	TTP	Půda	SUMA	PU [%]
klasifikovaná data	Voda	480	0	5	0	0	485	99	
	Les	0	52	0	20	0	72	72	
	Pole	0	0	313	40	0	353	89	
	TTP	0	16	0	126	0	142	89	
	Půda	0	0	0	38	342	380	90	
	SUMA	480	68	318	224	342	1432		
	CHO [%]	0	23	1	44	0			
	CHZ [%]	1	29	13	7	11			
	PZ [%]	100	76	98	56	100			

- Průměrná přesnost: $(480 + 52 + 313 + 126 + 342) / 1432 = 92 \%$
- CHU - chyba z opomenutí
- CHZ - chyba z nesprávného zařazení
- PU - přesnost z hlediska uživatele
- PZ - přesnost z hlediska zpracovatele

Řádek označený SUMA představuje očekávanou přesnost, což je celkový správný počet pixelů každé třídy. Ve sloupci označeném SUMA je pak uveden počet pixelů zařazených klasifikací do dané třídy. Celkový počet obrazových prvků klasifikovaných a referenčních dat musí být stejný. Počty pixelů mimo hlavní diagonálu představují chyby v klasifikaci. Těmi jsou tzv. chyby z opomenutí, které leží ve sloupcích mimo hlavní diagonálu a vyjadřují se poměrem mezi součtem všech prvků ve sloupci mimo hlavní diagonálu a počtem všech pixelů dané třídy v podkladových datech. Chyby nacházející se v řádcích mimo hlavní diagonálu se nazývají chyby z nesprávného zařazení. Vypočtou se jako součty nesprávně zařazených pixelů dané třídy dělené počtem všech pixelů dané třídy v podkladových datech (Dobrovolný, 1998).

Podle Campbella (2002) je hodnocení přesnosti klasifikace nazíráno ze dvou úhlů. Prvním z nich je hodnocení přesnosti z hlediska uživatele výsledků klasifikace, která se pro každou třídu vyjádří jako poměr mezi správně klasifikovanými pixely a celkovým počtem pixelů, které byly do této třídy zařazené. Tímto způsobem se definuje pravděpodobnost, s jakou pixel zařazený do určité třídy tuto třídu opravdu představuje. Přesností z hlediska zpracovatele je uvažován poměr počtu správně klasifikovaných pixelů k celkovému počtu natrénovaných pixelů.

3.6.2 Kappa koeficient

Kappa koeficient je kvantitativní metodou pro určení přesnosti výsledků klasifikace. Jedná se o hodnoty, které porovnávají klasifikaci podle určitého rozhodovacího pravidla s klasifikací, kde jsou pixely zatřídovány čistě náhodným procesem. U této klasifikace se pak předpokládá, že určité procento takto zatřídovaných pixelů bude zařazeno správně.

Hodnotu Kappa koeficientu lze vyjádřit následujícím vzorcem:

$$\kappa = \frac{PP - PO}{1 - PO},$$

kde PP je přesnost pozorovaná a PO je přesnost dosažitelná čistě náhodným zařazením pixelů do jednotlivých tříd. Výslednou hodnotu koeficientu, například 0,9, pak lze interpretovat tak, že daná klasifikace se vyhnula 90 % chyb, které by vznikly při čistě náhodném zatřídování pixelů (Dobrovolný, 1998).

3.7 Identifikace zástavby

Metody DPZ jsou zajisté vhodným prostředkem pro identifikaci zástavby. Analýza leteckých a družicových snímků umožňuje získání velkého množství informací o území v různých měřítcích a z více časových úseků. Takto vzniklá data pak lze použít ke studiu různých charakteristik území pro další účely, kterými může být například tvorba tematických map, územní plánování, geologické a environmentální studie a mnoho dalších.

Dálkový průzkum Země rychle nabývá na významu a získává hlavní úlohu v množství urbanistických aplikací, jako je například sledování růstu měst v časovém horizontu a tvorba modelů pro předpověď kvality života a udržitelného rozvoje. Pro tyto účely je pak třeba identifikovat zástavbu. Zájem o dálkový průzkum měst je dále poháněn dostupností satelitních snímků v měřítku, které dříve poskytovaly pouze letecké fotografie. V dnešní době se využívají zejména data ze satelitních snímačů, a to především pro jejich pružnost, komplexní rozsah multispektrálních vlnových délek, zaznamenávání v multitemporálních intervalech a globální dostupnost s relativně nižšími náklady než je tomu u leteckých snímků. Další výhodou může být realističtější zobrazení území, než je tomu u klasických map. To pak umožňuje snadnější pochopení situace a vztahů v krajině (Otrusina, 2002). Nejčastěji využívanými družicovými snímky v České republice jsou snímky pořízené družicí Landsat. Snímky jsou opatřeny ve vyšší počtu

spektrálních pásem a studované území tak lze vizualizovat v jejich různých kombinacích. Každá kombinace pak díky určitým vlastnostem jednotlivých povrchů umožňuje jejich snadnější rozlišení v daném území. O leteckých snímcích a ortofotech se dnes v literatuře hovoří spíše jako o zdroji podpůrných dat, jako primární zdroj jsou však hodnoceny jako méně vhodné (Rashed, Jürgens, 2010).

Městské území se mnohdy definuje ve vztahu k obyvatelstvu, tato práce však nebere v úvahu žádné populační statistiky. Identifikace zástavby je prováděna pouze s pomocí dat pořízených metodami DPZ. Do kategorie Zastavěné území jsou řazeny obytné, komerční, průmyslové, rekreační a dopravní plochy včetně komunikací a jiné zastavěné plochy. Zástavba nebo zastavěná území pak nesmí být ztotožňovány s urbanizovaným územím, které zahrnuje kromě zastavěných ploch i plochy zastavitelné. Zbylé plochy, jako jsou lesy, zemědělské plochy, pastviny, zahrady, plochy ostatní zeleně, vodní toky a vodní plochy apod., jsou pak zahrnuty do kategorie Ostatní. Území se také často dělí podle land-use (využití země) nebo land-cover (pokryv země). Toto dělení je rozsáhlejší a obsahuje podrobnější dílčí kategorie.

Drtivá většina současných výzkumů klasifikace zastavěného území zahrnuje manipulaci s obrazovými prvky reprezentující buď jednu, nebo více tematických tříd a využívá jednotlivé pixely (spektrálně založená klasifikace) nebo jejich uskupení (prostorově založená klasifikace). Bez ohledu na stupeň propracovanosti (solistikovanosti) klasifikační metodiky, seskupování „podobných“ pixelů na základě spektrálních nebo prostorových pravidel bude vždy velmi subjektivní, silně závislé na trénovacích datech, výběru tříd a zkrácené místními specifickými podmínkami scény (Forster 1985; Webster 1995; Cowen a Jensen 1998). Všechny výsledky klasifikace budou vždy vzdáleny od reality, a to o to více, když budou reprezentovat urbánní plochy. Otázkou pak na prvním místě zůstává, proč by tedy měly být snímky analyzovány? Neklasifikované snímky mohou být objektivnější a obsahovat více informací, ale pouze klasifikované tematické interpretace jsou přijatelné pro většinu aplikací.

4 VLASTNÍ ŘEŠENÍ

Vlastní řešení práce spočívalo v několika krocích. Nejprve bylo třeba připravit data pro samotnou klasifikační etapu, které předcházelo vytvoření trénovacích ploch, pro které byly zjištěny jejich statistické a grafické charakteristiky. Následovalo testování klasifikátorů řízenou klasifikací, po které se přešlo k hodnocení její přesnosti. Následně byly na vybraném snímku vyzkoušeny postklasifikační úpravy v podobě majoritní filtrace a na úplný závěr byla provedena identifikace zástavby pro plošně rozsáhlé území.

4.1 Příprava dat


Vstupními daty byly tři druhy snímků pořízených metodami DPZ. Jako první byl postup vyzkoušen na barevných leteckých snímcích z roku 2007 poskytnutých firmou GEODIS Brno (obr. 6). Následovala úprava a klasifikace černobílých snímků z roku 1985, jež byly získány z Vojenského geografického a hydrometeorologického úřadu v Dobrušce (obr. 7). Nakonec byly zpracovány multispektrální družicové snímky z roku 2005, vzniklé v rámci projektu NASA Landsat Program a pořízené na webových stránkách GLCF (Global Land Cover Facility) Marylandské univerzity (obr. 8).



Obr. 6 Barevný letecký snímek části města Olomouc (GEODIS Brno, 2007).


Měřické letecké snímky v podobě černobílých záznamů obsahovaly jisté geometrické nepřesnosti. Prvním krokem v pracovním postupu byly tedy geometrické korekce v podobě procesů rektifikace a georeferencování. Rektifikací byl proveden proces transformace polohy všech pixelů do nového souřadnicového systému. Pro účely této práce nebylo nezbytně nutné dodávat datům informaci o absolutní poloze, neboť zde nebyl kladen důraz na prostorovou přesnost. Pokud by však měly být výsledky práce dále prezentovány formou tematických map, bylo by zapotřebí snímky georeferencovat. Mezi cíle této práce tvorba tematických map nepatřila, ale i přesto byly snímky za pomoci první a druhé polynomické rovnice transformovány do souřadnicového systému S-JTSK (souřadnicový systém jednotné trigonometrické sítě katastrální). Georeferencování probíhalo v softwaru ArcGIS 10 od firmy ESRI. Barevné letecké snímky byly poskytnuty již v souřadnicovém systému. Všechny klasifikované snímky jsou tedy geometricky přesné, mají jednotné měřítko a lze na nich měřit vzdálenosti i plochy.

Jedním z úkolů práce bylo také provedení identifikace zástavby ve větším plošném rozsahu. Pro snadnější a rychlejší práci byla datová sada obsahující větší množství barevných leteckých snímků spojena do jednoho obrazu. Tento krok byl proveden v programu ERDAS IMAGINE 9.1 za pomoci nástroje Mosaic Tool. Výsledkem pak byla bezešvá mozaika, která usnadnila a zrychlila průběh práce.



Obr. 7 Černobílý letecký snímek města Olomouc (VGHMÚř Dobruška, 1985).

Družicový snímek pořízený přístrojem ETM+ družice Landsat byl poskytnut po jednotlivých pásmech, z nichž bylo nutné vytvořit barevnou kompozici. Tato úloha byla provedena nástrojem Layer Stack. Výsledek umožnil zobrazení více snímků nad sebou a práci jako s jediným snímkem složeným z více vrstev. Snímek byl obdržen prostorově zorientovaný.




Obr. 8 Multispektrální družicový snímek z družice Landsat zachycující část České republiky a Polska (NASA Landsat Program, 2005).

4.2 Tvorba trénovacích ploch


Všechny následující kroky byly prováděny v programu ERDAS IMAGINE 9.1.

Trénovací etapa je procesem definování trénovacích ploch pro všechny kategorie, které mají být na snímcích identifikovány. Těmito hledanými kategoriemi jsou třídy Zastavěné území a Ostatní (viz podkapitola 3.7). Na vymezení trénovacích ploch závisela kvalita výstupů z klasifikace, proto bylo třeba dodržet zásady pro výběr trénovacích dat. Důraz se tedy kladl na výběr co nejvíce homogenních ploch s dostatečným počtem pixelů, vhodnou velikostí a polohou. Dále bylo důležité vyhnout se okrajovým pixelům (tzv. mixelům), které často nesou smíšenou spektrální informaci.



Obr. 9 Trénovací plochy pro třídu a – Zastavěné území, b – Ostatní.

Tvorba trénovacích ploch probíhala nad danými podkladovými daty za pomoci nástrojů AOI (tzn. Area of Interest). Trénovací plochy pro letecké snímky byly jednoduše vybírány polygonem, pro družicový snímek byl zvolen nástroj Region Grow, kterým byl určen tzv. seed pixel. Pro tento reprezentativní pixel byla v programu metodou „pokus-omyl“ stanovena pravidla (obr. 9), podle kterých byly k seed pixelu vybírány spektrálně podobné pixely.



Obr. 10 Nastavení pravidel nástroje Region Grow

4.3 Výpočet statistických charakteristik vstupních dat

Před samotnou klasifikací bylo třeba ze všech trénovacích ploch vytvořit pro obě dané třídy signatury. Pro každou signaturu byly vypočteny statistické údaje, které obsahují informace o maximálních, minimálních a průměrných hodnotách, o směrodatné odchylce a údaje o kovarianci. Tyto hodnoty jsou prezentovány v následujících tabulkách.

Tab. 2 Statistické hodnoty signatur pro barevný snímek

	pásmo	minimum	maximum	průměr	směrodatná odchylka
zastavěné území	1	11,0	255,0	140,5	38,9
	2	12,0	255,0	135,7	39,2
	3	5,0	255,0	129,9	41,0
ostatní	1	4,0	229,0	85,3	27,5
	2	16,0	240,0	96,8	26,1
	3	4,0	210,0	74,5	20,6

kovariance	pásmo	1	2	3
zastavěné území	1	1516,1	1417,5	1408,5
	2	1417,5	1536,7	1586,0
	3	1408,5	1586,0	1681,2
ostatní	1	754,2	682,4	543,2
	2	682,4	679,0	520,3
	3	543,2	520,3	422,8

Tab. 3 Statistické hodnoty signatur pro černobílý snímek

	pásmo	minimum	maximum	průměr	směrodatná odchylka
zastavěné území	1	44,0	215,0	150,4	27,7
	2	41,0	211,0	146,7	28,3
	3	37,0	199,0	139,4	26,9
ostatní	1	41,0	184,0	102,9	25,2
	2	40,0	180,0	98,8	25,2
	3	0,0	168,0	92,6	25,6

kovariance	pásmo	1	2	3
zastavěné území	1	764,9	769,0	729,3
	2	769,0	799,2	747,9
	3	729,3	747,9	726,2
ostatní	1	636,4	624,9	629,8
	2	624,9	636,7	629,1
	3	629,8	629,1	654,1

Tab. 4 Statistické hodnoty signatur pro multispektrální snímek


	pásma	minimum	maximum	průměr	směrodatná odchylka
zastavěné území	4	21,0	62,0	34,4	7,4
	5	26,0	122,0	49,8	13,0
	3	39,0	122,0	58,9	12,1
ostatní	4	12,0	123,0	62,4	28,9
	5	10,0	155,0	61,7	28,1
	3	24,0	115,0	44,7	16,7

kovariance	pásma	4	5	3
zastavěné území	4	54,3	89,8	76,7
	5	89,8	169,6	138,7
	3	76,7	138,7	138,7
ostatní	4	834,6	180,6	56,9
	5	180,6	791,9	375,4
	3	56,9	375,4	277,7


Vhodnost trénovacích ploch lze hodnotit i graficky. Jednou z těchto metod je například tvorba histogramů pro jednotlivé třídy, u nichž se sleduje druh rozdělení trénovacích dat. Pro všechny dané snímky obecně platí, že obě sledované kategorie zahrnují různé povrchy, což bylo vzhledem k povaze tříd očekáváno. Trénovací plochy jsou tedy tvořeny více podtřídami, jejichž spektrální chování může být velmi podobné, ale také naopak poněkud odlišné. Předpokládá se, že tento fakt sníží kvalitu klasifikace pravidlem maximální pravděpodobnosti, které vyžaduje normální rozdělení dat.

Dalším vizuálním způsobem hodnocení kvality trénovacích dat je graf korelačního pole DN hodnot vždy mezi dvěma pásmy multispektrálního prostoru. Obě osy grafu nabývají hodnot od nuly po 255. Podle míry korelace se mezi dvěma pásmy vytváří obrazce, které reprezentují hledané třídy a mají většinou tvar elipsy, která je definována průměrem a směrodatnou odchylkou. Elipsy jsou obvykle orientované ve směru úhlopříčky. Úzká elipsa značí vysokou korelaci. Pokud pixely v grafu vytváří plošně rozsáhlý obraz, je míra korelační závislosti nízká. Překryv elips může značit případnou těžší separaci tříd.


Celkově bylo vytvořeno devět korelačních grafů (pro každý druh obrazového záznamu tři). Pro letecké snímky byly sledovány kombinace pásem 1-2, 1-3 a 2-3. Pixely barevného snímku v grafech vytvořily plošně rozsáhlejší obrazec, což značí nižší korelační závislost, avšak elipsy vyznačující třídy Zastavěné území a Ostatní se v prvním a druhém grafu mírně překrývaly a jejich separace tak mohla být ztížena. U černobílého snímku nastal překryv elips sledovaných tříd mezi všemi pásmy. Tyto třídy tedy obsahovaly pixely s podobnými charakteristikami spektrálních příznaků a byly hůře oddělitelné. Multispektrální snímek se lišil kombinací pásem (4-5-3). Jejich korelace je nižší a hledané třídy se dobře odlišují. Mezi pásmy 4-5 nastal překryv elips, přesto však byla zvolená kombinace pásem vhodná pro následnou klasifikaci.



Obr. 11 Grafy korelačního pole barevného snímku s kombinací pásem 1-2, 1-3, 2-3 (zleva).



Obr. 12 Grafy korelačního pole černobílého snímku s kombinací pásem 1-2, 1-3, 2-3 (zleva).



Obr. 13 Grafy korelačního pole multispektrálního snímku s kombinací pásem 3-4, 3-5, 4-5 (zleva).

Posledním způsobem hodnocení míry separability mezi dvěma třídami byla kvantitativní metoda divergence, což je vážená vzdálenost mezi průměrovými vektory daných tříd (ERDAS Field Guide, 1995). Čím vyšší je hodnota divergence, tím jsou trénovací plochy statisticky vzdálenější a pravděpodobnost správné klasifikace se zvyšuje. V této práci byla použita tzv. transformovaná divergence, která nabývá hodnot od nuly do dvou. Dle ERDAS Field Guide (1995) se za dobrou míru separability tříd považují hodnoty transformované divergence z intervalu 1,9 až 2.

Pro barevný snímek byla vypočtena hodnota transformované divergence 1,959, což bylo považováno za velmi dobrý výsledek. Ještě lepší výsledek vykázala hodnota transformované divergence multispektrálního snímku, jež byla 2,000. Data v těchto případech tedy nebylo třeba dále opravovat. Naopak hodnota 0,704 pro černobílý snímek vypovídala o velké shodě charakteristik spektrálních příznaků porovnávaných tříd, což bylo i při vizuálním hodnocení zcela patrné. Z toho bylo usouzeno, že klasifikace černobílého snímku nebude příliš kvalitní a její přesnost bude velmi nízká.

Tab. 5 Transformovaná divergence mezi třídami pro barevný snímek

Transformovaná divergence	
průměrná separabilita	1,959
minimální separabilita	1,959

Tab. 6 Transformovaná divergence mezi třídami pro černobílý snímek

Transformovaná divergence	
průměrná separabilita	0,704
minimální separabilita	0,704

Tab. 7 Transformovaná divergence mezi třídami pro multispektrální snímek

Transformovaná divergence	
průměrná separabilita	2,000
minimální separabilita	2,000

4.4 Klasifikační etapa a hodnocení přesnosti klasifikace

Stejně jako předchozí úkony byl i proces řízené klasifikace prováděn v softwaru ERDAS IMAGINE 9.1. Testovanými pravidly byly klasifikátory minimální vzdálenosti, pravoúhelníků, maximální pravděpodobnosti a Mahalanobisovy vzdálenosti. Pro klasifikátor pravoúhelníků byly vyzkoušeny tři možnosti nastavení násobku směrodatné odchylky (dále jen SO) vymezující hranice pravoúhelníků. Pro každý druh snímku tak klasifikací vzniklo šest výstupů, které byly následně vyhodnoceny a porovnány.


V následujících podkapitolách jsou vždy znázorněna srovnání klasifikovaných snímků a jejich chybové matice. Třída Zastavěné území je na výsledných snímcích znázorněna červeně, třída Ostatní šedě a černou barvu mají nezatříděné obrazové prvky.

4.4.1 Barevný letecký snímek

Klasifikační etapa byla zahájena řízenou klasifikací barevného snímku. Nej kvalitnějších výsledků dosáhl klasifikátor maximální pravděpodobnosti. Průměrná přesnost klasifikace zde nabyla hodnoty 91,40 %. Také klasifikátor Mahalanobisovy vzdálenosti s přesností 91,00 % poskytl dobré výsledky. Naopak nejhoršími výstupy se staly snímky klasifikované algoritmem pravoúhelníků, kde hranice pravoúhelníků byly definovány násobkem směrodatné odchylky rovné 0,5. Pravoúhelníky se často vymezují pomocí maximálních a minimálních hodnot, které však pro tuto ani zbylé klasifikace nebyly použity, neboť následně zklasifikované snímky byly zcela nevyhovující.

Přesnost z hlediska uživatele výsledků klasifikace se pro dané třídy jednotlivých snímků pohybovala v rozmezí 71,89 % - 100 %. Pravděpodobnost, že obrazový prvek doopravdy představuje třídu, do které byl zařazen, byla tedy poměrně vysoká. V porovnání tříd byla přesnost z hlediska uživatele vyšší pro třídu Zastavěné území. Výjimkou byl jen snímek klasifikovaný algoritmem pravoúhelníků (pro směrodatnou odchylku 1,0), kde byla vyšší přesnost u třídy Ostatní. Jinak tomu bylo s přesností z hlediska zpracovatele, která je poměrem počtu správně klasifikovaných pixelů a počtu pixelů využitých pro testování sledované třídy. Hodnoty této přesnosti byly pro jednotlivé klasifikátory různorodější (rozmezí 24,46 % - 100 %). Souhrnně byla přesnost z hlediska zpracovatele nejvyšší u snímků klasifikátoru maximální pravděpodobnosti a Mahalanobisovy vzdálenosti. Nejnížší přesnost pak měl snímek zatříděný pravidlem pravoúhelníků s násobkem směrodatné odchylky 0,5. Tyto informace jsou tedy v souladu s výsledky průměrné přesnosti, kde byly jako nejvíce a nejméně kvalitní vyhodnoceny ty samé snímky.

Dalšími sledovanými charakteristikami byly chyby z opomenutí a chyby z nesprávného zařazení. Na základě těchto charakteristik lze také hodnotit přesnost klasifikovaných snímků, ale jedná se spíše o doplňující informace. Nejvyšší chybu z opomenutí obsahoval pro obě třídy snímek klasifikovaný pravidlem pravoúhelníků s násobkem směrodatné odchylky 0,5. Naopak nejnížší chyba z opomenutí se vyskytla u snímků klasifikátorů maximální pravděpodobnosti a Mahalanobisovy vzdálenosti. Největší chybu z nesprávného zařazení vykazovaly snímky klasifikátoru pravoúhelníků se směrodatnou odchylkou 0,5 a 2,0. Nejmenší chybu pak měly opět snímky zatříděné klasifikátorem maximální pravděpodobnosti a Mahalanobisovy vzdálenosti, což stejně jako průměrná přesnost a přesnost z hlediska zpracovatele podporuje fakt, že se jedná o nejkvalitnější klasifikované snímky.



Obr. 14 Barevné snímky klasifikované algoritmem A – minimální vzdálenosti, B – pravoúhelníků (SO 0,5), C – pravoúhelníků (SO 1,0), D – pravoúhelníků (SO 2,0), E – maximální pravděpodobnosti, F – Mahalanobisovy vzdálenosti.

Kvantitativní hodnocení přesnosti umožňuje také Kappa koeficient, který porovnává klasifikaci pomocí klasifikátoru s náhodným zařazením obrazových prvků do jednotlivých tříd. Hodnoty Kappa koeficientu v tomto případě odpovídaly trendu průměrné přesnosti. Snímek zpracovaný klasifikátorem maximální pravděpodobnosti dosáhl nejvyššího výsledku ze všech snímků, a to hodnoty 0,82, což znamenalo, že se klasifikace tímto algoritmem vyhnula 82 % chyb, které by vznikly čistě náhodným zatříděním pixelů.

Celkové hodnocení klasifikace barevného snímku vybranými klasifikátory lze rozdělit na dvě poloviny, kde zejména výsledky klasifikátorů maximální pravděpodobnosti a Mahalanobisovy vzdálenosti výborně splnily svůj úkol a pro klasifikaci barevných leteckých snímků se velmi dobře osvědčily. Tyto klasifikátory se tedy hodí pro identifikaci zástavby na barevných snímcích a klasifikované snímky lze uplatnit v dalším zpracování nebo studiu dané problematiky. Na druhé straně pak stojí výstupy klasifikátoru pravoúhelníků, který už tak dobré výsledky nepodal.

Tab. 8 Chybová matice barevného snímku klasifikovaného pravidlem minimální vzdálenosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	360	28	388	92,78
	ostatní	109	503	612	82,19
	SUMA	469	531	1000	
	CHO %	23,24	5,27		
	CHZ %	5,97	20,53		
	PZ %	76,76	94,73		

průměrná přesnost: 86,30 %

celkový Kappa koeficient: 0,72

Tab. 9 Chybová matice barevného snímku klasifikovaného pravidlem pravoúhelníků (SO 0,5)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	308	465	773	---
	zastavěné území	0	101	0	101	100,00
	ostatní	0	4	122	126	96,83
	SUMA	0	413	587	1000	
	CHO %	---	75,54	79,22		
	CHZ %	---	112,59	53,15		
	PZ %	---	24,46	20,78		

průměrná přesnost: 22,30 %

celkový Kappa koeficient: 0,12

Tab. 10 Chybová matice barevného snímku klasifikovaného pravidlem pravoúhelníků (SO 1,0)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	195	118	313	--
	zastavěné území	0	297	62	359	82,73
	ostatní	0	39	289	328	88,11
	SUMA	0	531	469	1000	
	CHO %	--	44,07	38,38		
	CHZ %	--	33,90	49,89		
	PZ %	--	55,93	61,62		

průměrná přesnost: 58,60 %

celkový Kappa koeficient: 0,37

Tab. 11 Chybová matice barevného snímku klasifikovaného pravidlem pravoúhelníků (SO 2,0)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	101	492	593	--
	zastavěné území	0	222	0	222	100,00
	ostatní	0	52	133	185	71,89
	SUMA	0	375	625	1000	
	CHO %	--	40,80	78,72		
	CHZ %	--	131,20	24,48		
	PZ %	--	59,20	21,28		

průměrná přesnost: 35,50 %

celkový Kappa koeficient: 0,20

Tab. 12 Chybová matice barev. snímku klasifikovaného pravidlem maximální pravděpodobnosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	344	4	348	98,85
	ostatní	82	570	652	87,42
	SUMA	426	574	1000	
	CHO %	19,25	0,70		
	CHZ %	0,94	14,29		
	PZ %	80,75	99,30		

průměrná přesnost: 91,40 %

celkový Kappa koeficient: 0,82

Tab. 13 Chybová matice barev. snímku klasifikovaného pravidlem Mahalanobisovy vzdálenosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	325	0	325	100,00
	ostatní	90	585	675	86,67
	SUMA	415	585	1000	
	CHO %	21,69	0,00		
	CHZ %	0,00	15,38		
	PZ %	78,31	100,00		

průměrná přesnost: 91,00 %

celkový Kappa koeficient: 0,81

4.4.2 Černobílý letecký snímek


Výsledky klasifikace černobílého snímku nedosahovaly kvality výstupů ze snímku barevného. Důvodem bylo zejména stejné nebo velice podobné spektrální chování odlišných objektů na snímku. Proto bylo množství obrazových prvků zatříděno nesprávně (například oblasti polí v levé horní části snímku identifikované jako zástavba). Podle průměrné přesnosti, která se pohybovala okolo 72 %, dávaly nejlepší výsledky klasifikátory minimální vzdálenosti, maximální pravděpodobnosti a Mahalanobisovy vzdálenosti. Tato přesnost se nedala považovat za dobrou a klasifikované snímky by nebylo vhodné využívat k dalšímu zpracování. Průměrná přesnost snímků klasifikovaných pravidlem pravoúhelníků pak byla ještě nižší a zcela nevhodná pro účely identifikace zástavby.

Přesnost z hlediska uživatele se u všech klasifikovaných snímků různila. Hodnoty představující pravděpodobnost náležitosti pixelu ke třídě, do které byl zatříděn, se pohybovala v rozmezí 57,14 – 90,03 %. Procentuálně byla ve všech případech vyšší přesnost třídy Ostatní. Přesnost z hlediska zpracovatele byla pro obě třídy obecně nejnižší u snímků klasifikovaných pravidlem pravoúhelníků. Zbylé tři snímky měly vzájemně velice podobné hodnoty pohybující se pro třídu Zastavěné území okolo 58 % a pro třídu Ostatní kolem 80 %.

Z vizuálního posouzení bylo na první pohled zřejmé, že nejméně kvalitní klasifikace proběhla klasifikátorem pravoúhelníků, kde nebyl zatříděn velký počet obrazových prvků. Navíc bylo množství pixelů špatně vyhodnoceno, takže hodnoty chyb z opomenutí i z nesprávného zařazení byly opravdu vysoké. Zbýlými klasifikátory byly zatříděny všechny pixely, ale rovněž byla spousta z nich zařazena špatně.

Hodnoty kappa koeficientu byly nízké. Při čistě náhodném zařazení pixelů by se klasifikace ve všech případech nevyhnula ani 40 % chyb, což podporuje předchozí tvrzení o kvalitě snímků.

Výsledky klasifikace černobílého snímku se dají shrnout následovně. Žádný z vybraných klasifikátorů nepodal kvalitní výstupy. U všech klasifikovaných snímků se objevil velký počet chyb a průměrná přesnost byla nevyhovující. Závěrem je tedy tvrzení, že černobílé letecké snímky nejsou vhodné ke klasifikaci, neboť ani jeden z klasifikátorů nepodal uspokojivé výsledky. Klasifikované snímky se nehodí pro další zpracování ani jiné odborné využití. Srovnáním algoritmů mezi sebou pak bylo zjištěno, že nejlepších výsledků dosáhly klasifikátory minimální vzdálenosti, maximální pravděpodobnosti a Mahalanobisovy vzdálenosti.



Obr. 15 Černobílé snímky klasifikované klasifikátorem A – minimální vzdálenosti, B – pravoúhelníků (SO 0,5), C – pravoúhelníků (SO 1,0), D – pravoúhelníků (SO 2,0), E – maximální pravděpodobnosti, F – Mahalanobisovy vzdálenosti.

Tab. 14 Chybová matice černobílého snímku klasifikovaného pravidlem minimální vzdálenosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	196	129	325	60,31
	ostatní	147	528	675	78,22
	SUMA	343	657	1000	
	CHO %	42,86	19,63		
	CHZ %	37,61	22,37		
	PZ %	57,14	80,37		

průměrná přesnost: 72,40 %

celkový Kappa koeficient: 0,38

Tab. 15 Chybová matice černobílého snímku klasifikovaného pravidlem pravoúhelníků (SO 0,5)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	160	392	552	---
	zastavěné území	0	116	45	161	72,05
	ostatní	0	63	224	287	78,05
	SUMA	0	339	661	1000	
	CHO %	---	65,78	66,11		
	CHZ %	---	128,91	33,74		
	PZ %	---	34,22	33,89		

průměrná přesnost: 34,00 %

celkový Kappa koeficient: 0,12

Tab. 16 Chybová matice černobílého snímku klasifikovaného pravidlem pravoúhelníků (SO 1,0)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	18	101	119	---
	zastavěné území	0	184	138	322	57,14
	ostatní	0	142	417	559	74,60
	SUMA	0	344	656	1000	
	CHO %	---	46,51	36,43		
	CHZ %	---	69,48	24,39		
	PZ %	---	53,49	63,57		

průměrná přesnost: 60,10 %

celkový Kappa koeficient: 0,24

Tab. 17 Chybová matice černobílého snímku klasifikovaného pravidlem pravoúhelníků (SO 2,0)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	225	307	532	---
	zastavěné území	0	87	60	147	59,18
	ostatní	0	32	289	321	90,03
	SUMA	0	344	656	1000	
	CHO %	---	74,71	55,95		
	CHZ %	---	106,69	39,18		
	PZ %	---	25,29	44,05		

průměrná přesnost: 37,60 %

celkový Kappa koeficient: 0,16

Tab. 18 Chybová matice čb. snímku klasifikovaného pravidlem maximální pravděpodobnosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	200	133	333	60,06
	ostatní	144	523	667	78,41
	SUMA	344	656	1000	
	CHO %	41,86	20,27		
	CHZ %	38,66	21,95		
	PZ %	58,14	79,73		

průměrná přesnost: 72,30 %

celkový Kappa koeficient: 0,37

Tab. 19 Chybová matice čb. snímku klasifikovaného pravidlem Mahalanobisovy vzdálenosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	197	137	334	58,98
	ostatní	147	519	666	77,93
	SUMA	344	656	1000	
	CHO %	42,73	20,88		
	CHZ %	39,83	22,41		
	PZ %	57,27	79,12		


průměrná přesnost: 71,60 %

celkový Kappa koeficient: 0,37

4.4.3 Multispektrální družicový snímek

Posledním obrazem, na kterém proběhlo testování klasifikátorů, byl multispektrální družicový snímek zabírající plošně rozsáhlé území s nepatrnými zastavěnými plochami. Klasifikace byla prováděna pouze na jeho menším výřezu, aby bylo usnadněno vizuální i statistické posouzení. Průměrná přesnost se u všech snímků lišila. Nejlepšího výsledku bezesporu dosáhl klasifikátor maximální pravděpodobnosti s průměrnou přesností 98,9 %. Naopak nejhorší snímek s přesností 6,90 % vydal klasifikátor pravoúhelníků s násobkem směrodatné odchylky 0,5.

Mezi hodnotami přesností z hlediska uživatele se pro klasifikované snímky objevovaly značné rozdíly. Pro třídu Ostatní byla přesnost ve všech případech vysoká, jinak tomu bylo u třídy Zastavěné území. S výjimkami klasifikátorů maximální pravděpodobnosti a Mahalanobisovy vzdálenosti zde byla přesnost velice nízká, pro klasifikátory pravoúhelníků byla hodnota dokonce nulová. Přesnost z hlediska zpracovatele na tom byla podobně. Vyšší hodnoty se vyskytovaly u třídy Ostatní, ale pro klasifikátor pravoúhelníků byly i tak velmi špatné. Nejlepších výsledků dosáhlo pravidlo maximální pravděpodobnosti (72,50 %, 100 %), které tak daleko předstihlo ostatní klasifikační algoritmy.



Obr. 16 Multispektrální snímky klasifikované klasifikátorem A – minimální vzdálenosti, B – pravouhelníků (SO 0,5), C – pravouhelníků (SO 1,0), D – pravouhelníků (SO 2,0), E – maximální pravděpodobnosti, F – Mahalanobisovy vzdálenosti.

Už na pohled bylo zřejmé, že výsledky klasifikátoru pravoúhelníků obsahovaly obrovské množství chyb. U třídy Zastavěné území se objevovaly ve velkém počtu chyby z opomenutí. To znamenalo, že velké množství pixelů, které byly ve skutečnosti zastavěným územím, bylo opomenuto. Kromě snímků zpracovaných klasifikátory maximální pravděpodobnosti a Mahalanobisovy vzdálenosti, měly výstupy značnou chybu i ve třídě Ostatní. U chyb z nesprávného zařazení byl trend podobný. Velké chyby se kromě klasifikátorů maximální pravděpodobnosti a Mahalanobisovy vzdálenosti vyskytly u třídy Zastavěné území. Pro třídu Ostatní pak byly chyby nízké. Podle množství chyb tedy bylo možné jako nejlepší klasifikátory vyhodnotit pravidla maximální pravděpodobnosti a minimální vzdálenosti.

Hodnoty Kappa koeficientu pro multispektrální snímek byly velmi nízké. Nejhorší výsledky představovaly klasifikátory minimální vzdálenosti a pravoúhelníků. Klasifikace s jejich pomocí by se nevyhnula žádnému nebo jen pouhému 1 % chyb. Největšímu počtu chyb (85 %) by se při čistě náhodném zařazení vyhnul klasifikátor maximální pravděpodobnosti.

Shrnutím předchozích výsledků bylo zjištěno, že nejkvalitnější klasifikaci multispektrálního snímku provedl algoritmus maximální pravděpodobnosti. Jeho výstupy je možné použít k dalšímu studiu. Naopak klasifikátory pravoúhelníků ani v tomto případě nedosáhly dobrých výsledků a klasifikované snímky jsou k další práci nevhodné.

Tab. 20 Chybová matice multispek. snímku klasifikovaného pravidlem minimální vzdálenosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	10	199	209	4,78
	ostatní	40	751	791	94,94
	SUMA	50	950	1000	
	CHO %	80,00	20,95		
	CHZ %	398,00	4,21		
	PZ %	20,00	79,05		

průměrná přesnost: 76,00 %

celkový Kappa koeficient: 0,00

Tab. 21 Chybová matice multispek. snímku klasifikovaného pravidlem pravoúhelníků (SO 0,5)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	71	860	931	--
	zastavěné území	0	0	0	0	0,00
	ostatní	0	0	69	69	100,00
	SUMA	0	71	929	1000	
	CHO %	--	100,00	92,57		
	CHZ %	--	1211,27	7,64		
	PZ %	--	0,00	7,43		

průměrná přesnost: 6,90 %

celkový Kappa koeficient: 0,01

Tab. 22 Chybová matice multispek. snímku klasifikovaného pravidlem pravoúhelníků (SO 1,0)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	48	711	759	--
	zastavěné území	0	0	0	0	0,00
	ostatní	0	11	230	241	95,44
	SUMA	0	59	941	1000	
	CHO %	--	100,00	75,56		
	CHZ %	--	1205,08	6,27		
	PZ %	--	0,00	24,44		

průměrná přesnost: 23,00 %

celkový Kappa koeficient: 0,01

Tab. 23 Chybová matice multispek. snímku klasifikovaného pravidlem pravoúhelníků (SO 2,0)

	referenční data					
	třída	nezařazeno	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	nezařazeno	0	18	289	307	--
	zastavěné území	0	0	0	0	0,00
	ostatní	0	31	662	693	95,53
	SUMA	0	49	951	1000	
	CHO %	--	100,00	30,39		
	CHZ %	--	589,80	5,15		
	PZ %	--	0,00	69,61		

průměrná přesnost: 66,20 %

celkový Kappa koeficient: 0,01

Tab. 24 Chybová matice multispek. snímku klasifikovaného pravidlem max. pravděpodobnosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	29	0	29	100,00
	ostatní	11	960	971	98,87
	SUMA	40	960	1000	
	CHO %	27,50	0,00		
	CHZ %	0,00	1,15		
	PZ %	72,50	100,00		

průměrná přesnost: 98,90 %

celkový Kappa koeficient: 0,85

Tab. 25 Chybová matice multispek. snímku klasifikovaného pravidlem Mahalanobis. vzdálenosti

	referenční data				
	třída	zastavěné území	ostatní	SUMA	PU %
klasifikovaná data	zastavěné území	30	10	40	75,00
	ostatní	71	889	960	92,60
	SUMA	101	899	1000	
	CHO %	70,30	1,11		
	CHZ %	9,90	7,90		
	PZ %	29,70	98,89		

průměrná přesnost: 91,90 %


celkový Kappa koeficient: 0,39

4.5 Úprava výsledků klasifikace

V rámci pracovního postupu padlo rozhodnutí vyzkoušet na klasifikovaném snímku postklasifikační úpravy. Zvolena byla metoda majoritní filtrace, která vnímá obrazové prvky kvalitativně, což je v tomto případě podmínkou. Úpravy byly provedeny na snímku vytvořeném klasifikátorem maximální pravděpodobnosti, jehož základem byl barevný letecký snímek. V menu filtrace se nabízely tři možnosti nastavení velikosti filtrovacího okna, a to 3x3, 5x5 a 7x7. Všechny možnosti byly vyzkoušeny. Výsledky byly vizuálně porovnány. Velikost filtrovacího okna 7x7 byla vyhodnocena jako nejvhodnější, neboť klasifikovaný snímek nejlépe zbavila osamocených a pravděpodobně špatně zařazených pixelů a nenásilně celý snímek shladila.



Obr. 17 Klasifikovaný snímek upravený majoritním filtrem s velikostí filtrovacího okna 3x3.



Obr. 18 Klasifikovaný snímek upravený majoritním filtrem s velikostí filtrovacího okna 5x5.




Obr. 19 Klasifikovaný snímek upravený majoritním filtrem s velikostí filtrovacího okna 7x7.

4.6 Klasifikace plošně rozsáhlého území

Posledním cílem práce bylo provedení klasifikace pro plošně rozsáhlé území. K tomuto účelu byl vybrán klasifikátor maximální pravděpodobnosti, který během testování podával nejlepší výsledky. Řízená klasifikace pracovala s mozaikou vytvořenou z datové sady barevných leteckých snímků zachycujících město Olomouc. Výstup byl následně pro ještě lepší výsledek shlazen majoritním filtrem s filtrovacím oknem 7x7.



Obr. 20a Mozaika města Olomouc klasifikovaná algoritmem maximální pravděpodobnosti a upravená majoritním filtrem (levá část).



Obr. 20b Mozaika města Olomouc klasifikovaná algoritmem maximální pravděpodobnosti a upravená majoritním filtrem (pravá část).

5 DISKUZE

Pro splnění cílů této bakalářské práce bylo nutné vybrat vhodné per-pixel klasifikátory a software, který by umožnil digitální zpracování obrazu a obsahoval nástroje pro řízenou klasifikaci. Vzhledem k předchozím zkušenostem byl zvolen software ERDAS IMAGINE, ke kterému byl zajištěn přístup na katedře geoinformatiky na univerzitě Palackého v Olomouci. Navíc jej bylo možné získat i jako 30-ti denní demoverzi na webových stránkách společnosti ERDAS. Na základě nabídky softwaru ERDAS IMAGINE a nastudování příslušné literatury byly vybrány klasifikátory minimální vzdálenosti, pravoúhelníků, maximální pravděpodobnosti a Mahalanobisovy vzdálenosti.

Ke klasifikaci byly nejprve určeny černobílé letecké snímky poskytnuté VGHMÚř. Po prvním testování klasifikátorů však bylo zjištěno, že klasifikace černobílých leteckých snímků nepodávala příliš kvalitní výsledky. Příčinou bylo stejné nebo podobné spektrální chování u různých druhů povrchu, které se vyskytovaly na snímku. Porovnání klasifikátorů pouze na základě těchto výstupů by nebylo dostatečné, a proto bylo pro srovnání kvality klasifikace rozhodnuto provést testování rovněž na barevných leteckých snímcích a multispektrálních družicových snímcích.

Před samotným procesem řízené klasifikace bylo třeba vytvořit trénovací plochy. Jejich vymezování se řídí mnohými pravidly. Nikde však není pro klasifikovaný snímek stanoven počet obrazových prvků reprezentujících různé druhy povrchu na snímku. Pokud by trénovací plochy zabíraly velké procento plochy obrazu, jednalo by se spíše o manuální klasifikaci a automatický proces řízené klasifikace by víceméně ztratil smysl. Proto byl pro počet pixelů v trénovacích plochách stanoven limit cca 5 % z celkového počtu obrazových prvků klasifikovaného snímku.

Další rozhodnutí vyžadovalo posouzení přesnosti klasifikovaných snímků, které se provádí porovnáním referenčních a klasifikovaných dat a jejich následným statistickým vyhodnocením. Nejprve je třeba vygenerovat náhodné body označující pixely, které se mají hodnotit. Jejich počet stanovuje uživatel. V této práci bylo generováno tisíc bodů, což je považováno za dostatečný počet pro účely hodnocení přesnosti. Vygenerované body byly následně exportovány a použity vždy pro všechny klasifikované snímky vzešlé z jednoho druhu snímku. Díky tomuto šetření vznikly výsledky prezentované formou chybové matice. Některé hodnoty průměrných přesností se zdají být vyšší, než je tomu ve skutečnosti. Důvodem může být fakt, že se posuzuje pouze reprezentativní vzorek dat a zbylé množství špatně zatříděných prvků není bráno v úvahu. Pro srovnání klasifikátorů však postačí vnímat tyto hodnoty relativně.

6 ZÁVĚR

Cílem bakalářské práce bylo porovnání vybraných per-pixel klasifikátorů pro identifikaci zástavby. Zvoleny byly klasifikátor minimální vzdálenosti, pravoúhelníků, maximální pravděpodobnosti a Mahalanobisovy vzdálenosti. Metodami pro jejich testování byly proces řízené klasifikace a následné hodnocení přesnosti. Pracovním prostředím byl po celou dobu software ERDAS IMAGINE 9.1. Klasifikace probíhala za pomoci barevného a černobílého leteckého snímků a multispektrálního družicového snímků. Obrazové prvky byly rozřídovány do dvou kategorií, kterými byly třídy Zastavěné území a Ostatní. Dalším úkolem bylo nastudování související problematiky a podrobný popis daných klasifikátorů. Získané informace byly zařazeny do kapitoly s názvem Dálkový průzkum Země a digitální zpracování obrazu, která je úvodem a seznámením se současným stavem oboru, s nímž souvisí tato práce.

Samotný proces klasifikace byl proveden pro čtyři druhy klasifikátorů, přičemž pro algoritmus pravoúhelníků byla vyzkoušena tři různá nastavení hranic pravoúhelníků podle násobků směrodatné odchylky. Z klasifikační etapy pro každý druh snímku tedy vzešlo šest výstupů.

Nejlepších výsledků klasifikace barevného snímku s průměrnou přesností 91,4 % a 91,0 % dosáhly klasifikátory maximální pravděpodobnosti a Mahalanobisovy vzdálenosti. Tyto klasifikátory se hodí pro identifikaci zástavby na barevných snímcích a klasifikované výstupy lze uplatnit v nejrůznějších urbanistických studiích. Přesnost výstupů klasifikátoru pravoúhelníků byla naopak nedostatečná. Proto je použití těchto klasifikátorů a klasifikovaných snímků pro další práci nevhodné.

Na základě klasifikace černobílého leteckého snímku bylo zjištěno, že žádný z klasifikátorů nepodal kvalitní výsledky. Velké množství obrazových prvků bylo špatně zařazeno a nesprávně tak identifikovalo druhy povrchu zastoupené na snímku. Zejména velké oblasti polí byly špatně vyhodnoceny jako zastavěné území, což by bylo pro další pracovní využití nepřijatelné. Díky použití těchto snímků bylo zjištěno, že výsledky klasifikace jsou silně závislé na kvalitě vstupních dat. V tomto případě byla kvalita dat nedostačující a pro identifikaci zástavby na černobílých leteckých snímcích by měla být zvolena jiná metoda než řízená klasifikace.

Poslední klasifikace byla provedena pro multispektrální družicový snímek. Zde byly zaznamenány největší rozdíly mezi klasifikátory. Nejlepší výstup předvedl algoritmus maximální pravděpodobnosti s průměrnou přesností 98,9 %. Dobrého výsledku dosáhl také klasifikátor Mahalanobisovy vzdálenosti. Tato pravidla tedy mohou být bez problému využívána pro další pracovní účely. Výstupy zbylých klasifikátorů jsou pro identifikaci zástavby nevhodné.

Ze všech klasifikovaných snímků byl vybrán ten nejlepší, aby na něm byly provedeny postklasifikační úpravy použitím majoritního filtru. Zvolen byl obraz klasifikovaný algoritmem maximální pravděpodobnosti s podkladem barevného leteckého snímku.

Filtrace byly vyzkoušeny pro trojí nastavení velikosti filtrovacího okna, přičemž nejlepších výsledků dosahovalo okno 7x7. U filtrovaného snímku si lze všimnout většího shlazení a odfiltrování velkého počtu osamocených a s největší pravděpodobností špatně zařazených pixelů.

Posledním zadaným úkolem bylo provedení identifikace zástavby pro konkrétní datovou sadu ve větším plošném rozsahu. Vybranou datovou sadou byly barevné letecké snímky zachycující město Olomouc ve formě bezešvé mozaiky. Klasifikace byla prováděna s pomocí klasifikátoru maximální pravděpodobnosti, který byl v předchozích testech vyhodnocen jako nejlepší. Výstup klasifikace byl rovněž upraven majoritním filtrem s velikostí filtrovacího okna 7x7. Klasifikovaná mozaika dosáhla kvalitního výsledku, který potvrzuje možnost dalšího využití v dotčených oborech.

Jako celkově nejlepší klasifikátor byl tedy vyhodnocen algoritmus maximální pravděpodobnosti, který zejména v procesu klasifikace barevného leteckého a multispektrálního družicového snímku podal velmi dobré výsledky. Špatně si nevedl ani klasifikátor Mahalanobisovy vzdálenosti. Obě zmíněná klasifikační pravidla dobře identifikovala zástavbu a lze je tak využít pro další studijní či pracovní účely, kterými může být například tvorba tematických map nebo územních plánů. Spektrum využití je široké, ale jak dokazují výsledky klasifikace černobílého leteckého snímku, vždy záleží na kvalitě a vlastnostech vstupních dat.

Tab. 26 Pořadí klasifikátorů pro barevný letecký snímek, černobílý letecký snímek a multispektrální družicový snímek podle průměrné přesnosti

pořadí	barevný letecký snímek	černobílý letecký snímek	multispektrální družicový snímek
	klasifikátor		
1.	maximální pravděpodobnosti	minimální vzdálenosti	maximální pravděpodobnosti
2.	Mahalanobisovy vzdálenosti	maximální pravděpodobnosti	Mahalanobisovy vzdálenosti
3.	minimální vzdálenosti	Mahalanobisovy vzdálenosti	minimální vzdálenosti
4.	pravouhelníků (SO 1,0)	pravouhelníků (SO 1,0)	pravouhelníků (SO 2,0)
5.	pravouhelníků (SO 2,0)	pravouhelníků (SO 2,0)	pravouhelníků (SO 1,0)
6.	pravouhelníků (SO 0,5)	pravouhelníků (SO 0,5)	pravouhelníků (SO 0,5)

POUŽITÁ LITERATURA

ARONOFF, Stan. Remote Sensing for GIS Managers. 1st edition. Redlands (California) : ESRI Press, 2005. 352 s. ISBN 1-58948-081-3.

BLASCHKE, Thomas; STROBL, Josef. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. GIS-Zeitschrift für Geoinformationssysteme. 2001, v. 14, s. 12-17.

CAMPBELL, James B. Introduction to remote sensing. 3rd edition. New York : The Guilford Press, 2002. 625 s. ISBN 1-57230-640-8.

COWEN, Dave C.; JENSEN, John R. People and pixels : linking remote sensing and social science. Washington, D.C. : National Academy Press, 1998. Extraction and modeling of urban attributes using remote sensing technology, s. 164-188.

DOBROVOLNÝ, Petr. Dálkový průzkum Země, Digitální zpracování obrazu. Vyd. 1. Brno : Masarykova univerzita, 1998. 210 s. ISBN 80-210-1812-7.

DUDA, Richard. Computer Science Department at Princeton University [online]. 1997 [cit. 2011-04-25]. Mahalanobis Classifiers. Dostupné z WWW: <http://www.cs.princeton.edu/courses/archive/fall08/cos436/Duda/PR_Mahal/PR_Mahal.htm>.

ERDAS Field Guide. Atlanta (Georgia) : ERDAS, Inc., 1995. 628 s.

FORSTER, B. C. An examination of some problems and solutions in monitoring urban areas from satellite platforms. International Journal of Remote Sensing. 1985, v. 6, i. 1, s. 139-151.

LILLESAND, Thomas M.; KIEFER, Ralph W. Remote sensing and image interpretation. 3rd edition. New York : Wiley, 1994. 750 s. ISBN 0471577839.

MERY, Domingo; FILBERT, Dieter. Classification of potential defects in automated inspection of aluminium castings using statistical pattern recognition. In 8th ECNDT Proceedings [online]. Barcelona : Spanish Society for NDT, 2002 [cit. 2011-04-25]. Dostupné z WWW: <<http://www.ndt.net/article/ecndt02/232/232.htm>>.

OTRUSINA, Jiří. Družicová mapa CHKO Litovelské Pomoraví. Brno, 2005. 41 s. Bakalářská práce. Masarykova univerzita, Přírodovědecká fakulta, Geografický ústav.

RASHED, Tarek; JÜRGENS, Carsten. Remote Sensing of Urban and Suburban Areas : Remote Sensing and Digital Image Processing. 1st edition. Dordrecht; Heidelberg; London; New York : Springer, 2010. 352 s. ISBN 978-1-4020-4371-0.

RICHARDS, John A.; JIA, Xiuping. Remote Sensing Digital Image Analysis : An Introduction. 4th edition. Verlag; Berlin; Heidelberg : Springer, 2006. 439 s. ISBN 978-3-540-25128-6.

WACKER, A. G.; LANDGREBE, D. A. Minimum Distance Classification in Remote Sensin. In LARS Technical Report[online]. Lafayette (Indiana) : Purdue University, 1972 [cit. 2011-04-25]. Dostupné z WWW: <[http://docs.lib.purdue.edu/cgi/viewcontent.cgi?article=1024&context=larstech&sei-redir=1#search="The+Minimum+Distance+Approach+to+Classification+%C3%A2%C2%80%C2%93+Wacker,+Landgrebe++1972">](http://docs.lib.purdue.edu/cgi/viewcontent.cgi?article=1024&context=larstech&sei-redir=1#search=)>.

WEBSTER, C. J. Urban morphological fingerprints. Environment and Planning B: Planning and Design. 1995, v. 23, s. 279-297.

ZDROJE DAT

GEODIS BRNO, spol. s r. o., Brno, 2007, barevné letecké snímky města Olomouc a okolí.

NASA Landsat Program, 2005, Landsat ETM+ scene L71190025_02520050908, Ortho, GLS2005, USGS, Česká republika, Polsko. Dostupné z WWW: <<http://glcfapp.glc.f.umd.edu:8080/esdi/index.jsp>>.

VGHMÚř, Dobruška, 1985, černobílé letecké snímky města Olomouc a okolí.

SUMMARY

These days methods of remote sensing and digital image processing offer extensive possibilities of research of socioeconomical and physical geography through the analysis of aerial and satellite images. One of the areas where the data are acquired by remote sensing methods is an urbanism dealing with residential units. For its needs it is possible to extract the large amounts of information from the digital images, which include data on built-up areas.

Required information can be obtained from aerial and satellite images in various ways. One of them is an image classification, which is the process of assortment of all picture elements into the classes which represent the specific types of surfaces. Classification is based on certain decision rules. These rules are also the per-pixel classifiers which evaluate the individual pixels, regardless of the surrounding pixels. For a proper selection of classifier it is necessary to get acquainted with them and to test them. The quality of the outputs in the form of the classified images can be assessed by calculating statistical accuracy and number of produced errors.

The target of this bachelor thesis was to compare the selected per-pixel classifiers which are used to identify built-up areas in digital images. In the scope of work process a detailed description of each classifier was created and they were subsequently tested. The tested algorithms were a minimum distance classifier, a parallelepiped classifier, a maximum likelihood classifier and a Mahalanobis distance classifier. Several options for classifier with the variable were tested (in this case, the parallelepiped classifier). A statistical evaluation of the accuracy of classification was performed by creating an error matrix and calculating Kappa coefficient. The error matrix contains percentages of the statistical precision and number of errors. According to these data a verbal assessment of the classifiers was made and the best classifier for a particular dataset was chosen. The classified images were adjusted by the majority filter. Another task was to implement the most appropriate classifier for a selected dataset to identify built-up area in the greater areal extent. The results of the work may be used for planning studies, e.g. monitoring changes in extent of built up area.

The supervised classification was performed in software ERDAS IMAGINE 9.1 using colour and black and white aerial photographs and multispectral satellite images. Pixels were grouped into classes named The built-up area and The others. Four types of classifiers were tested and three different settings of rectangle boundaries according to the standard deviation for parallelepiped classifier were tried. Six outputs for each type of image were obtained.

As the overall best classifier was evaluated a maximum likelihood algorithm which gave very good results, especially in classification of colour aerial photograph and multispectral satellite image. Mahalanobis distance classifier was also successful. Built-up areas were well identified by both of these decision rules. But the results may be

different for each dataset. As demonstrated by the classified black and white images, it always depends on the quality and characteristics of the input data.

Majority filtering was applied to the best classified image. Filtration was tested for three settings of filtering window sizes (3x3, 5x5, 7x7), window 7x7 yielded the most quality result. The filtered image is noticeably smoother and without a large number of isolated and most likely incorrectly classified pixels.

The last task was to identify built-up areas for a particular dataset in a greater areal extent. The selected dataset was colour aerial photographs capturing the city of Olomouc. Classification was performed using maximum likelihood classifier, which was evaluated as the best in previous tests. The output was also adjusted by majority filter with filtering window size 7x7.

SEZNAM PŘÍLOH

Volná příloha

Příloha 1 DVD – adresáře:

Metadata

Text_Prace

Vstupni_Data

Vystupni_Data

WEB