

**Univerzita Pardubice  
Fakulta ekonomicko-správní  
Ústav systémového inženýrství a informatiky**

**Využití automatické klasifikace obrazu pro analýzu vývoje  
krajiny v obci Staré Jesenčany**

**Eva Trojovská**

**Diplomová práce  
2012**

## ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Mgr. Eva Trojovská**  
Osobní číslo: **E100446**  
Studijní program: **N6209 Systémové inženýrství a informatika**  
Studijní obor: **Informatika ve veřejné správě**  
Název tématu: **Využití automatické klasifikace obrazu pro analýzu vývoje krajiny v obci Staré Jesenčany**  
Zadávací katedra: **Ústav systémového inženýrství a informatiky**

### Z á s a d y p r o v y p r a c o v á n í :

Zhodnocení stávajících způsobů automatické klasifikace obrazu.  
Charakteristiky zájmového území.  
Příprava distančních dat pro zpracování.  
Klasifikace obrazu a kvantifikace ploch pro jednotlivé časové horizonty.  
Porovnání změn krajiny zájmového území.

Rozsah grafických prací:

Rozsah pracovní zprávy:

**55 stran**

Forma zpracování diplomové práce:

**tištěná/elektronická**

Seznam odborné literatury:

**DOBROVOLNÝ, P. Dálkový průzkum Země. Brno, 1998.**

**LILLESAND, T. M., KIEFER, R. W. Remote Sensing and Image Interpretation. New York, 1994.**

**SCHOWENGERDT, R. A. Remote Sensing: Models and Methods for Image Processing. Burlington, 2007.**

**TUČEK, J. Geografické informační systémy. Teorie a praxe. Praha, 1998.**



Vedoucí diplomové práce:

**Mgr. Pavel Sedlák, Ph.D.**

Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce:

**3. října 2011**

Termín odevzdání diplomové práce:

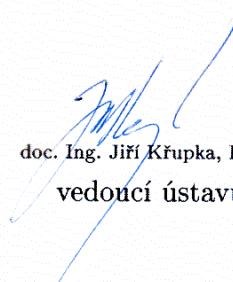
**30. dubna 2012**



doc. Ing. Renáta Myšková, Ph.D.

děkanka

L.S.



doc. Ing. Jiří Křupka, Ph.D.

vedoucí ústavu

V Pardubicích dne 3. října 2011

## **PROHLÁŠENÍ**

Prohlašuji, že jsem tuto práci vypracovala samostatně. Veškeré literární prameny a informace, které jsem v práci využila, jsou uvedeny v seznamu použité literatury.

Byla jsem seznámena s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako Školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Souhlasím s prezenčním zpřístupněním své práce v Univerzitní knihovně Univerzity Pardubice.

V Pardubicích dne 10. 8. 2012

Mgr. Eva Trojovská

## **PODĚKOVÁNÍ**

Tímto bych velmi ráda poděkovala svému vedoucímu práce Mgr. Pavlu Sedlákovi, Ph.D. především za podporu, za jeho odbornou pomoc, cenné rady a poskytnuté materiály, které mi pomohly při zpracování této diplomové práce.

## **ANOTACE**

*Tato práce je zaměřena na metody digitálního zpracování obrazu z dálkového průzkumu Země, a to konkrétně na metody automatické klasifikace obrazu. Toto téma je nejprve přiblíženo v teoretické rovině a poté je na něj navázána problematika sledování změn v krajině. Významným dílem této práce je aplikace automatické klasifikace na letecké i družicové snímky a analýza změn krajiny v obci Staré Jesenčany pomocí programu ArcGIS Desktop.*

## **KLÍČOVÁ SLOVA**

*Dálkový průzkum Země, digitální zpracování obrazu, automatická klasifikace, krajina, ArcGIS Desktop*

## **TITLE**

Use of Automatic Image Classification for Analysis of Landscape Evolution in the Village of Staré Jesenčany

## **ANNOTATION**

*This work focuses on methods of digital image processing of remote sensing and namely on the methods of automatic image classification. This topic is at first indicated in the theory level and then tied to the problems of monitoring changes in the landscape follow. An important part of this work is the application of automated classification for air and satellite images and analysis of landscape changes in the village of Old Jesenčany using ArcGIS Desktop.*

## **KEYWORDS**

*Remote sensing, image processing, automatic classification, landscape, ArcGIS Desktop*

# OBSAH

ÚVOD.....	10
<b>1 ZHODNOCENÍ STÁVAJÍCÍCH ZPŮSOBŮ AUTOMATICKÉ KLASIFIKACE OBRAZU .....</b>	<b>11</b>
1.1 ÚLOHA KLASIFIKACE OBRAZU V DIGITÁLNÍM ZPRACOVÁNÍ MATERIÁLŮ DPZ.....	11
1.2 PODSTATA KLASIFIKAČNÍCH METOD.....	14
1.3 ŘÍZENÁ KLASIFIKACE.....	15
1.3.1 <i>Trénovací etapa</i> .....	15
1.3.2 <i>Výpočet statistických charakteristik jednotlivých tříd</i> .....	16
1.3.3 <i>Klasifikační etapa</i> .....	17
1.3.4 <i>Nerízená klasifikace</i> .....	19
1.4 NOVĚJŠÍ PŘÍSTUPY KE KLASIFIKACI.....	20
1.4.1 <i>Neuronové sítě a klasifikace obrazu z DPZ</i> .....	20
1.4.2 <i>Princip neurčitosti</i> .....	21
1.4.3 <i>Objektově orientovaný přístup ke klasifikaci</i> .....	22
1.4.4 <i>Rozhodovací stromy</i> .....	22
1.5 ZPRACOVÁNÍ VÝSLEDKŮ AUTOMATICKÉ KLASIFIKACE.....	23
1.5.1 <i>Postklasifikační shlázení výsledků</i> .....	23
1.5.2 <i>Hodnocení přesnosti klasifikace</i> .....	24
1.5.3 <i>Prezentace výsledků klasifikace</i> .....	24
1.6 ANALÝZA ZMĚN V KRAJINĚ POMOCÍ AUTOMATICKÉ KLASIFIKACE.....	25
1.7 ANALÝZA ANALOGOVÝCH MULTITEMPORÁLNÍCH DAT.....	26
1.8 ANALÝZA DIGITÁLNÍCH MULTITEMPORÁLNÍCH DAT Z DPZ.....	26
1.8.1 <i>Techniky ke zlepšení výsledků multitemporální analýzy</i> .....	28
1.8.2 <i>Land Cover a Land Use</i> .....	29
<b>2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY.....</b>	<b>30</b>
2.1 POJETÍ KRAJINY A HODNOCENÍ JEJÍCH ZMĚN.....	30
2.2 SLEDOVÁNÍ ZMĚN V KRAJINĚ.....	32
2.3 PŘÍPADOVÉ STUDIE A KVALIFIKAČNÍ PRÁCE.....	34
2.3.1 <i>Ukázka povahy některých projektů</i> .....	34
2.3.2 <i>Kvalifikační práce</i> .....	36
2.3.3 <i>Software pro digitální zpracování obrazu</i> .....	37
<b>3 CHARAKTERISTIKY ZÁJMOVÉHO ÚZEMÍ.....</b>	<b>39</b>
3.1 GEOLOGIE.....	39
3.2 GEOMORFOLOGIE A PEDOLOGIE.....	40
3.3 KLIMATICKÉ PODMÍNKY.....	40
3.4 HYDROLOGIE.....	41
3.5 VEGETACE.....	41
3.6 FAUNA.....	42
3.7 HISTORIE OBCE.....	43
<b>4 KLASIFIKACE OBRAZU A KVANTIFIKACE PLOCH PRO JEDNOTLIVÉ ČASOVÉ HORIZONTY .....</b>	<b>44</b>
4.1 PŘÍPRAVA DISTANČNÍCH DAT PRO JEJICH ZPRACOVÁNÍ.....	44
4.1.1 <i>Příprava leteckých snímků</i> .....	44
4.1.2 <i>Příprava družicových snímků</i> .....	44
4.2 ISODATA KLASIFIKÁTOR APLIKOVANÝ NA LETECKÉ SNÍMKY.....	46
4.3 KLASIFIKÁTOR MAXIMÁLNÍ PRAVDĚPODOBNOSTI APLIKOVANÝ NA LETECKÉ SNÍMKY.....	48
4.3.1 <i>Zhodnocení přesnosti klasifikace leteckých snímků</i> .....	52
4.4 POROVNÁNÍ VÝSLEDKŮ ŘÍZENÉ AUTOMATICKÉ KLASIFIKACE A VIZUÁLNÍ INTERPRETACE LETECKÝCH SNÍMKŮ.....	55
4.5 KLASIFIKACE DRUŽICOVÝCH SNÍMKŮ.....	57
4.5.1 <i>Určení plochy vodní plochy z dat družice Landsat 7</i> .....	61
4.5.2 <i>NDVI Change</i> .....	62
<b>5 POROVNÁNÍ ZMĚN KRAJINY ZÁJMOVÉHO ÚZEMÍ .....</b>	<b>64</b>
5.1 ZMĚNY V KRAJINĚ MEZI ROKY 2003 A 2008.....	64
<b>ZÁVĚR.....</b>	<b>67</b>
<b>SEZNAM INFORMAČNÍCH ZDROJŮ.....</b>	<b>68</b>
<b>SEZNAM PŘÍLOH.....</b>	<b>73</b>

## SEZNAM TABULEK

Tabulka 1: Výměra plochy a procentuální zastoupení informačních tříd snímku z roku 2003.....	51
Tabulka 2: Výměra plochy a procentuální zastoupení informačních tříd snímku z roku 2008.....	51
Tabulka 3: Chybová matice automatické klasifikace leteckého snímku z roku 2003.....	52
Tabulka 4: Chybová matice automatické klasifikace leteckého snímku z roku 2008.....	54
Tabulka 5: Porovnání výsledků klasifikace vizuální interpretací a klasifikátorem maximální pravděpodobnosti pro rok 2003.....	55
Tabulka 6: Porovnání výsledků klasifikace vizuální interpretací a klasifikátorem maximální pravděpodobnosti pro rok 2008.....	56
Tabulka 7: Shrnutí výsledků různých metod klasifikace snímků z Landsat 7.....	61
Tabulka 8: Kvantitativní zachycení změn v jednotlivých kategoriích mezi léty 2008 a 2003.....	64

## SEZNAM OBRÁZKŮ

Obrázek 1: Posloupnost kroků v DZO.....	12
Obrázek 2: Příklad binárního rozhodovacího stromu.....	23
Obrázek 3: Mapová kompozice lokalizace Starých Jesenčan.....	39
Obrázek 4: Družicové snímky Landsat 7 území Starých Jesenčan v roce 2000 a 2010 (zleva).....	46
Obrázek 5: Klasifikace obrazu z roku 2003 před a po úpravě (zleva).....	50
Obrázek 6: Klasifikace obrazu z roku 2008 před a po úpravě (zleva).....	50
Obrázek 7: Klasifikace družicových snímků z roku 2000 a 2010 algoritmem ISODATA (zleva).....	57
Obrázek 8: Družicové snímky z let 2000 a 2010 klasifikované algoritmem maximální pravděpodobnosti (zleva).....	59
Obrázek 9: Družicové snímky z roku 2000 a 2010 vizuální interpretací (zleva).....	60
Obrázek 10: Vymezení plochy rybníka na snímku s kombinací pásem 4-5-3 a ve výsledku automatické klasifikace, (zleva).....	62
Obrázek 11: Vizualizace změny indexu NDVI mezi roky 2000 a 2010.....	63

## SEZNAM GRAFŮ

Graf 1: Informační třídy algoritmu ISODATA pro rok 2003.....	47
Graf 2: Informační třídy algoritmu ISODATA pro rok 2008.....	48
Graf 3: Výsledek algoritmu maximální pravděpodobnosti pro rok 2003.....	51
Graf 4: Výsledek algoritmu maximální pravděpodobnosti pro rok 2008.....	52
Graf 5: Porovnání výsledků klasifikace vizuální interpretací a klasifikátorem maximální pravděpodobnosti pro rok 2003 a 2008.....	56
Graf 6: Grafy procentuelních zastoupení informačních tříd klasifikace ISODATA z let 2000 a 2010 (zleva).....	58
Graf 7: Grafy procentuelních zastoupení informačních tříd klasifikátorem maximální pravděpodobnosti z let 2000 a 2010 (zleva).....	59
Graf 8: Grafy procentuelních zastoupení informačních tříd vizuální interpretací z let 2000 a 2010 (zleva).....	60
Graf 9: Vývoj zastoupení jednotlivých kategorií v letech 2003 a 2008 v ha.....	65
Graf 10: Vývoj plochy zastoupení základních kategorií v hektarech.....	66



## SEZNAM ZKRATEK

CORINE	Coordination of Information on the Environment
DEM	Digital Elevation Model (digitální model terénu)
DN	Digital Number
DPZ	Dálkový průzkum Země
DZO	Digitální zpracování obrazu
GIS	Geografický informační systém
LC	Land Cover
LU	Land Use
ML	Maximum Likelihood
MPL	Multilayer Perceptron
NDVI	Normalized Difference Vegetation Index
NS	Neuronové sítě
VaV MŠMT	Výzkum a vývoj, Ministerstvo školství, mládeže a tělovýchovy
VI	vizuální interpretace
WGS 84	World Geodetic System 84
WMS	Web Map Service
κ	kappa

# ÚVOD

Krajina se neustále proměňuje. Nejen díky svým vlastním procesům, ale proměňuje se v současnosti především vlivem člověka. Tyto změny se stávají postupem času i růstem obyvatel čím dál významnější. Pro plánování budoucnosti a kontrolu našich zdrojů je potřebné tyto změny monitorovat. K tomu jsou již po dlouhou dobu využívána data z dálkového průzkumu Země. Růst úrovně technologie a vědeckého poznání potřebu zkoumání krajiny podporuje, ale stále nelze z tohoto procesu vynechat interpretační schopnosti člověka. V současnosti se povaha metod digitálního zpracování obrazu přibližuje právě k lidskému myšlení nebo vnímání.

Pro sledování změn v krajině je nejprve nutné snímek z dálkového průzkumu Země klasifikovat neboli zjednodušeně řešeno abstrahovat jej a rozčlenit do několika kategorií. Teoretickou podstatou automatické klasifikace a zároveň i jednotlivými metodami se zabývá první kapitola.

Druhá kapitola zachycuje současný stav řešené problematiky, jejímž cílem je uvést zmíněnou teorii v kontextu praxe. Tato kapitola představuje pojem „krajina“, jenž není jednoznačně definován, také jako systém.

V následující kapitole je podrobněji popsáno zájmové území Starých Jesenčan, kterým se tato diplomová práce zabývá. Jedná se o poměrně malé území, kterého se průběhu zkoumaných let dotkl především růst počtu obyvatel a prodej orné půdy.

Čtvrtá kapitola popisuje řešení aplikace automatické klasifikace na zájmové území. V této diplomové práci byly použity letecké snímky a družicové snímky Landsat 7. Tyto byly následně zpracovávány v programu ArcGIS Desktop 10. Součástí této kapitoly je i zhodnocení výsledků klasifikace.

Poslední kapitola je závěrečnou etapou v konceptu této diplomové práce, neboť popisuje kvantitativně změny v dané krajině.

Cílem této diplomové práce je zhodnocení stávajících způsobů automatické klasifikace obrazu, popis charakteristik zájmového území, příprava distančních dat pro jejich zpracování, klasifikace obrazu a kvantifikace ploch pro jednotlivé časové horizonty a porovnání změn krajiny zájmového území.

# 1 ZHODNOCENÍ STÁVAJÍCÍCH ZPŮSOBŮ AUTOMATICKÉ

## KLASIFIKACE OBRAZU

Cílem první kapitoly je shrnout teoretické základy metod klasifikace obrazu, jež jsou využívány pro zpracování obrazové informace z dálkového průzkumu Země (dále DPZ). Snahou je zvýraznit možnosti využití jednotlivých metod ve vzájemných vztazích a jejich výhody či nevýhody. V obecnosti neexistuje nejlepší řešení úlohy klasifikace obrazu, protože výběr té nejvhodnější metody závisí na dostupných datech, možnostech techniky, ale především se odvíjí od cíle klasifikace.

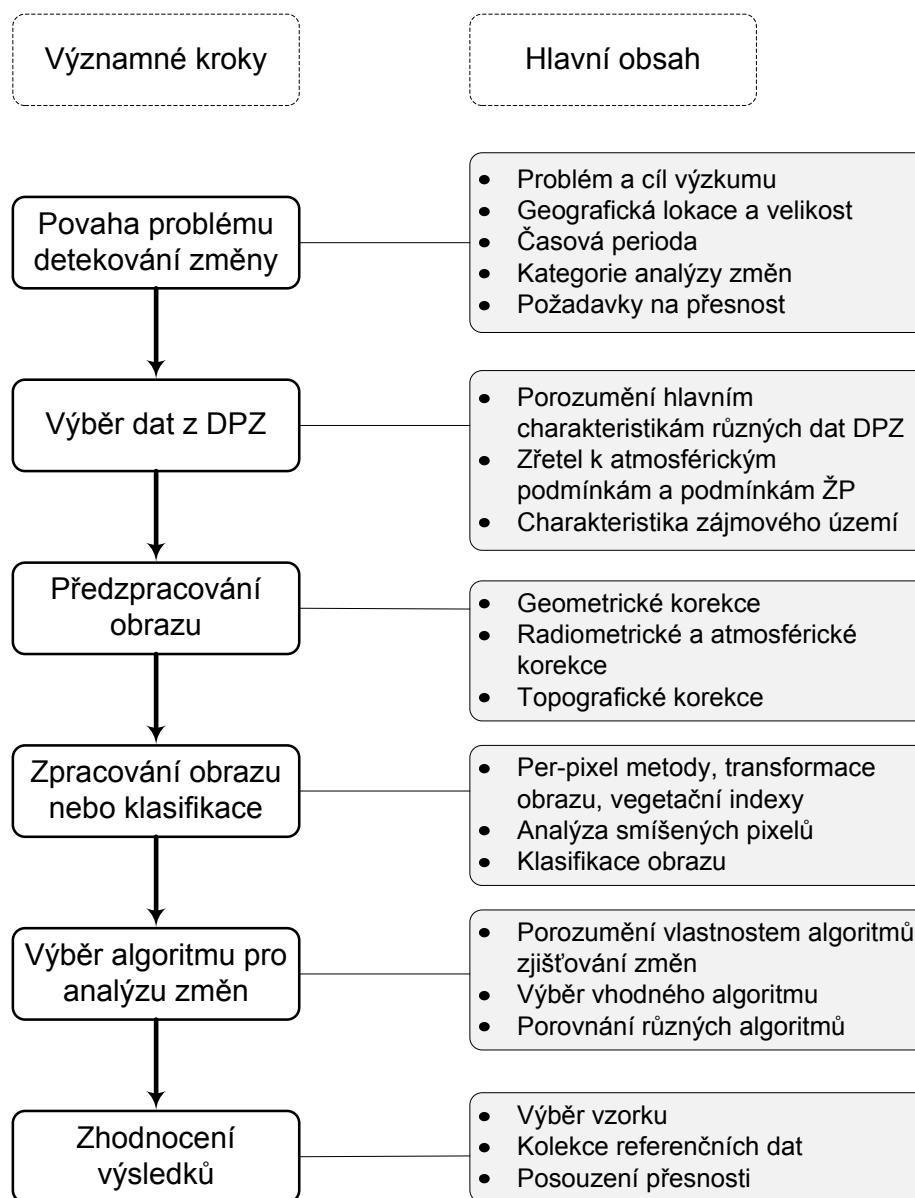
### 1.1 Úloha klasifikace obrazu v digitálním zpracování materiálů DPZ

Distančně získaný obrazový materiál je buď povahy analogové, nebo digitální, a proto forma obrazu určuje také možnosti jeho dalšího zpracování, což následně shrnuje Dobrovolný [12].

Zpracování analogových dat klasickými postupy interpretace je rozvíjeno od počátků fotografie. Každý obrazový materiál obsahuje informaci jak o topografických (geometrických) vlastnostech objektů (např. velikost, vzdálenost objektů a jejich vzájemná poloha), tak informaci tematickou (např. druh povrchu, obsah půdní vlhkosti). Získáváním tematických informací se zabývá fotointerpretace, jež je založena na tzv. interpretačních znacích, jako jsou především tvar, tón, barva, stín, velikost, textura, struktura, poloha a příčinné vztahy. Interpretačních znaků je využíváno k sestavování tzv. interpretačních klíčů, které definují vztah mezi vzezřením objektů a jevů na snímcích a ve skutečnosti.

Zpracování digitální obrazové informace, jež je ukládána v číslicové formě, spolu s rozvojem výpočetní techniky představuje zautomatizování řady postupů a urychlení některých, zvláště výpočetních postupů (transformace, tvorba ortofoto apod.). Dalšími významnými přednostmi je objektivita, přesnost a v jistém smyslu i nižší náklady na zpracování. Vedle těchto výhod přináší digitální zpracování materiálů DPZ i nevýhody, a právě v oblasti automatické klasifikace je nutné využívat i poznatky z analogové interpretace. V číslicové formě lze totiž velmi dobře prezentovat interpretační znaky jako je barva nebo tón, ale například v případě textury či struktury to lze již obtížně. Klasické postupy analogové interpretace jsou proto stále používány a také role člověka v interpretačním procesu je neopominutelná.

Členění a posloupnost metod digitálního zpracování obrazů nejsou však úplně jednotné a uzavřené. Zde na obrázku 1 je uvedeno schéma převzaté z [45], které nejlépe souvisí s tématem této diplomové práce. Uvedení některých významných metod digitálního zpracování obrazu je na základně též publikace v následujícím textu.



**Obrázek 1:** Posloupnost kroků v DZO

*Zdroj: upraveno dle [45]*

Metody korekce obrazu jsou zaměřeny na zjišťování a redukci chyb, šumu a geometrických zkreslení, které vznikají v průběhu snímání, přenosu a zaznamenávání údajů. Cílem těchto metod je upravit obraz tak, aby co nejlépe odpovídal snímané skutečnosti. Rozdělujeme je na radiometrické a geometrické. Do skupiny radiometrických korekcí patří především rekonstrukce periodických výpadků obrazu, rekonstrukce pásování, odstranění náhodného šumu, odstranění atmosférických vlivů aj. Zdrojové digitální obrazy obvykle

obsahují také geometrická zkruslení, jejichž zdrojem je například zeměpisná poloha, vliv snímacího zařízení, panoramatické vlivy, zaoblení Země a reliéf. K jejich odstranění nebo ke sladění snímku s určitou mapovou projekcí se využívají metody geometrické korekce obrazů. Zde lze, pokud je to možné, v aplikaci vycházet ze známých matematických vztahů nebo využít souřadnic známých pozemních kontrolních bodů a teorie transformace souřadných systémů a převzorkování obrazu<sup>1</sup>.

Metody převzorkování slouží k efektivnějšímu znázornění obrazu z hlediska možnosti dalšího vizuálního nebo automatického zpracování. V průběhu jejich aplikace nezískáme žádnou novou informaci, můžeme jen některé informace potlačit nebo zvýraznit. Většinou se zvýraznění provádí v několika krocích, které například manipulují kontrastem snímku, provádí jeho filtraci, zvýraznění hran apod.

V případě obrazů z DPZ, jejichž důležitou vlastností je multispektrálnost, se vyčleňují metody transformace obrazu. Pozemní objekty mají v různých spektrálních pásmech různou odrazivost a některá pásma jsou vhodnější k identifikaci určitých objektů než jiná a celá sada multispektrálních obrazů nese příliš mnoho informací, proto je užitečné vytvořit kompozitní obraz. Zároveň je kompozitní multispektrální obraz vhodnými metodami komprimován, neboť například hodnoty intenzity jasu pro pixely jsou mezi pásmy vysoce korelované. Jednou z metod používaných pro tento účel je analýza hlavních komponentů (*PCA – principal components analysis*). Velké praktické využití má také výpočet tzv. vegetačních indexů.

Etapa klasifikace obrazu je často cílovou částí jeho zpracování a je také těžištěm této diplomové práce, jejímž účelem je identifikace jednotlivých povrchů či objektů. K tomuto cíli jsou využívány například vícerozměrné statistické metody nebo různá rozhodovací pravidla (klasifikátory) a výsledkem je, že každému obrazovému prvku je přiřazen určitý tematický obsah. Klasifikátory jsou většinou založeny na studiu spektrálních vlastností objektů, dále pak na vlastnostech geometrických a prostorových.

Pokud budou optimálním způsobem připravena data pomocí vhodné kombinace metod výše uvedených fází digitálního zpracování obrazu získaného z DPZ, následují jejich výhodné využití pro studium dynamiky jevů, modelování s obrazovými daty například pro odvození kvantitativních vztahů mezi daty získanými DPZ či integraci obrazových dat a jejich vstup do GIS.

---

<sup>1</sup> proces transformace DN (*digital number*) hodnoty každého obrazového prvku z původní souřadné soustavy do soustavy nové

## 1.2 Podstata klasifikačních metod

Tato podkapitola je úvodem do klasifikačních metod a nejdůležitější pojmy tohoto tématu jsou definovány dle Dobrovolného [12]. V nejobecnějším slova smyslu je klasifikace proces, při kterém je jednotlivým pixelům přiřazován určitý informační význam. Jeho cílem je nahradit hodnoty radiometrických charakteristik původního obrazu hodnotami vyjadřujícími tzv. informační třídy. Typ a obsah nových informací například ve formě tematické mapy se odvíjí od zaměření celého projektu.

Klasifikace obrazu je založena na použití klasifikátorů, podle nichž lze všechny prvky zařadit do určité třídy a které se mohou týkat obecně nejrůznějších vlastností objektů a jevů v obraze. Podstatné je, že jevy či objekty v obraze se v hodnotách porovnávaných vlastností vzájemně dostatečně odlišují. Klasifikátory prostorového chování objektů zahrnují klasifikaci na základě okolních pixelů. Prostorové klasifikátory zahrnují rozpoznávací příznaky jako texturu, vzájemnou vzdálenost, velikost, tvar, opakovatelnost či kontext. Klasifikátory časového chování používají časových změn objektu jako prostředku k jejich třídění.

Nejvíce propracované a využívané jsou klasifikátory spektrálního chování objektů. K zařazení všech prvků obrazu do určité třídy využívají multispektrálních dat a znalostí spektrálního chování objektů. Předpokladem je vykazování odlišného spektrálního chování různých objektů na základě svých odrazových nebo vyzařovacích vlastností.

Nejčastěji využívané klasifikátory spektrálního chování jsou bodové (*per pixel*) klasifikátory, jež k zařazení obrazových prvků do tříd sledují vlastnosti a příznaky právě klasifikovaného pixelu, nikoliv jeho okolí. Dále vzhledem k běžně dostupným obrazovým datům je proces této automatické klasifikace založen na následujících předpokladech. Citlivost snímacího zařízení je konstantní pro všechna pásma multispektrálního obrazu. Každý obrazový prvek odpovídá přesně definované ploše na zemském povrchu a také představuje homogenní prvek ve smyslu jeho spektrálního chování. Takový obrazový prvek může náležet pouze k jedné klasifikační třídě. Nakonec mají naměřená data v každém pásmu normální rozdělení,

Následující schéma zachycuje základní dělení *per pixel* metod klasifikace obrazu. Jejich podrobnější popis je obsahem dalších podkapitol.

- **tvrdé** - na základě hodnoty pixelu přiřazují jeho příslušnost k jedné konkrétní třídě (pixel nemůže příslušet více třídám),
- **měkké** - hodnoty pixelu (např. procenta) vyjadřují stupeň jeho příslušnosti k různým třídám.
- **neřízené** – probíhají zcela automaticky, je definován pouze počet výstupních tříd,
- **řízené** – uživatel klasifikaci ovlivňuje definováním trénovacích tříd.

Do skupiny *per pixel* klasifikace patří také metody neuronové klasifikace, které spolu s objektově orientovanou klasifikací jsou již novějšími přístupy k této problematice. Na rozdíl od bodové klasifikace objektově orientovaná klasifikace zohledňuje předpoklad pravděpodobnosti, že sousední pixely náležejí určité třídě.

### 1.3 Řízená klasifikace

Při řízené klasifikaci zpracovatel specifikuje nejprve tzv. trénovací plochy, jež jsou částmi obrazu, které může zpracovatel na základě nejrůznějších podpůrných dat určit jako určitý typ povrchu. Před vlastní klasifikací je tedy nutné sestavit klasifikační schéma dle účelu projektu. Prvky tohoto schématu jsou položky legendy (třídy) výsledné tematické mapy. Výsledná klasifikace obrazu však nemusí být jeho konečným zpracováním, ale lze ji využít pro přesnější analýzu povrchu. Řízená klasifikace má dle Dobrovolného [12] tedy tyto fáze:

1. definování trénovacích ploch,
2. výpočet statistických charakteristik (tzv. spektrálních příznaků) pro trénovací plochy charakterizující jednotlivé třídy, jejich editace a výběr vhodných pásem pro vlastní klasifikaci,
3. volba vhodného rozhodovacího pravidla (tzv. klasifikátoru) pro zařazení všech prvků obrazu do jednotlivých tříd,
4. zatřídění všech obrazových prvků do vymezených tříd,
5. úprava, hodnocení a prezentace výsledků klasifikace.

#### 1.3.1 TRÉNOVACÍ ETAPA

Kvalita provedení této etapy významně ovlivňuje výsledek klasifikace. Pro každou třídu (kategorii) musí být vymezeny trénovací plochy a jejich výběr závisí pouze na zpracovateli. Tato fáze má základy ve využití podpůrných dat jako jsou například mapy, letecké snímky či

terénní výzkum. Tato data musí být kompletní, ve kterých zpracovatel musí charakterizovat všechny hledané třídy, a reprezentativní, právě když hledané třídy jsou charakterizovány částmi obrazu, které jsou pro danou třídu typické. Je dána řada doporučení, jak vhodně definovat trénovací plochy. Způsob a odůvodnění jejich definice je blíže popsána v praktické části této diplomové práce.

### 1.3.2 VÝPOČET STATISTICKÝCH CHARAKTERISTIK JEDNOTLIVÝCH TŘÍD

Statistickými charakteristikami třídy, tvořícími její signaturu, rozumíme například průměrový vektor, směrodatnou odchylku nebo kovarianční matici. Účelem uvedených statistik je vyjádřit, zda trénovací plochy vhodně charakterizují jednotlivé třídy a zda se také třídy ve zvoleném multispektrálním prostoru vzájemně dostatečně odlišují.

Vhodnost trénovacích ploch je hodnocena především testováním normálního rozdělení všech natrénovaných pixelů v každé třídě. Vhodnost trénovacích množin závisí také na volbě pásem multispektrálního obrazu. Určité povrchy, které jsou si spektrálně podobné v určité části spektra, mohou být spektrálně separovatelné v jiné části spektra.

Spektrální příznaky mohou být zobrazeny graficky například ve formě histogramu. Vzájemné porovnání kvality natrénovaných dat dovoluje tzv. spektrogram, jenž znázorňuje průměr i rozptyl hodnot pixelů z trénovacích ploch v rámci každého pásma. Třetím způsobem grafického znázornění je korelační pole DN hodnot mezi jakýmkoli dvěma pásmy multispektrálního obrazu. V každém grafu jsou tedy vyneseny DN hodnoty odpovídajících si pixelů. Je-li splněn požadavek normálního rozdělení trénovacích ploch, pak základní statistické charakteristiky aritmetický průměr a směrodatná odchylka vymezují v korelogramu elipsu. Průměr hodnot dvou testovaných pásem definuje polohu jejího středu, směrodatná odchylka určuje meze, která v korelogramu vymezuje jeho část, do níž je elipsa vepsána.

Míra odlišnosti mezi třídami může být vyjádřena také kvantitativně, a to tzv. divergencí, jež vyjadřuje váženou vzdálenost mezi průměrovými vektory uvažovaných tříd. Divergence nebo tzv. transformovaná divergence nabývá hodnot v intervalu  $\langle 0;2 \rangle$ , kde 0 je hodnota dokonalé shody mezi charakteristikami spektrálních příznaků porovnávaných tříd a hodnota 2 znamená ideální odlišení zkoumané dvojice tříd.

O kvalitě trénovací etapy se lze přesvědčit také při klasifikaci v trénovacích plochách v tzv. chybové matici, která zaznamenává kolik pixelů je správně klasifikováno. Tento způsob však vypovídá pouze o kvalitě trénovacích ploch. Celkovou úspěšnost klasifikace lze testovat v tzv. testovacích plochách, vymezených v obrazu mimo trénovací plochy.



Důležitou částí této etapy je také výběr vhodných pásem pro klasifikaci. Pro poměrně vysokou korelaci mezi pásmy je často využíváno různých transformací původních pásem k rozšíření příznakového prostoru a zvýšení separability hledaných tříd. Mezi tyto způsoby transformace patří například *metoda analýzy hlavních komponent*, *transformace Tasseled Cap*, *metoda aritmetické kombinace původních pásem* (poměry pásem) či *výpočet vegetačního indexu* a také do jisté míry i *hodnoty divergencí*.

### 1.3.3 KLASIFIKAČNÍ ETAPA

V této etapě jsou prostřednictvím vhodného rozhodovacího pravidla (klasifikátoru) postupně zařazovány jednotlivé pixely do jedné z tříd. Tento proces stojí na předpokladu, že pixely z jedné třídy se budou ve vícerozměrném prostoru shlukovat v jeho určité části. Je tedy nutné nalézt pravidlo, které určí, ke kterému shluku každý pixel patří. Pixely jednotlivých tříd tedy vytvářejí shluky, jejichž středy (centroidy) odpovídají průměrné hodnotě, vypočtené ze všech pixelů v daném pásmu. Průměrné hodnoty všech pásem použitých v klasifikaci tvoří průměrový vektor. V praxi se v analyzovaném obrazu vždy vydělí určitá množina pixelů, jejichž spektrální chování je odlišné od natrénovaných tříd a které dle použitého klasifikátoru nepatří k žádnému shluku. Bývá početná i množina pixelů, které budou náležet do více tříd. V reálné automatické klasifikaci nebývá trénovací etapa ani spektrální odlišitelnost jednotlivých klasifikovaných tříd vždy ideální.

Následující odstavce jsou popisem různých klasifikátorů, naznačení jejich principu, jejich výhod či nevýhod. Jejich popis vychází ze skript [12].

#### **Klasifikátor minimální vzdálenosti středů shluků**

Pro každý shluk je nejprve vypočtena průměrná spektrální hodnota v každém klasifikovaném pásmu. Jednotlivé průměrné hodnoty definují střed shluku – centroid – ve vícerozměrném prostoru. Příslušnost každého pixelu je poté hodnocena dle vzdálenosti, jakou má tento pixel od jednotlivých centroidů. Toto pravidlo umožňuje definovat určitou mez nebo také varianci shluku. Je-li vzdálenost od centroidu větší než definovaná mezní vzdálenost, pixel pak není do shluku zařazen. Tento algoritmus je sice jednoduchý, ale výpočet není citlivý na různý stupeň rozptylu ve spektrálním chování dat.

#### **Klasifikátor pravouhelníků**

Nedostatek předchozího klasifikátoru lze vyřešit tím, že rozptyl hodnot každé třídy budeme uvažovat ve smyslu minimální a maximální hodnoty všech pixelů. Tím získáme oblast ve vícerozměrném prostoru, do které buď určitý pixel bude patřit, nebo ne. Sensitivita

tohoto klasifikátoru na rozptyl hodnot každé třídy je vyjádřena velikostí definované oblasti. V případě překryvu dvou pravoúhelníků může být pixel spadající do dvou tříd klasifikován v další etapě jiným rozhodovacím pravidlem, či můžeme určit priority tříd. Takový překryv může být způsoben také vysokou korelací mezi hodnotami pixelů v klasifikovaných pásmech. Úspěšnost klasifikace ovlivňují především odlehlé pixely. Pro tento klasifikátor ale existují způsoby jeho úpravy, aby se snížil negativní vliv odlehlých pixelů na výsledek.

### **Klasifikátor $k$ nejbližších sousedů**

Modifikací a rozšířením klasifikátoru minimální vzdálenosti je klasifikátor  $k$  nejbližších sousedů. Tento klasifikátor však hodnotí příslušnost daného pixelu také na základě početního zastoupení pixelů určité třídy v okolí zpracovávaného obrazového prvku. Algoritmus vyhledá ke klasifikovanému pixelu určitý předem stanovený počet  $k$  nejbližších pixelů v analyzovaném příznakovém prostoru bez ohledu na trénovací množiny. Pixel je pak zařazen do té kategorie, která v množině  $k$  sousedů převažuje.

### **Klasifikátor maximální pravděpodobnosti**

U obou výše uvedených rozhodovacích pravidel vzniká problém správného zatřídění sporných pixelů nebo případ, kdy se shluky jednotlivých tříd často překrývají. Klasifikátor maximální pravděpodobnosti kvantitativně hodnotí jak varianci hodnot, tak korelaci a kovarianci každé třídy při zatřídování neznámého prvku. Z předpokladu normálního rozdělení shluků pixelů v trénovacích množinách lze pro každý shluk sestavit z průměrového vektoru a kovarianční matice frekvenční funkci normálního rozdělení. Pro každou DN hodnotu pak lze vypočítat pravděpodobnost jejího výskytu čili pravděpodobnost její příslušnosti k danému rozdělení. Při znázornění v korelačním poli můžeme spojit pro každý shluk místa o stejné pravděpodobnosti výskytu pixelu s určitou hodnotou. Dostaneme tak izoliny často o tvaru elipsy. Tento klasifikátor realizuje nejlepší výsledky za cenu vyšší výpočetní náročnosti. Aby byla klasifikace úspěšná, je třeba důkladně provést trénovací etapu, neboť tento klasifikátor je na nedostatky v trénovacích datech velmi citlivý.

### **Bayesovský klasifikátor**

Bayesovský klasifikátor je rozšířením klasifikátoru předchozího. Tento přístup umožňuje vážit výpočet pravděpodobnosti příslušnosti pixelu k určité třídě podle následujících hledisek. Jedno z nich je předpokládaná pravděpodobnost výskytu určité třídy, která je přímo úměrná jejímu předpokládanému plošnému zastoupení v obraze. Vysokou hodnotu váhy dostanou v procesu ty kategorie, jejichž správná klasifikace má pro nás největší význam. Použití vah pro každou třídu tedy vede k optimalizaci klasifikace. Klasifikátor pracuje s podmíněnými

pravděpodobnostmi<sup>2</sup>. Stanovení a priori pravděpodobnosti však bývá problematické. Dále pomocí tohoto klasifikátoru lze užít jako možnosti klasifikace sporných pixelů, a to v kombinaci s předchozími metodami. Podobně jako u klasifikátoru maximální pravděpodobnosti je výsledek klasifikace zatížen přesností a kvalitou trénovacích ploch, ale i přesností stanovení vah. Bayesovský klasifikátor je nejpřesnějším pravidlem řízené klasifikace.

#### **1.3.4 NEŘÍZENÁ KLASIFIKACE**

Tato skupina algoritmů zahrnuje metody, jak agregovat pixely, jež vytvářejí shluky ve vícerozměrném prostoru. Předpokladem neřízené klasifikace je vlastnost pixelů, které patří do jedné třídy, mít polohu ve vícerozměrném prostoru blízko sebe. Naopak pixely odlišných skupin, zastupující povrchy s rozdílným spektrálním chováním, jsou dobře separované. K vymezení odlišných skupin v multispektrálním příznakovém prostoru slouží metody shlukové analýzy. Na rozdíl od řízené klasifikace jsou výsledkem první fáze klasifikace třídy spektrální, ne informační. Těmi se stávají až v následující interpretační etapě. Spektrální třídy jsou srovnávány s jinými podpůrnými a referenčními daty a je určena jejich informační hodnota, neboli je jim přiřazen geografický význam.

Metody neřízené klasifikace jsou tedy založeny v prvním kroku na čistě matematických základech a při vhodně zvolených kritériích procesu shlukování lze tímto přístupem zjistit velmi jemné rozdíly ve spektrálním chování objektů, které pomocí řízené klasifikace nebylo možné odhalit. Celý proces definování shluků probíhá iteračním výpočtem.

##### **Algoritmus K-means**

Tato metoda je nejjednodušším shlukovacím algoritmem. Na počátku vyžaduje zadání požadovaného počtu shluků, a pokud je k dispozici, pak také počáteční polohu centroidů. Poté je každý klasifikovaný pixel přiřazen do shluku, k jehož průměrovému vektoru má v analyzovaném prostoru nejblíže. Z výsledků této klasifikace jsou poté vypočteny nové polohy centroidů neboli nové průměrové vektory. Proces končí dosažením zadaného počtu iterací nebo stavem, kdy v iteracích již nedochází k významnějšímu počtu změn v zařazování jednotlivých pixelů do shluků.

##### **Algoritmus ISODATA**

---

<sup>2</sup> Pomocí podmíněné pravděpodobnosti lze určit pravděpodobnost  $P_1$ , že daný pixel náleží k určité třídě, nabývá-li tento pixel určité hodnoty  $h_1$ . Z trénovacích dat lze zjistit pouze pravděpodobnost  $P_2$ , s jakou bude mít pixel tuto určitou hodnotu  $h_1$ , za předpokladu, že se jedná o danou třídu. Dle Bayesova vztahu lze pravděpodobnost  $P_1$  vypočítat za předpokladu předem stanovené pravděpodobnosti  $P_2$ .

Zmíněný algoritmus je rozšířením metody  $K$ -means o kontrolu heterogenosti. Na počátku je definován opět počet požadovaných shluků a počet iterací. Vlastní zařazování pixelů do jednotlivých shluků se řídí následujícími podmínkami. Shluk, který se stane heterogenním (určení dle dané hodnoty směrodatné odchylky) je rozdělen na dva nové shluky. Shluky, které jsou svými středy blíže, než je předem zadaná hodnota, jsou spojeny v jeden shluk a shluky, které obsahují méně pixelů, než je předem dáno, jsou zrušeny a jejich pixely zařazeny k okolním shlukům.

Tento přístup je výpočetně náročný, proto se často nejdříve klasifikují jen vybrané plochy na scéně. Poté jsou tyto plochy klasifikovány nezávisle na sobě. Vytvořené třídy jsou statisticky zpracovány a dle výsledků jsou stejné třídy spojovány. Nevýhodou tohoto algoritmu oproti algoritmu  $K$ -means je tedy větší specifikace parametrů pro vyřazení pixelů nebo spojení shluků a nutnost výpočtu rozptylu pro každý shluk. Naopak výhodou ISODATA klasifikátoru je jeho adaptivita a komplexnost samotného výpočtu.

## 1.4 Novější přístupy ke klasifikaci

Předchozí schéma klasifikačních metod zpracované dle Dobrovolného [12] je považováno za klasické. Do tematiky digitálního zpracování obrazu však v posledních letech významně zasahují poznatky z oboru umělé inteligence, a to princip neurčitosti a neuronové sítě. Na problém klasifikace podkladů DPZ se lze dívat také z jiného pohledu a využít objektivě orientovaného přístupu. Tato podkapitola má tedy za cíl tyto významné oblasti načrtnout v souvislosti s daným tématem diplomové práce.

### 1.4.1 NEURONOVÉ SÍŤE A KLASIFIKACE OBRAZU Z DPZ

Vývoj teorie neuronových sítí v oblasti klasifikace obrazu z DPZ v posledních deseti letech významně vzrostl, protože překonávají standardní statistické klasifikátory. [39] Atraktivitu neuronových sítí také zvyšuje případný nedostatek distribuovaných dat, zvláště pokud je limitovaná velikost dat trénovacích. Nejoblíbenějším klasifikátorem neuronové sítě je *multilayer perceptron* (MPL)<sup>3</sup>. Pro klasifikaci lze taktéž použít Kohonenovy samoorganizované mapy či fuzzy ARTMAP systémy. Problematika těchto druhů NS je pro účely klasifikace obrazu vhodně zpracována v [39], pro moji práci není však klíčovým tématem. Důležité je, že pomocí NS lze zpracovávat různé druhy vstupních dat (data z optické části spektra, data z radaru atd.) s využitím spektrálních znalostí povrchů. Jednotlivým vstupním datům lze přiřadit různou váhu. Naneštěstí tyto postupy nejsou popsány žádným

---

<sup>3</sup> vícevrstvý klasifikátor

matematickým modelem. Dále je pro vytvoření NS třeba velké množství trénovacích dat. Výhodami oproti parametrické klasifikaci dle [16] je možnost nelinearity vstupních dat, a tak není kladen požadavek na vlastnost jejich normální rozdělení. Existuje relativní tolerance k neúplným či roztržitým datům a metody NS jsou vhodné jak pro diskrétní, tak spojitá data. Dále není nutné do NS programovat algoritmus učení. Pokud jsou klasifikátory správně natrénovány, jsou velmi efektivní a výstup lze považovat za důvěryhodný. NS mají schopnost se adaptovat na změny v průběhu času lze v nich snadno zahrnout i jiná pomocná data. Na druhou stranu je trénování rozsáhlých sítí na sekvenčních strojích neúměrně pomalé a vznikají problémy s prvky, které nejsou reprezentovány ve vytvořených třídách. Je obtížné nakonfigurovat ideální architekturu sítě a samotný algoritmus trénování. Pro zpracování některých druhů sítí například vzniká potencionální potřeba velkého množství paměti. Dále během trénování mohou činit problém lokální minima a NS může projevovat nepředvídatelné chování.

#### 1.4.2 *PRINCIP NEURČITOSTI*

Princip neurčitosti neboli fuzzy<sup>4</sup> teorie označuje skupinu algoritmů a rozhodovacích pravidel, které umožňují pracovat s jistou mírou nejistoty. Fuzzy teorie se snaží vyrovnat s předpokladem klasických klasifikátorů, a to s předpokladem, že každý obrazový prvek musí být zařazen do jedné informační třídy, ale v důsledku omezeného prostorového rozlišení běžného digitálního obrazu vzniká problém tzv. smíšených pixelů (*mixture element* neboli *mixel*). Fuzzy teorie umožňuje definovat pro každý pixel pravděpodobnost jeho příslušnosti k více třídám. Vztah mezi příslušností pixelu k určité třídě a hodnotou radiometrické charakteristiky v obrazu tedy popisuje funkce příslušnosti. [12]

##### **Fuzzy *c*-means algoritmus**

Tento algoritmus je velmi podobný algoritmu *K*-means. V této fuzzy klasifikaci však každý pixel nese informaci (vektor) o stupni příslušnosti k nějaké *k*-té třídě. Střed shluku je pak průměr všech pixelů a jejich vah dle stupně příslušnosti k danému shluku. Odhad tříd vykazuje vysokou přesnost a pomocí tohoto algoritmu můžeme získat velké množství získaných informací. Je ale obtížné vizualizovat výsledek klasifikace a příliš mnoho informací může zbrzdit jejich samotnou reprezentaci. Není také jisté, jak velké množství získaných informací lze skutečně prakticky využít. Vzhledem k zmíněnému přehledu výhod a nevýhod tohoto přístupu ke klasifikaci je vždy nutné zvážit pro každý případ zvlášť jeho použití. [39]

---

<sup>4</sup> fuzzy = neurčitý, nepevný, nedeterminovaný

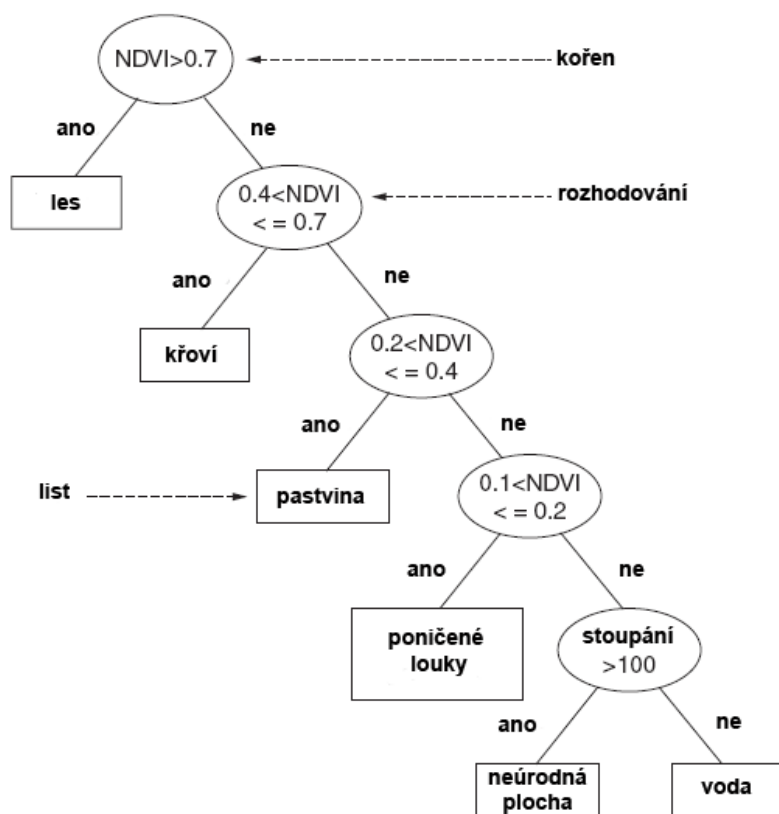
### 1.4.3 **OBJEKTIVĚ ORIENTOVANÝ PŘÍSTUP KE KLASIFIKACI**

V posledních letech se stává velice atraktivním objektivě orientovaný přístup ke zpracování obrazů z DPZ. Obsahuje metody, které se označují také jako kontextuální klasifikátory. Objektem obrazu rozumíme buď jeden pixel, ale síla tohoto přístupu spíše tkví v tom, že objektem označíme prostorový obrazový segment, který zahrnuje dva a více sousedních pixelů. Každý objekt nese vlastnosti, jako jsou například plocha, perimetr, tvar, průměrná hodnota zeleně, tyto klasifikátory tedy nejsou založeny pouze na spektrálních vlastnostech. Kontextuální klasifikátory se snaží popsat především kontext a strukturu (souhrnně topologii: vzdálenost, směr, konektivita, dotyk a vnoření) a jsou často aplikovány již na data klasifikovaná.[12]

Aplikace objektivě orientované analýzy obrazu se objevuje od map krajinného pokryvu, kde je potřeba kombinovat různá prostorová uspořádání v různých částech obrazu, po automatickou extrakci například zakrytých částí silnice či vytvoření obalových zón. Lze ji výhodně využít u mnohonásobných měření a pozorování, dále jako filtr informací pro redukci nepodstatných informací a je možné při řešení dané úlohy přejít k využití fuzzy logiky. Předpokladem pro přesnost této klasifikace je kvalita předchozí *per pixel* klasifikace. V případě chyby v klasifikaci hrozí její akumulace v dalších procesech a výsledkem může být i desinformace. Pokud je v průběhu klasifikace objekt vyřazen, jsou pak provždy vyřazeny i všechny pixely tohoto objektu. [16]

### 1.4.4 **ROZHODOVACÍ STROMY**

Analýza snímků z družic pomocí rozhodovacích stromů se začala rozvíjet od počátku osmdesátých let. Tyto klasifikátory sdílejí některé výhody použití neuronových sítí, ale již nezahrnují jejich limity. Rozhodovací strom popisuje podmínky, za kterých je množina podstatných atributů abstrahována do množiny hlavních informačních tříd. Struktura rozhodovacího stromu sestává typicky z proměnných, uzlů, větví a listů. Proměnnými mohou být prediktory, odkazující ke vstupním datům, nebo cílové proměnné, reprezentující krajinný pokryv, který má být zkoumán. Proměnné definované uživatelem mohou zahrnovat rastrové obrázky, vektorové vrstvy GIS, model terénu nebo externí programy. Rozhodovací strom obsahuje právě jeden kořenový uzel, obsahující všechna vstupní data. Větvě jsou tvořeny třemi komponenty, a to hypotézou, pravidly a podmínkami. Je běžné zahrnout do klasifikace mnohonásobná pravidla, která jsou hierarchicky uspořádaná. [16] Příklad jednoduchého binárního rozhodovacího stromu je uveden na obrázku 2.



**Obrázek 2:** Příklad binárního rozhodovacího stromu

*Zdroj: upraveno dle [16]*

Existuje řada druhů rozhodovacích stromů, které se liší různými kritérii, jako jsou proměnné pro testování v každém interním uzlu, homogenita pravidel na všech větvích nebo povaha konečných uzlů. Dále rozhodovací stromy lze dělit jako jednorozměrné nebo více rozměrné, diskrétní, regresní, homogenní nebo hybridní.

Rozhodovací stromy jsou jednoduché pro interpretaci a porozumění, jsou neparametrické povahy. Samotný model je možné validovat statistickými metodami a vstupní data není nutné významně předpřipravovat. Vytvořit optimální rozhodovací strom je ale NP-úplným problémem. Nevýhodou při vytváření rozhodovacího stromu je složitější vyjádření relací jako je XOR nebo shodnost. [16]

## 1.5 Zpracování výsledků automatické klasifikace

### 1.5.1 POSTKLASIFIKAČNÍ SHLAZENÍ VÝSLEDKŮ

Spektrální chování tříd se často překrývá u mnohých informačních tříd, a proto v již klasifikovaném obraze je množství osamocených pixelů, které jsou zařazeny odlišně od svého okolí. Tento problém vzniká právě u klasické *per pixel* klasifikace, neboť zařídění určitého pixelu nebere v potaz vlastnosti pixelů okolních.

Nejběžnější metodou pro zlepšení výsledků klasifikace je *nízkofrekvenční filtrace*, jejímž základním předpokladem je, že většina osamocených pixelů jsou chybami v klasifikaci. Nízkofrekvenční filtrace však vytváří třídy „zprůměrováním“ okolních tříd kvalitativně ohodnocených, což je také její nevýhodou. Tento problém odstraňuje *modální filtr*. V tomto případě je centrální pixel označen tou kategorií, která je ve filtrovacím okénku zastoupena nejčastěji. Do této filtrace je možné promítnout různorodost vah jednotlivých tříd nebo některé třídy mohou být přímo z filtrace vypuštěny. [12]

### 1.5.2 HODNOCENÍ PŘESNOSTI KLASIFIKACE

Jestliže je některý pixel označen jako chybně zařazený do třídy, pak pro jejich množinu obecně platí, že chybně klasifikované pixely se ve výsledném obrazu nevyskytují náhodně, ale mají určité prostorové upořádání, dále jsou více méně asociovány pouze s určitými třídami, většinou se nevyskytují izolovaně, ale ve skupinách a nakonec chybně klasifikované pixely jsou svým výskytem vázány na typické části klasifikovaných ploch.

Přesnost výsledků klasifikace je tedy nutné hodnotit vždy s ohledem na polohu. Jedním z nejvíce užívaných přístupů k hodnocení úspěšnosti klasifikace je sestavení *klasifikační chybové matice*. V tomto schématu je sledován vztah podpůrných dat a výsledků klasifikace v částech obrazu mimo trénovací plochy. Objektivnějším je způsob porovnávání klasifikovaného obrazu s referenčními daty ve shodných částech obrazu mimo trénovací plochy. Chyby v klasifikaci jsou dvojího druhu, a to chyby z opomenutí a chyby z nesprávného zařazení. [12]

Přesnost klasifikace lze sledovat také ze dvou pohledů, a to jako přesnost z hlediska uživatele a přesnost z hlediska zpracovatele. Příklad práce s chybovou maticí je uveden v [12] a také v kapitole 4.

Kvantitativní vyjádření přesnosti výsledků automatické klasifikace je možné také pomocí hodnot tzv. *Kappa koeficientu*, který porovná přesnost klasifikace (*PP*) s přesností náhodného zařazení pixelů do tříd (*PO*) následovně:

$$\kappa = \frac{PP - PO}{1 - PO}. \quad (1)$$

### 1.5.3 PREZENTACE VÝSLEDKŮ KLASIFIKACE

Kvalita výsledků klasifikace se musí promítnout i do způsobu prezentace koncovému uživateli v některé z následujících forem, uvedených také v [12]:



- tematická mapa vytištěná na papír – každá třída je prezentována jinou barvou, obsahuje legendu, možnosti tisku jsou však omezenější než možnosti grafické karty a obrazovky,
- tabulární data – výpočet plochy v rastrovém obrázku,
- digitální výstupy – jsou to především vstupní data pro GIS, je možné je kombinovat s jinými geografickými daty a prostředky pro vznik nových informačních vrstev.

## 1.6 Analýza změn v krajině pomocí automatické klasifikace

Detekování změn je procesem identifikování rozdílů v rámci objektu nebo jevu pozorováním v různých časových horizontech. Včasné a přesné změny zjišťování vlastností zemského povrchu poskytuje základ pro lepší pochopení vztahů a interakcí mezi člověkem a přírodou a vede k cíli lépe řídit a využívat zdroje. Obecně lze říci, že detekce změn zahrnuje především použití multitemporálních dat pro kvantitativní analýzu vlivu času na jev v centru zájmu. Kvalitní výzkum při analýze změn může poskytnout například následující informace: plocha a rychlost změny, prostorové rozložení pozměněných oblastí, změna rozložení půdy.

Základním předpokladem při použití distančních dat pro určování změn v krajině je, že změny v objektech zájmu budou mít za následek změny v hodnotách odrazivosti nebo textury, které jsou oddělitelné od změn způsobené jinými faktory, jako jsou rozdíly v atmosférických podmínkách, osvětlení nebo vlhkost půdy. V praxi navíc výsledek ovlivní mnoho faktorů jako je kvalita obrazu, kvalita atmosférických korekcí nebo normalizace v multitemporálních datech, dovednosti a zkušenosti analytika a samozřejmě zvolená metoda analýzy.

Existují dvě kategorie změn: změny mezi třídami a změny v rámci třídy. Změna mezi třídami je přeměna krajinného pokryvu z jedné kategorie do úplně jiné kategorie (např. odlesňování a urbanizace). Změna ve třídách je změna stavu území nebo typu povrchu v rámci stejné kategorie (např. prostřednictvím selektivní těžby dřeva). [12]

Obecně platí, že na místní úrovni jsou užitečné objektově orientované metody, pokud jsou k dispozici snímky ze satelitů s velmi vysokým prostorovým rozlišením, jako je QuickBird nebo IKONOS. Na regionální úrovni jsou používány *per pixel* metody při středním prostorovém rozlišení, jako jsou tematické Landsat Mapper (TM). Na národní i globální úrovni při hrubém prostorovém rozlišení, jako Moderate Resolution Imaging Spectroradiometer (MODIS) a Advanced Very High Resolution Radiometer (AVHRR) jsou

změny analyzovány na základě *subpixel* metod, které mohou poskytnout lepší výsledky než *per pixel* techniky kvůli problému s mixelami. Nicméně v praxi jsou technologie na bázi *per pixel* metod stále nejběžnějšími metodami pro analýzu změn krajiny v různých měřítkách.

V ideálním případě by data k multispektrální analýze měla splňovat tyto podmínky. Obrazy tvoří chronologicky uspořádanou řadu nejméně dvou členů, obrazy jsou pořízeny analogickým snímacím zařízením, které má pravidelnou periodu přeletů a zaznamenává stejnou část zemského povrchu a jsou pořízeny ve stejnou denní a roční dobu. Data jsou pořízena ve stejném měřítku, pod stejným úhlem záběru a jsou eliminovány vlivy reliéfu na radiační hodnoty objektů a nakonec data jsou pořízena ve stejných spektrálních pásmech a se stejným radiometrickým rozlišením. [12]

### 1.7 Analýza analogových multitemporálních dat

Metody zpracování analogových multitemporálních dat jsou založeny především na vizuálním porovnání snímků nebo interpretačních schémat. Výsledky této analýzy nelze obecně kvantifikovat a další nevýhodou je její časová náročnost, ale na druhou stranu lze zkoumat mnohem více interpretačních znaků (okolí objektu, jeho tvar či polohu). Tato data je nutné digitalizovat. [12]

### 1.8 Analýza digitálních multitemporálních dat z DPZ

Povaha rastrových dat dovoluje poměrně jednoduše získat přehled o změnách v krajině mezi více obrazy rychlým způsobem a změny poté lze kvantifikovat. Časová řada obrazových záznamů však musí mít přesnou geometrickou korekci (1/2 až 1/4 velikosti pixelu), jinak dojde k určení „nepravých změn“. Následující text na základě [12] zpřehledňuje nejběžnější metody k určování změn z digitálních obrazových záznamů.

#### Diference obrazů

Tato metoda spočívá v odečítání DN hodnoty dvou obrazů v odpovídajících si obrazových prvcích. Potencionální rozpětí výsledných hodnot je od -255 do +255, kde 0 odpovídá oblasti beze změny. Výsledky jsou obvykle převedeny do kladných hodnot přičtením určité konstanty:

$$d_{i,j,k} = DN_{i,j,k}(1) - DN_{i,j,k}(2) + c, \quad (2)$$

kde  $d_{i,j,k}$  - hodnota změny obrazového prvku,

$DN_{i,j,k}(1)$  - radiační hodnota prvního snímku,

$DN_{i,j,k}(2)$  - radiační hodnota druhého snímku,

$i, j$  - souřadnice obrazového prvku,

$k$  - spektrální pásmo,

$c$  - konstanta.

Vypočtené hodnoty mají ve výsledném obrazu přibližně normální rozdělení.

### **Obrazové podíly**

Tato metoda na rozdíl od předchozí eliminuje změněné podmínky snímání (např. polohu Slunce). Vyloučením těchto vedlejších vlivů se v analýze dostaneme k přesnějšímu určení podstatných změn sledované krajiny následujícím způsobem:

$$d_{i,j,k} = \frac{DN_{i,j,k}(1)}{DN_{i,j,k}(2)}, \quad (3)$$

kde význam symbolů odpovídá symbolům ve výpočtu difference obrazů. Pixel, jenž se mezi oběma časovými okamžiky nezměnil, dává v podílu hodnotu 1. Pixely ve výsledném podílovém obrazu budou mít opět normální rozdělení a největší změny se budou koncentrovat na obou koncích histogramu. Kritickým bodem je nalezení hraniční hodnoty mezi porovnávanými obrazy. Tato metoda dává lepší výsledky, použijí-li se transformovaná pásma (např. hodnoty vegetačních indexů).

### **Regresní závislost dvou obrazů**

Předpokladem této metody je, že každý pixel prvního obrazu je lineární kombinací odpovídajícího pixelu druhého obrazu. Pak je možné metodou nejmenších čtverců určit teoretické hodnoty druhého obrazu. Pro analýzu bude vytvořen rozdílový obraz mezi prvním a teoretickým obrazem. Pomocí této techniky dochází k potlačení vlivů, jako je výška Slunce či atmosférické efekty.

### **Multitemporální barevná syntéza**

Jedná se o prostou metodu vizualizace obrazů v barevném systému RGB. Pokud jsou hodnoty odpovídajících si pixelů stejné, v RGB budou takové části znázorněny určitým stupněm šedi. Naopak, budou-li odlišné, výsledek bude určitý barevný odstín. Ten indikuje určitou změnu a poměrně i charakter změny. Toto přiřazení barevného odstínu určité změně je však v praxi celkem problematické. Také zde významnou roli hraje výběr pásem, proto se pásma nahrazují například hodnotami PCA nebo vegetačními indexy.

### **Porovnání výsledku klasifikace**

V této metodě se nezávisle klasifikují dva nebo více obrazů z různých období stejným klasifikátorem. Výsledky klasifikace jsou ve formě tematických map porovnávány a zjišťují se tak oblasti změn a také jejich charakter. Přesnost této techniky však závisí na přesnosti každé klasifikace. Nevhodné pro tuto analýzu jsou tedy oblasti s heterogenním spektrálním chováním. Přítomnost velkého množství mixelů snižuje přesnost klasifikace.

### **Analýza vektoru spektrální změny**

Tato metoda staví na předpokladu, že změna objektů v krajině se projeví změnou jejich spektrálních charakteristik. Změnu spektrálních charakteristik pak zobrazuje tzv. vektor spektrální změny, jenž popisuje velikost i charakter změny mezi dvěma časovými horizonty.

Velikost změny  $V$  je definována jako velikost vektoru  $v$ , tedy

$$V = \sqrt{(DN1(T1) - DN1(T2))^2 + (DN2(T1) - DN2(T2))^2}. \quad (4)$$

Charakter nebo typ změny je určen směrem vektoru a lze jej určit jako úhel, který svírá vektor spektrální změny s určeným počátečním směrem.

#### **1.8.1 *TECHNIKY KE ZLEPŠENÍ VÝSLEDKŮ MULTITEMPORÁLNÍ ANALÝZY***

Aby byla analýza změn v krajině úspěšná, je třeba vstupní data vhodným způsobem předzpracovat. Nejdůležitějšími operacemi s daty jsou dle [12] následující tři.

#### **Nízkofrekvenční filtrace**

Tato metoda je výhodná v kombinaci s vyhlazením obrazu například průměrovým filtrem. Tento typ zvýrazní homogenní plochy na úkor detailů.

#### **Texturní transformace**

Textura může být měřítkem heterogenity nebo homogenity zjištěných tříd změn. Její analýza však není na místě, jestliže se jedná o přirozeně heterogenní třídy, jako jsou vegetace nebo zastavěné plochy.

#### **Analýza hlavních komponent**

Tato metoda lineárními transformacemi setřídí  $n$  vstupních pásem multitemporálních dat do nových  $n$  nekorelovaných výstupních pásem tak, že první komponenta nese nejvíce informací obsažených v původních datech a množství informací v dalších komponentách se progresivně zmenšuje. Při zjišťování změn lze tedy využít nejvíce informativní obraz.

### 1.8.2 *LAND COVER A LAND USE*

S tematickou této diplomové práce souvisí dva významné pojmy: Land Use a Land Cover. Ač se zdají být velice podobné, je nesprávné je zaměňovat.

#### **Land Cover**

Krajinný pokryv (Land Cover) vyjadřuje základní fyziognomii ekosystémů tvořících krajinnou mozaiku. Jeho obvyklé definice vycházejí z přirozeného vnímání krajiny nebo z geografického aspektu ekologie krajiny. Jednotlivé typy krajinného pokryvu jsou relativně homogenní a navzájem očividně odlišné. V systémovém pojetí představuje typologii reálně existujících podsoustav krajiny. Land Cover pojímáme tedy jako fyzický pokryv tak, jak je viděn ze zemského povrchu nebo z vesmíru. Zahrnuje vegetaci (přírodní nebo pěstovanou) a lidské výtvoř (obydlí, komunikace a další), které pokrývají zemský povrch. [36]

#### **Land Use**

Naproti tomu Land Use je založen na souboru funkcí, za jakým účelem je území využíváno. Proto může být využití krajiny definováno jako série aktivit podniknutých k produkci jednoho či více zboží nebo služeb v určitém typu Land Cover. Land Use je přeměnou přírodního prostředí či divočiny na prostředí vytvořené člověkem (pole, pastviny a sídla). Pozdější významné účinky na Land Use představuje živelný růst měst, půdní eroze, degradace půdy, salinita a přeměna v poušť. [36]

#### **CORINE Land Cover**

Program CORINE (*COoRdination of INformation on the Environment*) byl zahájen v roce 1985. Iniciátorem byla Evropská komise a cílem je sběr, koordinace a zajištění kvalitních informací o životním prostředí a přírodních zdrojích, které jsou srovnatelné v rámci Evropského společenství. Databáze CORINE Land Cover byla vytvořena interpretací družicových snímků Landsat a dalších podpůrných dat do kategorií CORINE LC nomenklatury. Nomenklatura rozlišuje 44 tříd, které jsou seskupené do tříúrovňové hierarchie, která reflektuje fyzikální a fyziognomické charakteristiky. Kategorie hlavní úrovně jsou urbanizovaná území, zemědělské plochy, lesy a polopřírodní oblasti, humidní území a vodní plochy. [4]

## 2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

### 2.1 Pojetí krajiny a hodnocení jejích změn

Krajina jako pojem se objevil na počátku devadesátých let 20. století jako jedno z klíčových slov této doby. V přírodních vědách částečně nahradil pojem ekosystém a v humanitních disciplínách se stal trochu nostalgickým povzdechem nad světem, který ztrácíme. [5] Je snahou pojem *krajina* přesně definovat, neboť se jedná vzhledem k problematice této diplomové práce o odborný termín. Záleží ovšem na kontextu použití tohoto pojmu a s ním spojeném typickém výrazovém slovníku. Článek vzdělávacího programu Ecologica Plus [11] a učebnice Krajinná ekologie [27] například uvádí následující možné definice a názory na tento pojem.

**Krajina** je heterogenní část zemského povrchu, skládající se ze souboru vzájemně se ovlivňujících ekosystémů, který se v dané části povrchu v podobných formách opakuje. [15]

**Krajina** je část zemského povrchu s charakteristickým reliéfem, tvořená souborem funkčně propojených ekosystémů a civilizačními prvky. [8]

Dle současných trendů rozvoje v geografii a v krajinné ekologii se **krajina** považuje často za holistickou entitu reálného světa, za totální systém geografické sféry, tedy za geosystém v širším slova smyslu. [30]

V reálné krajině se z pohledu systémového přístupu projevují dva základní druhy kvality:

- prvky (elementy) systému (geosféry, regiony atd.) definované svými stavovými veličinami, např. nadmořská výška, výška hladiny podzemní vody aj.
- vazby systému, realizované krajinnými procesy mezi prvky systému nebo v rámci jednotlivých prvků. Procesy se projevují změnami stavových veličin prvků krajiny v čase. [23]

Subsystém geografické sféry definuje [30] jako systém:

$$SG_s(P, T) = \{G_s(P, T), S_s(P, T)\}, \quad (5)$$

kde existuje interakce dvou relativně autonomních systémů: krajinoekologické sféry  $G_s$  (geosystémy, geokosystémy) a socioekonomické sféry  $S_s$  (socioekonomické systémy, systém společnosti).  $P$  definuje prostorový aspekt systému a  $T$  aspekt časový. Obě sféry jsou

ve vzájemných interakcích. Geosystém ( $G_s$ ) je tvořen fyzickými komponenty geografické sféry (ovzduší, vodstvo, půdy, geologický podklad, půdotvorný substrát, reálná biota, člověkem vytvořené a transformované prvky - prvky využití země a technické objekty) a nehmotným reliéfem. Systém socioekonomické sféry je složitější než geosystémy z důvodu různorodých vazeb mezi prvky systému.

Z hlediska geneze, fyzického charakteru a vztahu využívání krajiny člověkem [30] rozlišují:

1. primární (původní) struktura krajiny, kde prvky krajiny a jejich vazby tvoří původní a trvalý základ pro ostatní struktury (geologická stavba, půda, reliéf, vodstvo a ovzduší).
2. sekundární (současná) struktura krajiny, tvořena prvky využití země a materiálními výtvoři člověka (zejména technickými objekty), tj. zmíněný krajinný pokryv (Land Cover).
3. terciární struktura krajiny, daná prvky a prostorovými subsystémy socioekonomické sféry, tj. nehmotnými prvky a jevy (zájmy, projevy a důsledky činnosti společnosti a jednotlivých odvětví v krajině).

U všech krajin [15] definuje obecnou základní strukturu danou ploškami, koridory a základní krajinnou maticí. Matrice, jež má v krajině dominantní roli, je rozsáhlou krajinnou složkou, tvořící prostředí pro ostatní složky. Ploška je vymezena jako plošná část povrchu, která se vzhledem liší od svého okolí. Každá ploška má svou velikost, tvar, typ, heterogenitu a hranice. Koridory jsou úzké pruhy země, které se liší od krajinné matrice na obou stranách. Odlišují se vznikem, šířkou, stupněm propojenosti a křivolakostí. Koridory vznikají stejným způsobem jako plošky. Působením člověka vznikají lineární koridory.

Vztah mezi lidskou společností a přírodními složkami krajiny lze ve většině případů považovat za disharmonický. Antropogenní procesy ve srovnání s většinou přírodních procesů působí velmi rychle. Mění vzhled, strukturu a funkce krajiny přímo nebo nepřímo ovlivněním intenzity a průběhu přírodních procesů [28]. Přímé antropogenní jevy lze předvídat, očekávat nebo plánovat na rozdíl od vyvolaných antropogenních jevů, které jsou důsledkem těžce kontrolovatelných antropogenních procesů v krajině. [31]

## 2.2 Sledování změn v krajině

Sledování změn v krajině v čase je obecně založeno na sledování změn jednotlivých krajinných složek, jejich plošného zastoupení, dynamiky a prostorové konfigurace. Ke změně krajinného typu dochází tehdy, když odlišný typ krajinné složky se stane krajinnou maticí, kdy některá krajinná složka roste nebo ustupuje. [29]

Kvantifikace struktury krajinného pokryvu vždy podněcovala ekology k tvorbě nejrozmanitějších indexů či k jejich přejímání z jiných oborů. Tento přístup byl rozpracován především v osmdesátých letech, kdy nastupující vlna počítačů umožnila rozsáhlé a složité výpočty. Postupně bylo vyvinuto několik softwarových produktů, které tvoří jádro geografických informačních systémů. [19]

Například v [22] je uváděna následující kategorizace ukazatelů:

- metrické ukazatele plošek, které kvantifikují počet a velikost plošek,
- metrické ukazatele hranic a tvaru, které kvantifikují výskyt ekotonů<sup>5</sup>,
- měření diverzity, prováděné nejčastěji pomocí Shannonova indexu diverzity,
- ukazatele konfigurace krajiny, které jsou získány na základě měření souvisejících s určením nejbližšího sousedství, kontrastu hranic atd.

**Shannonův index diverzity** (*Shannon's Diversity Index*)

$$H' = -\sum_{i=1}^n (p_i \log p_i), \quad (6)$$

kde  $p_i$  je procentní zastoupení kategorie  $i$  na celkové rozloze území. Tento index se zvyšuje, jestliže se zvyšuje také počet typů plošek či je proporční zastoupení typů plošek vyrovnanější.

Krajinný pokryv je tedy tvořený mozaikou homogenních ohraničených plošek (*patches*). Právě diversita krajinné mozaiky je měřítkem pro diversitu struktury v krajině (*pattern*), která je jednou ze složek globální diversity. Následuje charakteristika některých vybraných ukazatelů dle článku [19].

**Maximální diversity** je dosaženo při vyrovnaném zastoupení všech tříd  $n$ , tedy

$$H_{\max} = \log n. \quad (7)$$

**Index dominance** je měrou skutečného poměrného zastoupení jednotlivých tříd a roste s významem matrice, tedy

---

<sup>5</sup>ekoton = rozhraní jednotlivých krajinných složek



$$D = H_{\max} - H'. \quad (8)$$

Plošky mají určitý tvar a jsou ohraničeny více či méně složitou hranicí. Tato složitost je snadno vyjádřitelná běžně užívaným indexem poměru obvodu  $P$  a plochy  $S$ , popř. poměru obvodu a obvodu odpovídajícího stejně velké ploše kruhu. Mnohem komplexnější hodnotou je však tzv. **fraktální dimenze**  $d$ , která vyjadřuje právě komplexitu obvodu plošek, kdy

$$P = \frac{1}{2} d \log S, \quad (9)$$

a tedy

$$d = 2 \frac{\log P}{\log S}. \quad (10)$$

Nízké hodnoty indexu  $d$  vyjadřují jednoduché tvary s rovnými okraji, naopak vyšší hodnoty vyjadřují složitější struktury. Ekologická interpretace těchto hodnot je taková, že čím se jedná o přirozenější stav, tím je hodnota fraktální dimenze vyšší. Lze tak srovnávat nejenom stav různých krajin, ale i míru přirozenosti tříd krajinného pokryvu.

Tvar plošky je poměrně složitě vyjádřen také např. **mírou linearity**  $LN$ , jejíž podstata vychází z „kostry“ plošky, která nabývá hodnot od 0 pro čtverec k 1 pro lineární útvary o šíři 1 pixel. „Kostra“ plochy je středová linie o šíři 1-2 pixelů nabývajících hodnot počtu pixelů od středu ke kraji plošky. Potom hodnota indexu linearity každé plošky je

$$LN = \frac{1}{S} \left( \frac{S}{(2b-r)^2} - 1 \right), \quad (11)$$

kde  $S$  je plocha (v pixelech),  $b$  je maximální hodnota na „kostře“ a  $r$  nabývá hodnot 0 pro šíři 2 pixely a 1 pro šíři 1 pixel v maximu „kostry“.

Významnou složkou prostorové heterogenity je fragmentovanost. Lze ji hodnotit v lokálním nebo celkovém kontextu pomocí **indexu lokální fragmentace**:

$$F = \frac{n-1}{c-1}, \quad (12)$$

kde  $n$  je počet přítomných tříd a  $c$  počet hodnocených pixelů rastrové mapy (obvykle 3×3 pixely).

V celkovém kontextu lze fragmentovanost vyjádřit tzv. **indexem sdělnosti**, jehož hodnota klesá s celistvostí a vyrovnaností větších ploch:

$$C = 2n \log n + \sum_i \sum_j (P_{ij} \log P_{ij}), \quad (13)$$

kde  $P_{ij}$  je relativní zastoupení společných obvodů sousedících tříd  $i$  a  $j$  (tedy četnost jejich hranic, ekotonů) z celkového počtu  $n$  tříd.

Kromě indexů vyjadřujících celkový charakter pokryvu potřebujeme způsob, jak zachytit prostorové vazby mezi jednotlivými ploškami. K tomu slouží **index blízkosti** (proximity) počítaný pro každou plošku z ploch a vzdáleností plošek ležících v určitém okruhu. Pak nabývá hodnot

$$PX = \sum_k \frac{S_k}{v_k}, \quad (14)$$

kde  $S_k$  je plocha a  $v_k$  vzdálenost  $k$ -té plošky. Indexy linearity a proximity zatím nenacházejí širšího uplatnění.

Vedle metrických ukazatelů krajiny lze na základě výzkumu krajinného pokryvu určit rovněž ekologickou stabilitu území. Porovnáním hodnot ekologické stability krajiny v jednotlivých časových řadách můžeme sledovat trend změn v čase. Možnosti kvantitativní analýzy a indexy v této oblasti shrnuje dizertační práce [31].

## 2.3 Případové studie a kvalifikační práce

Cílem této podkapitoly je uvést příklady některých projektů, které probíhají či proběhly na území České republiky. Získáme tak představu o tematickém zaměření automatické klasifikace dat z DPZ, a tedy hlavně o jejím využití jak pro účely praxe, tak i vědeckého zkoumání.

### 2.3.1 UKÁZKA POVAHY NĚKTERÝCH PROJEKTŮ

Jedním z významných projektů je inventarizace krajiny CzechTerra, multizdrojové celorepublikové statistické šetření, které kombinuje analýzu leteckých snímků a pozemní šetření. Rozsáhlý soubor dat získávaných v rámci projektu CzechTerra skýtá velké možnosti různých, dosud často netradičních pohledů nejen na lesní ekosystémy, ale i na zeleň mimo les a na krajinu jako celek. Šetření na lokalitě probíhá cestou klasifikace leteckých snímků a má za cíl zjistit rozlohu územních kategorií a typů pokryvu. Na základě kvantifikovaných rozloh lze vypočítat základní krajinné metriky (např. heterogenitu pokryvu, fragmentaci, délky okrajů apod.) a umožnit hodnocení zastoupení jednotlivých typů pokryvu, jejich strukturu, fragmentaci a konektivitu pomocí standardních statistických metod. Výsledky inventarizace

krajiny a zejména údaje z opakovaných inventarizací mohou být využívány pro potřeby strategického plánování a ochrany krajiny a mezinárodního reportingu. [41] Webové stránky projektu poskytují velké množství informací o zpracování, průběhu a výsledcích projektu.

Změnám využívání krajiny se věnuje výzkum na Oddělení ekologie krajiny a Oddělení aplikací GIS brněnské pobočky Výzkumného ústavu Silva Taroucy pro krajinu a okrasné zahradnictví. Webová prezentace tohoto tématu informuje jednak o možných mapových zdrojích, které se při výzkumu změn využívání krajiny používají, jednak i o metodách, resp. nejrůznějších příkladech analýz. Rovněž lze nalézt informace o projektech a dílčích výsledcích. Pro mnohé může být velkým lákadlem mapový server, který funguje nejen jako webová prohlížečka, ale lze si jej načíst také i ve formátu wms. V neposlední řadě tu najdete i odkazy na stránky zabývajícími se podobnými tématy. Změny krajiny jsou zkoumány v rámci výzkumného záměru MSM 6293359101 Výzkum zdrojů a indikátorů biodiverzity v kulturní krajině v kontextu dynamiky její fragmentace, který byl zahájen v roce 2005 a měl být ukončen v roce 2011. [43] Pro tuto diplomovou práci je webová prezentace toho projektu cenná jako souhrn odkazů na další odborné články.

V oboru dálkového průzkumu Země v podmínkách obchodu je v České republice významná firma GISAT. Hlavním cílem GISATu je nabídnout svým zákazníkům kompletní, inovativní, dostupné a kvalitní geoinformační služby založené na moderní technologii dálkového průzkumu Země. GISAT poskytuje svým zákazníkům kompletní portfolio služeb, od distribuce družicových dat a geoinformačních programů přes digitální zpracování družicových či leteckých snímků až po tvorbu geoinformačních systémů. Zákazníkům jsou tak poskytovány ucelené informační podklady a analytické výstupy pro monitoring a efektivní rozhodování o využívání přírodních či ekonomických zdrojů v krajině. Tato firma organizuje různé semináře a projekty. Například minulý rok proběhl v GISATu seminář eCognition day 2011. GISAT představil ukázky aplikací automatické klasifikace na různých typech dat DPZ. Prezentovány byly ukázky klasifikace sněhové pokrývky, Land Cover/Land Use, klasifikace zemědělských ploch nebo mapování krajinných prvků na datech s velmi vysokým rozlišením. Součástí tematické prezentace byla i živá ukázka klasifikace s využitím řešení v prostředí eCognition Architect a také dávkové zpracování dat pomocí eCognition Server. [17]

Svým pojetím je zajímavý projekt VaV MŠMT Kačina 2006–2011 neboli Implementace opatření Evropské úmluvy o krajině v intenzivně zemědělsky využívaných oblastech nesoucích stopy historických krajinářských úprav (pilotní studie Nové Dvory – Kačina). Předmětem řešení projektu je vypracování strategie a efektivních postupů k zabezpečení

trvale udržitelného rozvoje krajiny, respektujícího jak její hospodářský potenciál, tak i ochranu a rozvoj přírodních a kulturně-historických hodnot krajiny. [44] Webová prezentace tohoto projektu je velice kvalitní a co do množství informací velice výživná. V tomto projektu jsou letecké snímky sice využity, ale zpracovatelé se více opírají o vyhodnocení vývoje krajinné struktury na základě historických map a plánů, identifikují hospodářské využití krajiny, přírodní a kulturní hodnoty, zasazují činnosti významných osobností a dalších subjektů do širšího společenského a dobového kontextu. Tento směr je jistě velice odlišný od podoby zpracování této diplomové práce, ale je zde uveden jako ukázka „analýzy změn v krajině nejen pomocí dat z DPZ“, neboť je analyzována krajina z hlubší historie.

Na úrovni vzdělávacích procesů je nakonec uveden například sylabus předmětu Analýza krajiny v GIS. Jedná se o předmět vyučovaný na Univerzitě Palackého v Olomouci na Katedře geoinformatiky), jenž byl inovován v rámci projektu FRVŠ 1482/2009/F1/a. Předmět přibližuje klasické a moderní přístupy v mapování a hodnocení změn krajinné struktury s využitím geoinformačních technologií. Studenti se postupně seznamují s používanými metodami a přístupy k mapování krajiny. Předmět se rovněž dotýká dostupných datových sad. Studenti se seznámí také se stanovením a interpretací krajinně-ekologických indexů. [2] K tomuto předmětu je vytvořena sada zajímavých výukových materiálů.

### **2.3.2 KVALIFIKAČNÍ PRÁCE**

Tématu obdobnému této diplomové práci se věnovalo velké množství jiných kvalifikačních prací, jež jsou volně k dispozici na internetu. Některými je vhodné se inspirovat. Lze také zjistit, co již o dané problematice psáno bylo, nebo naopak nebylo, a tak svůj text doplnit.

V mnohých z prací jsou zpracovávány a analyzovány snímky ze dvou časových období. Výjimkou je dizertační práce Moniky Mulkové [31], ve které bylo sledováno šest časových období, a diplomová práce Barbory Vostracké [42], kde bylo zkoumáno pět období. Nejčastějším tématem prací je samozřejmě zjišťování změn krajiny. Dalším příkladem zkoumání je sledování rozložení ploch zemědělských plodin, detekce antropogenních tvarů reliéfu, detekce těžebních tvarů reliéfu či antropogenních změn krajiny pod vlivem hornictví. V souhrnu lze říci, že nejčastější metodou klasifikace je klasifikace řízená nebo klasifikace vizuální interpretací za podpory databáze CORINE Land Cover. Data jsou obvykle zpracovávána programy PCI Geomatica a ArcGis.

První zmíněnou kvalifikační prací je dílo Tomáše Volka z roku 1993, které by mělo být i první ve smyslu sledování změn v krajině. Popisuje katastry obcí Šošůvka a Ostrov

u Macochy pro léta 1950, 1976 a 1990. Výsledky byly získány programem Orient a MicroStation [34]. Pro tuto diplomovou práci je zajímavý text Tomáše Hromádka [24], neboť autor analyzoval letecké snímky území Starých Jesenčan ze stejných časových období pomocí vizuální interpretace a jeho výsledky jsou velmi vhodné pro porovnání s výsledky automatické klasifikace v kapitole 4 a 5. Svou kvalitou zpracování je zajímavá již zmíněná diplomová práce Barbory Vostracké [42], která se ve svých analýzách zaměřuje na mapování změn zástavby. Využívá k tomu družicové i letecké snímky v propojení s daty ZABAGED a databází CORINE Land Cover. Metodicky autorka aplikuje jak automatickou klasifikaci a vizuální interpretaci, tak i vegetační indexy. Nakonec co do rozsahu i hloubky je pečlivě zpracována také již zmíněná dizertační práce Moniky Mulkové, jež je zaměřena na krajinu zasaženou hornictvím. Zajímavé je, že v historii jde autorka při zpracování leteckých snímků až do roku 1947. O dalších kvalifikačních pracích pojednává ve svých kapitolách [24] nebo [34], proto další texty již zde dále popsány nejsou.

### **2.3.3 SOFTWARE PRO DIGITÁLNÍ ZPRACOVÁNÍ OBRAZU**

Tato podkapitola náhledu na současný stav řešené problematiky je drobným přehledem softwarových nástrojů, které lze využít při analýze obrazových dat z DPZ. Informace o mnohých dalších nástrojích jsou obsaženy v disertační práci Mulkové [31].

Software lze klasifikovat na softwarové prostředky digitální fotogrammetrie (HELAVA, Z/I Imaging ImageStation, PhoTopol), nástroje zpracování také leteckých snímků (PCI Geomatica, ErdasImagine) a nástroje přímo pro výzkum změn v krajině a krajinného pokryvu (PCI Geomatica, AutoCAD Map 2000, ErdasImagine, IDRISI Selva, ArcGis 10, eCognition aj.). V následujícím textu následuje stručný popis vybraných nejvýznamnějších produktů.

PCI Geomatica dle [17] získala jedno z vedoucích postavení v oblasti software pro vyhodnocení a analýzu obrazových dat dálkového průzkumu Země. Program nabízí profesionální řešení zahrnující fotogrammetrické zpracování (ortorektifikace, blokové vyrovnání, tvorba DEM<sup>6</sup>, mozaikování) a vyhodnocení (obrazová analýza, klasifikace, interpretace) všech typů leteckých a družicových snímků.

IDRISI Selva je řešení integrovaného GIS a softwaru pro zpracování obrazu, jež poskytuje téměř 300 modulů pro analýzu a zobrazení digitálních prostorových informací. Jak také domovská stránka produktu [25] uvádí, IDRISI nabízí nejrozsáhlejší soubor nástrojů GIS a zpracování obrazu.

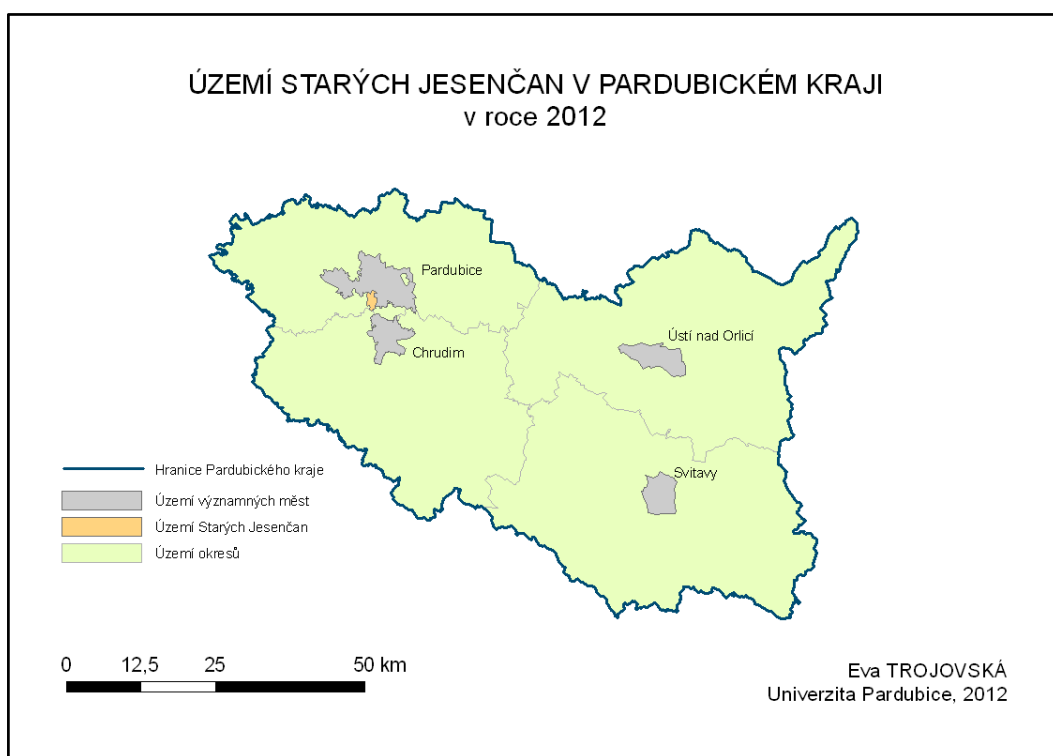
---

<sup>6</sup> DEM = Digital Elevation Model (digitální model terénu)

Skupina programových produktů eCognition má za cíl vývoj a poskytování software založených na moderních metodách rozpoznávání a klasifikace obrazových dat. Hlavním motivem snahy nabídnout nové řešení problému automatizovaného vyhodnocení obrazových dat se stala neustále se rozšiřující nabídka leteckých a družicových snímků (digitální letecké ortofoto, družicová data s velmi vysokým rozlišením, radarová družicová data) a dalších typů dat (např. laserscanning nebo hyperspektrální data). [17] Tento software podporuje objektově orientovanou klasifikaci.

### 3 CHARAKTERISTIKY ZÁJMOVÉHO ÚZEMÍ

Základní údaje o obci Staré Jesenčany lze získat ze serveru Obec ČR [32] a webových stránek Českého statistického úřadu [9]. Obec Staré Jesenčany leží v okrese Pardubice a Pardubickém kraji 229 m n. m. Tato obec sousedí s Třebosicemi na západě, Dřenicemi a Blatem na jihu, Dražkovicemi na východě a Pardubicemi na severu<sup>7</sup>. Od centra tohoto krajského města je obec vzdálena přibližně 6,5 km. V o málo větší vzdálenosti asi 7 km na jih od Starých Jesenčan leží také významné město Chrudim, viz obrázek 3. Tato obec k datu 31. 12. 2010 čítala 323 obyvatel. Její katastrální výměra je 3,71 km<sup>2</sup>. Do severní části katastrálního území zasahuje část veřejného mezinárodního letiště. Staré Jesenčany jsou také vlakovou stanicí na trase Pardubice-Chrudim.



Obrázek 3: Mapová kompozice lokalizace Starých Jesenčan

*Zdroj: vlastní zpracování*

#### 3.1 Geologie

Větší část Pardubického kraje leží dle [3] na mořských usazeninách z období křídý (druhohtory), na České křídové pánvi. Samotná Česká křídová pánev je tvořena usazeninami mělkého moře (slepence, pískovce, jílovce), které zalilo naše území v období svrchní křídý.

<sup>7</sup> Přesná poloha obce (konkrétně obecního úřadu) je 49°59'58.55"S zeměpisné šířky a 15°45'18.62"V zeměpisné délky.

Podrobné údaje o geologii území podává [7]. Katastrální území Starých Jesenčan se však rozkládá na geologickém podloží čtvrtohor, konkrétně z doby pleistocénu a holocénu. Starším podložím je písek a štěrk, ale Staré Jesenčany leží také významně na mladším písčito-hlinitém až hlinito-písčitém sedimentu. V okolí se nachází jemnozrnný smíšený sediment a karbonát sladkovodní, spraš a sprašová hlína.

### 3.2 Geomorfologie a pedologie

V geomorfologickém členění České republiky lze Staré Jesenčany nalézt na Východolabské tabuli, jež je částí celku Východočeské tabule, subprovincie Česká tabule, provincie Česká vysočina. Jak [6] popisuje, rovinný reliéf pardubického regionu je tvořen nivami a nad ně vystupujícími pleistocénními terasami. V regionu se uplatňují drobné tvary – mrtvá ramena, hrany teras, a na terasách i písčné přesypy. Reliéf má tedy charakter roviny s výškovou členitostí do 30 m, patří tak k nejplošším v České republice. Nejnižším bodem regionu je kóta asi 200 m u Týnce nad Labem, nejvyšším Kunětická hora s kótou 306 m.

V labské nivě převládá typická fluvizem (typu vega<sup>8</sup>), která má nápadně červený odstín, daný splachy z podkrkonošského permu. Na rozsáhlých štěrkopísčích se vyvinuly chudé arenickékambizemě až kambizemní podzoly, na navátých písčích málo vyvinuté půdy typu kyselých rankerů. V plochých, špatně drenovaných místech podél některých přítoků Labe se vyvinuly na karbonátových nivních sedimentech černice, víceméně oglejené<sup>9</sup>. [6]

### 3.3 Klimatické podmínky

Dle Quittovy klasifikace náleží Staré Jesenčany do oblasti W2, jež je součástí teplých oblastí v terminologii této klasifikace. Charakteristiky této oblasti W2 podrobně popisuje [38]. Počet letních dní převyšuje počet ledových dní. Průměrná lednová teplota je  $-2$  až  $-3$  °C. Průměrná červencová teplota oblasti W2 je 18-19 °C. Počet dní s mrazem je 100-110. Průměrný počet dní se srážkami 1 mm a více činí 90-100 a počet zatažených dní převyšuje téměř třikrát počet jasných dní.

Dle Köppenovy klasifikace, jež byla vypracována v roce 1900, patří zájmové území do klimatické oblasti Cfb neboli podtyp podnebí lesů mírného pásma. Její charakteristiky odpovídající jednotlivým znakům C, f a b jsou vysvětleny v [38].

---

<sup>8</sup> naplavená půda, jež je v nivě položena níže

<sup>9</sup> půdotvorný proces zamokřených oblastí



### 3.4 Hydrologie

Většina území Pardubického kraje náleží do povodí horního a středního Labe. Říční síť na území kraje prodělala dlouhý a složitý vývoj. Její rozložení bylo ovlivněno geologickou stavbou podloží, geomorfologickým vývojem i kolísáním klimatu ve čtvrtohorách. Labe protéká v délce 53 km pouze okresem Pardubice, kde tvoří osu Východolabské tabule. Z řeky odbočuje řada náhonů dříve používaných k zásobování dnes již ze značné části zrušených rybníků.

Čistota vody v tocích je stále problémem, i když v posledních letech dochází k částečnému zlepšení. Většina toků regionu má na svých středních a dolních tocích jakost vody ve 2. třídě kvality, více znečištěné je Labe (3. třídy jakosti) díky průmyslu v okolí. Přirozené vodní nádrže se v kraji prakticky nevyskytují. Jejich nedostatek byl nahrazen nejprve budováním rybníků, později údolních nádrží.

Většina území regionu má vhodné podmínky pro vytváření zásob podzemních vod. Chemické složení podzemních vod na většině území kraje je typu Ca-HCO<sub>3</sub>, jsou středně mineralizované (200-600mg/l), vhodné k využití po běžné úpravě. Kvartérní sedimenty Labe, Loučné a Chrudimky mají podzemní vody typu Ca-HCO<sub>3</sub>-HSO<sub>4</sub>, silněji mineralizované (600-900 mg/l), se zvýšeným obsahem Mn, Fe, NO<sub>3</sub>. Veškeré tyto i další informace lze nalézt na [21].

Východní částí katastrálního území Starých Jesenčan protéká Jesenčanský potok, jenž se vyčleňuje u Rosic od Labe. Jesenčanský potok nakonec ústí v Medlešicích do nádrže. Z Jesenčanského potoka je také voda odváděna do chovného rybníka (29 820 m<sup>2</sup>).

### 3.5 Vegetace

Vegetaci Pardubického kraje podrobně popisuje [14]. Katastrální území Starých Jesenčan leží převážně na orné půdě a ve východní části katastru se rozkládají louky.

V Pardubickém kraji považujeme za zcela obecné a všudypřítomné přibližně 300 druhů domácích a 60 nepůvodních. Okres Pardubice patří ve fyto geografickém členění do termofytika - do Východního Polabí. Jeho květena je spíše rozmanitá, rozpětí vegetačních stupňů převládá kolinní nad planárním (nížina), reliéf krajiny převládá plochý nad svažitém, podkladem jsou především půdy slinité i písčité, živné půdy převažují nad chudými, je to spíše krajina zemědělsky využívaná než lesnatá.

Střemchová jasenina se vyskytuje například v nivách potoků. Její stromové patro je tvořeno jasanem ztepilým, méně často převládá olše lepkavá a na sušších místech se objevuje lípa malolistá. V druhově bohatém keřovém patře převládá brslen evropský, střemcha obecná a mladé jasan. Pestré je bylinné patro, v němž najdeme např. bršlici kozí nohu, kostřavu obrovskou, kuklík městský, popenec břechťanovitý, plicník tmavý, čistec lesní a kopřivu dvoudomou.

Jilmová doubrava je vázána na zaplavované říční nivy právě v teplých nížinách a v regionu se vyskytuje právě především na Východolabské tabuli. V jejím stromovém patře převládá dub letní, častěji jasan. Na vlhčích místech přistupují olše lepkavá a vrby, na sušších místech habr a javor babyka. Keřové patro je druhově bohaté, typická je střemcha obecná. Bylinné patro je nejkrásnější na jaře, kdy zde kvetou dymnivka dutá, sasanka hajní, sasanka pryskyřníkovitá, orsej jarní, vzácněji česnek medvědí, sněženka podsněžník i řada dalších rostlin. V létě tvoří bylinné patro kopřiva dvoudomá a bršlice kozí noha.

Louky tvoří náhradní vegetaci po odstranění lesních porostů. Jejich charakter určují jednak stanovištní podmínky, jednak dlouhodobá činnost člověka.

Pro okres Pardubice je typické pěstování obilovin, podíl ploch s kukuřicí na zrno překračuje 51% krajského úhrnu. Z technických plodin je významné pěstování slunečnice na semeno (98% slunečnice zaseté v kraji). Málo jsou zastoupeny pícniny na orné půdě, brambory a luskoviny. Na okres připadají v rámci kraje dvě třetiny osevních ploch zeleniny. Ze všech okresů v kraji měl v roce 2010 pardubický okres nejvyšší podíl orné půdy bez sklizně. [1]

### **3.6 Fauna**

Publikace [14] se také fauně věnuje dopodrobna. V pardubickém regionu nalezneme bohaté spektrum bezobratlých živočichů. Relativně dobře je známa fauna vážek. Rybníky jsou stanovišti některých vodních, mokřadních a rákosinných druhů obratlovců. Na lužní porosty je vázána řada evropsky chráněných a ohrožených druhů bezobratlých živočichů. Mezi nejvýznamnější patří motýli, jejichž druhové spektrum je v lužním společenstvu bohaté (bělopásek topolový, babočka osiková, babočka jilmová). Na sušších stanovištích lze nalézt skokana štíhlého, lejska bělokrkého, slavíka obecného a v blízkosti vod užovku obojkovou. Pro louky je typickým, i když nepočetným druhem strnad luční, Letiště je hnízdní kolonií havrana polního.

Značnou část regionu pokrývají stanoviště zemědělsky využívaná, vzniklá dlouhodobou hospodářskou činností člověka. Pro polní kultury jsou typickými např. koroptev polní, skřivan polní, bažant obecný, hraboš polní nebo křeček polní. Na lukách Pardubického kraje je možné se také setkat se zářednicí jedovatou.

### 3.7 Historie obce

Historie obce Staré Jesenčany má počátek již v době kamenné, bronzové a železné. Z doby husitské pochází nálezný hrnek z nepálené hlíny se stříbrnými husitskými penízky, z doby Karla IV. cínový džbán s groši.

Jméno obce pochází pravděpodobně po předku, zakladateli, nebo dle polohy osady. Ta byla založena v tzv. jesénkách<sup>10</sup> (jesínkách). Tím by se vysvětloval i tvar Jesínčany z roku 1654. Původně byla obec nákolní osadou Slovanů na vodní ploše. Později, po rozšíření počtu obyvatel, byla tzv. okrouhlicí, vznikající seskupením staveb kolem společné návsi.

První písemná historická zmínka o Jesenčanech pochází z roku 1384, i když je možné, že mohla být i dřívějšího data. Původní archiválie se nedochovaly, protože je zničil požár pardubického muzea, kde byly uchovány.

Z dalších písemných zpráv vyplývá, že obec Jesenčany zdědil po smrti Arnošta ze Staré na Bydžovsku roku 1340 jeho nejstarší syn, pozdější arcibiskup pražský Arnošt z Pardubic. Od roku 1493 byla obec v majetku pánů z Pernštýna, kterým král obnovil též právo k výplatě Pardubic, Dražkovic, Mikulovic a dalších obcí v okolí.

Obec Jesničany (dle původního názvu) se skládala ze dvou osad - Starých Jesničan a Nových Jesničan. Nové Jesničany se rozrostly na počet obyvatel 1100 a z tohoto důvodu z iniciativy Starých Jesničan došlo v roce 1920 k rozluce. Pojmenování obce na Jesenčany vzniklo na popud profesora češtiny na chrudimském gymnasiu, místního rodáka Jana Markalouse. Upozornil na skutečnost, že jméno obce je germanismus (Jesnitschan), a proto byl zvolen název český – Jesenčany. Nové Jesenčany jsou nyní součástí Pardubic.

Již v roce 1860 se v Jesenčanech provozovalo pod vedením vlasteneckého faráře Theobalda Bulíčka z Třebosic ochotnické divadlo, které však po jeho smrti v roce 1866 zaniklo a nové bylo v činnosti až v roce 1920.

Tyto informace o historii Starých Jesničan lze nalézt na webových stránkách obce [35].

---

<sup>10</sup> jesen = strom jasan

## 4 KLASIFIKACE OBRAZU A KVANTIFIKACE PLOCH PRO JEDNOTLIVÉ ČASOVÉ HORIZONTY

### 4.1 Příprava distančních dat pro jejich zpracování

#### 4.1.1 PŘÍPRAVA LETECKÝCH SNÍMKŮ

V této práci jsou nejprve ve smyslu automatické klasifikace zpracovány letecké snímky. Data byla poskytnuta firmou GEODIS. Jedná se o dvě množiny ortofot z let 2003 a 2008. Snímky z roku 2003 tvoří mozaiku ze čtyř snímků ve formátu JPEG spolu s asociovaným souborem \*.jgw, obsahujícím informace o geokódování snímku. Snímky mají rozlišení 1:5 000 a jsou georeferencovány v souřadném systému WGS 84 UTM Zone 33N. Data roku 2008 mají podobné vlastnosti, ale jsou v počtu dvaceti menších snímků. Na samotné zpracování zájmové oblasti jich stačilo pouze jedenáct.

Kromě těchto dat bylo využito vrstev z WMS služeb ZABAGED (Základní báze geografických dat), Základní mapy ČR 1:10 000 či WMS služby Pardubického kraje. Dalším podpůrným zdroje je databáze CORINE.

Hlavní zpracování leteckých snímků bylo provedeno v programu ArcGIS 10. Nejdříve bylo třeba sloučit menší snímky do jednoho rastrového datasetu, a to pomocí funkce *Mosaic to new raster*. Tento byl následně ořezán pomocí funkce *Clip* na základě polygonové vrstvy vymezující katastrální území Starých Jesenčan. U těchto snímků nebylo třeba provádět žádné korekce, neboť byly pořízeny za bezoblačného počasí ve vegetačním období a žádoucím způsobem rektifikovány. Katastrální území Starých Jesenčan v roce 2003 a 2008 zobrazují obrázky přílohy A.

#### 4.1.2 PŘÍPRAVA DRUŽICOVÝCH SNÍMKŮ

Použití družicových snímků pro automatickou klasifikaci přináší mnoho zajímavých možností jak zkoumat zemský povrch. Je to zejména možnost kombinace spektrálních pásem a využití infračerveného pásma spektra pro sledování vegetace. Úspěšnost automatické klasifikace se ale odvíjí od dodaných dat, tedy i od možností konkrétní družice. Pro sledování změn krajiny zájmové území vzhledem k jeho rozloze by bylo nejvhodnější pracovat se snímky družice QuickBird (rozlišení až 60 cm) nebo IKONOS (rozlišení až 80 cm), ale tato data jsou velmi drahá. Proto byl dále digitálně zpracováván obraz z družice Landsat 7 ETM+, jejíž snímky jsou zdarma k dispozici každému uživateli na internetu.

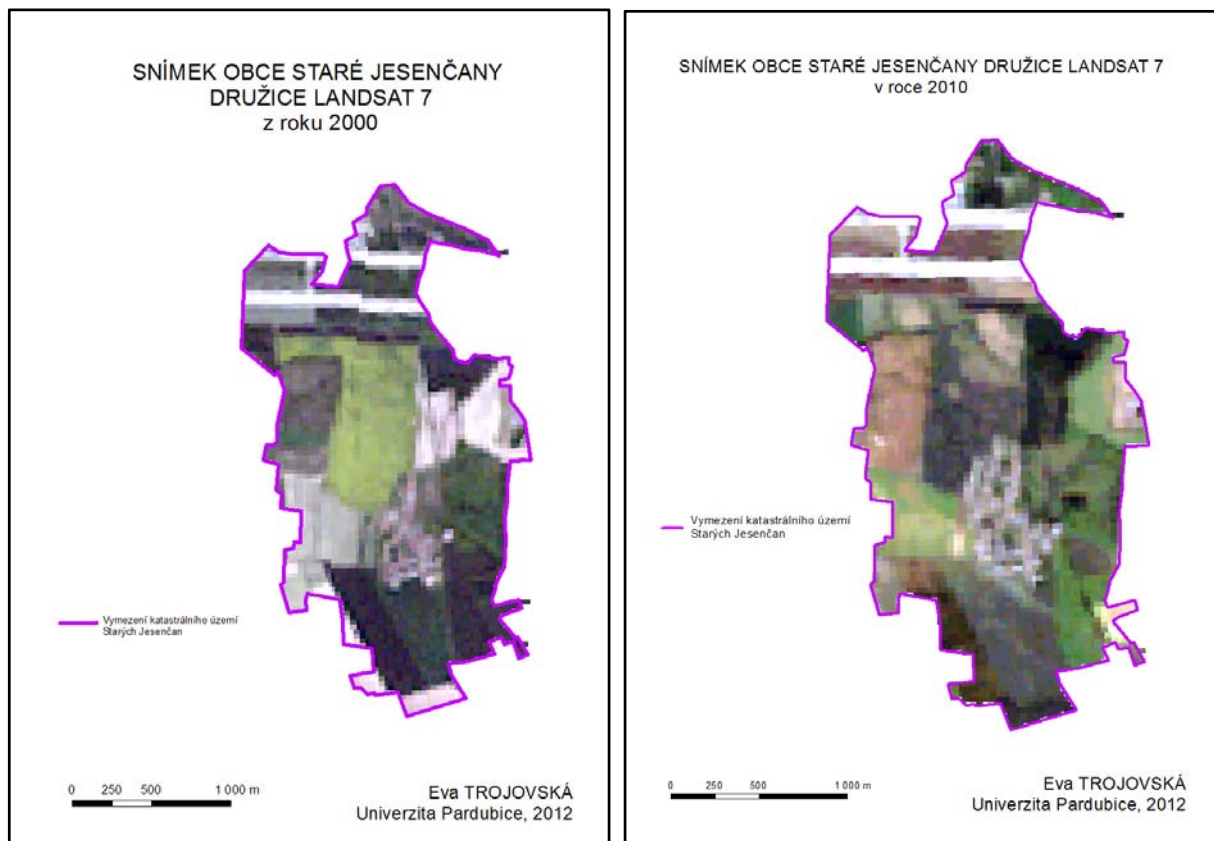
V roce 2008 *Department of the Interior* představil svůj plán zveřejnit družicové snímky Landsat a následně *U. S. Geological Survey* (USGS) a *National Aeronautics and Space Administration* (NASA) se k tomuto plánu přidaly a byl tak vytvořen *Global Land Survey* (GLS), zahrnující snímky ze sedmdesátých a devadesátých let, z roku 2000, 2005 a 2010 z vegetačního období za minimální oblačnosti. V roce 2010 společnost ESRI zpřístupnila ArcGIS Server 10, aby zjednodušila správu snímků a zrychlila přístup k nim přes internet. O rok později společnost ESRI vytvořila webovou službu *ChangeMatters*, jež dovoluje prohlížet uživatelům multispektrální i multitemporální GLS Landsat snímky. Podrobnosti z historie, technické údaje a další zajímavé informace o tomto projektu jsou popsány ve článku [18].

V této diplomové práci zmíněné webové aplikace využito nebylo, ale přímo byl připojen GIS Server<sup>11</sup> v software ArcGIS Desktop 10. Přístup k těmto družicovým snímkům je vskutku jednoduchý a celkem rychlý, ale tato data mají pro následné zpracování velmi nevýhodnou vlastnost, a to své nízké rozlišení, jež je v případě obrazu v přirozených barvách 30 m.

Předzpracování vybraných snímků sestávalo z několika kroků, totožných pro snímky v přirozených barvách z období 2000 a 2010. Nejdříve byla vložena do nově připraveného ArcMap dokumentu vrstva s hranicí Starých Jesenčan v daném souřadném systému WGS 84 a jakmile byla do dokumentu připojena i vrstva ze vzdáleného serveru s družicovými snímky, automaticky proběhla transformace souřadného systému, a tak nebylo dále nutné provádět i vzhledem k rozlišení geometrické korekce. Stejně jako u leteckých snímků bylo třeba importované snímky ořezat dle hranic zájmového území, a to nástrojem *Clip*. Po aplikaci toho nástroje ale došlo ke zvýraznění obrazu. Snímky se tím staly vhodnějšími pro následné klasifikační zpracování, viz obrázek 4.

---

<sup>11</sup> <http://imagery.arcgisonline.com/arcgis/services>



**Obrázek 4: Družicové snímky Landsat 7 území Starých Jesenčan v roce 2000 a 2010 (zleva)**

*Zdroj: vlastní zpracování*

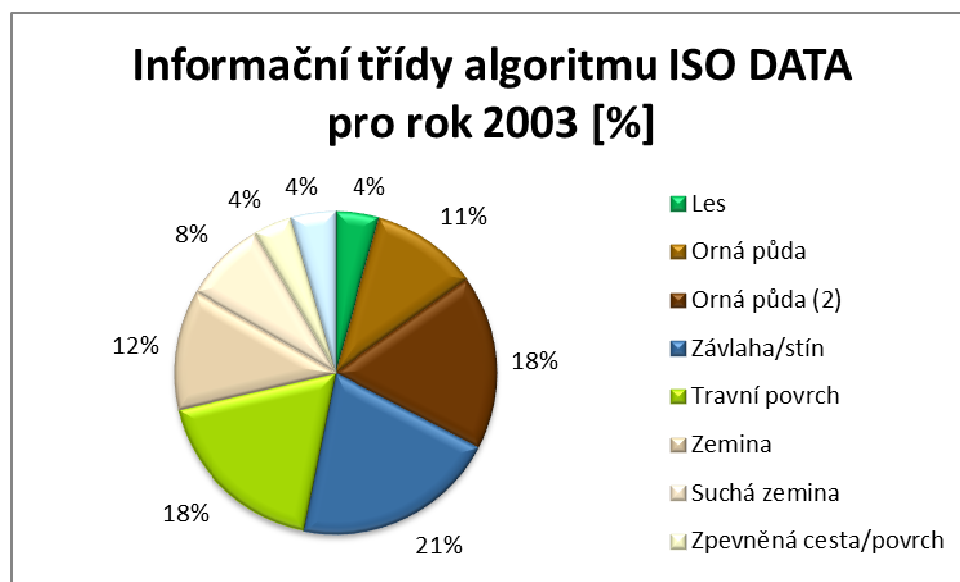
Pro klasifikaci obrazu bylo využito funkcí, které nabízí program ArcGIS. V dalších podkapitolách je věnována pozornost ISODATA klasifikátoru a klasifikátoru maximální pravděpodobnosti. *Image Classification Toolbar* nabízí také metodu hlavních komponent PCA a určení pravděpodobnosti tříd.

## **4.2 ISODATA klasifikátor aplikovaný na letecké snímky**

Tento klasifikátor je zástupcem neřízené klasifikace. Zjednodušeně řečeno je zvolen předpokládaný počet tříd a vytvořeným třídám po klasifikaci je určen informační význam. Dle podpůrných dat byl zvolen počet 9, počet iterací byl dán 24 a práh konvergence byl 0,95. Použití tohoto klasifikátoru byl zvolen spíše pro informativní charakter toho, co lze od jiných metod klasifikace přibližně očekávat. Samotný ISODATA klasifikátor je pro klasifikaci leteckých snímků nevýhodný. Výsledek klasifikace pro oba roky je zobrazen v příloze B. Je zřejmě vidět, že plochy jsou značně heterogenní. Na klasifikovaný rastr byla využita funkce *Majority filter*, ale významně ke zlepšení nedošlo. V kombinaci s vizuální interpretací snímků byly získány následující informační třídy: *Les*, *Orná půda (1)*, *Orná půda (2)*, *Závlaha nebo*


*stín, Travní povrch, Zemina, Suchá zemina, Zpevněná cesta nebo povrch a Zástavba*. Nejedná se ani o Land Use ani Land Cover. Význam těchto tříd spíše vychází z charakteru povrchu. Tyto informační třídy v následujícím klasifikování pomocí řízené klasifikace využity nebyly, pouze lze předpokládat, že některé povrchy si budou velice podobné a bude docházet k značným chybám. Například je možno předpokládat blízkost povrchu rybníku a orné půdy, či orné půdy a travního porostu. Také lze díky výsledku této klasifikace dospět k tomu, že v následující automatické řízené klasifikaci bude vhodné vynechat návrh třídy pro potok či železnici. Prostor, jež ze znalosti dalších dat tyto dva elementy zabírají, je v rastru reprezentován spíše charakteristickou texturou než shlukem blízkých DN hodnot. Není možné tyto informační třídy pomocí řízené či neřízené klasifikace určit. Zde by se spíše naskýkala možnost uplatnění objektové klasifikace.

Graf 1 a graf 2 zachycuje pro ilustraci procentuální zastoupení charakterizovaných informačních tříd v jednotlivých letech.



**Graf 1: Informační třídy algoritmu ISODATA pro rok 2003**

*Zdroj: vlastní zpracování*



**Graf 2: Informační třídy algoritmu ISODATA pro rok 2008**

*Zdroj: vlastní zpracování*

### **4.3 Klasifikátor maximální pravděpodobnosti aplikovaný na letecké snímky**

Tento klasifikátor je jako jediný z možností řízené klasifikace implementován v programu ArcGIS Desktop a jeho toolboxu *Image Classification*. Úspěšnost klasifikátoru maximální pravděpodobnosti (*Maximum Likelihood Classification*) závisí na sestavení trénovacích ploch. Postupně byly vytvářeny trénovací plochy, přesněji spektrální třídy, pro tyto informační třídy: *Zástavba*, *Orná půda*, *Travní porost*, *Rybník*, *Komunikace* a *Stín/Les*. Každá informační třída je klasifikována pomocí několika spektrálních tříd. Postup zpracování spočíval ve využití *Training Sample Manageru* a funkce *Merge*. Na výsledek klasifikace byl pro lepší výsledky využit modální filtr *Majority filter*. Přestože do klasifikace nebyly zařazeny třídy pro železnici a potok, lze na klasifikovaném obrázku vysledovat polohu a tvar těchto elementů. Je to právě textura, která je pro ně nějakým způsobem charakteristická a odlišná od okolního prostoru.

Třída *Zástavba* je velice heterogenní, proto jsou očekávány horší výsledky při klasifikaci. Mezi zástavbu je zařazen i kus letiště v severní části katastrálního území. Tato třída velmi souvisí s třídou *komunikace*. Lepších výsledků klasifikace zástavby by dávalo použití multispektrálního snímku a také využití vegetačních indexů.

Třída *Orná půda* bude mít na daném území jistě největší zastoupení. Problémem je, že jednotlivá pole jsou různorodá, a tak dochází k mísení s jinými třídami, protože je obtížné jednoznačně určit střední hodnotu spektrální charakteristiky této třídy.




Mnohdy podobnou třídou třídě *Orná půda* je *Travní porost*. Na základě snímku z roku 2003 je poněkud nejednoznačné přiřazení travního porostu či pole jisté ploše.

Třída *Rybník* se v klasifikaci prolíná do třídy *Orná půda*. Plocha odpovídající rybníku ve východní části katastrálního území je ale dobře vymežitelná.

Co se týče třídy *Komunikace*, jedná se o všechny zpevněné cesty či silnice a do jisté míry i nezpevněné cesty v závislosti na citlivosti klasifikace. Tato třída by měla být téměř jednoznačně určena.

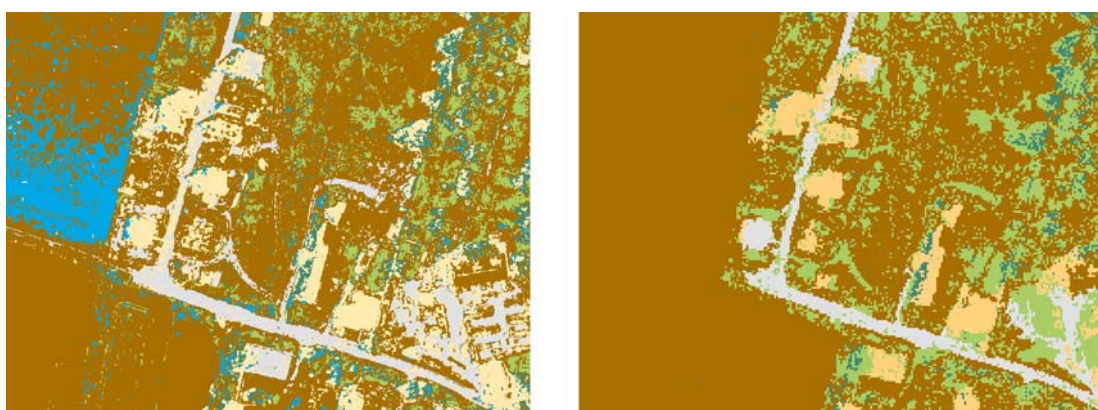
Problém činí klasifikace lesů, stromů či keřů. V tomto případě se spektrální charakteristika dřevin ve vegetačním období mísí s charakteristikou travního porostu. Pokud je cílem sledovat změny v krajině kvantitativně vyjádřené například v hektarech, klasifikace samotných stromů byla nahrazena klasifikací stínů, jež stromy vrhají. Samozřejmě zde dochází k odchylkám především pro započítání stínů budov, ale tento nadbytek zjednodušeně může vykompenzovat menší plocha stínů stromů po klasifikaci. Slunce při pořizování snímku v roce 2008 stojí na východě, ale porovnáním obou snímků se zdá, že je stejně vysoko jako na západě u snímku 2003. U snímku z roku 2008 po klasifikaci je zastoupení méně směrodatné, protože třídu *Travní porost* a *Orná půda* tvoří mnohdy rozsáhlé spojité polygony s mnoha vrcholy a nelze plochy stromů lépe přiblížit. Z podobného důvodu jsem u snímku z roku 2008 zpřesňovala třídu *Zástavba*. Mnoho střech se spektrálně krylo s vlastnostmi jiné třídy jako v případě lesů, proto nezbylo nic jiného než zatřídit do zástavby stín daného domu. Tento problém vzniká proto, že třída *Orná půda* je značně heterogenní jak lze jediným pohledem na snímek vysledovat.

Výsledek klasifikace je zobrazen v příloze C. Zřejmě ale nedává přesné výsledky, proto bylo třeba s klasifikovaným snímkem dále pracovat. Nejdříve byla rastrová vrstva převedena do polygonové a k atributové tabulce bylo přidáno pole *Skutečnost*. Poté byl pročištěn klasifikovaný snímek od chyb způsobem spočívajícím ve spojování polygonů jedné třídy pomocí funkce *Merge* a zařazování v případě chyb způsobem vyplnění atributu *Skutečnost*. Nakonec byly vytvořeny díky selekci dle hodnoty atributu jednotlivé soubory typu *shapefile*. Výřez z klasifikace v porovnání s opravenou verzí zobrazuje obrázek 5 a obrázek 6.



**Obrázek 5: Klasifikace obrazu z roku 2003 před a po úpravě (zleva)**

*Zdroj: vlastní zpracování*



**Obrázek 6: Klasifikace obrazu z roku 2008 před a po úpravě (zleva)**

*Zdroj: vlastní zpracování*

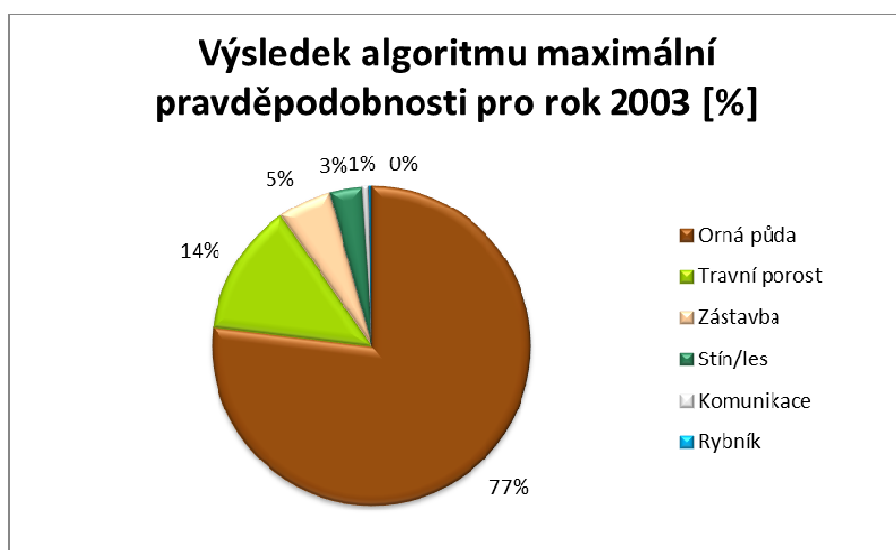
Elementy zástavby mají přesto „roztřepené“ hranice, ale byly zpracovávány skutečně pouze polygony vytvořené z rastrové klasifikace. Polygony, kterým nebylo vyplněno atributové pole *Skutecnost*, byly nakonec zařazeny do třídy *Travní porost*. Klasifikace snímků po těchto úpravách je zobrazena v příloze D. Jakmile byly získány jednotlivé polygonové vrstvy, snadno lze pomocí funkce *Calculate Area* u georeferencovaného snímku určit plochu odpovídající jednotlivým informačním třídám.

Přehledové statistiky a shrnutí v tabulkách či grafech zachycuje po řadě tabulka 1, graf 3, tabulka 2 a graf 4.

**Tabulka 1: Výměra plochy a procentuální zastoupení informačních tříd snímku z roku 2003**

Název informační třídy	Výměra plochy [ha]	Poměrné zastoupení [%]
Zástavba	19,9948	5,40
Orná půda	284,2529	76,75
Travní porost	49,5978	13,39
Stín/les	12,3006	3,32
Rybník	1,2823	0,35
Komunikace	2,9364	0,79

*Zdroj: vlastní zpracování*




**Graf 3: Výsledek algoritmu maximální pravděpodobnosti pro rok 2003**

*Zdroj: vlastní zpracování*

**Tabulka 2: Výměra plochy a procentuální zastoupení informačních tříd snímku z roku 2008**

Název informační třídy	Výměra plochy [ha]	Poměrné zastoupení [%]
Zástavba	20,5372	5,55
Orná půda	253,5227	68,51
Travní porost	82,4700	22,29
Stín/les	8,6299	2,33
Rybník	1,9286	0,52
Komunikace	2,9764	0,80

*Zdroj: vlastní zpracování*



**Graf 4: Výsledek algoritmu maximální pravděpodobnosti pro rok 2008**

*Zdroj: vlastní zpracování*

#### 4.3.1 ZHODNOCENÍ PŘESNOSTI KLASIFIKACE LETECKÝCH SNÍMKŮ

Jak bylo zmíněno v podkapitole 1.5.2, přesnost klasifikace lze kvantitativně stanovit například pomocí takzvané chybové matice. Z ní lze vypočítat řadu ukazatelů přesnosti, jež budou následovat řešení pro danou klasifikaci v ArcGIS.

Nejdříve byly v programu ArcGIS vygenerovány náhodně umístěné body na území Starých Jesenčan pomocí funkce *Random points* v počtu 100 a minimální vzdálenosti 25 m od sebe. Těmto bodům bylo v atributové tabulce přidáno pole „VALUE“ a následně každému z nich byla přiřazena skutečná referenční hodnota pro určení druhu povrchu. Pomocí funkce *Point to Raster* byly body nahrazeny pixely a pomocí nástroje *Raster Calculator* a funkce *Combine* v syntaxi `OutRas = Combine ([“KlasRaster”, ”BodyPovrch1”])` byly zjištěny rozdíly i shody mezi referenčními body a klasifikovaným snímkem. Výsledné chybové matice pro klasifikované letecké snímky jsou uvedeny v tabulce 3 a v tabulce 4.

**Tabulka 3: Chybová matice automatické klasifikace leteckého snímku z roku 2003**

		Referenční body						
		Zástavba	Orná půda	Rybník	Komunikace	Les/stín	Travní povrch	celkem
Body klasifikovaného snímku	Zástavba	8	1	0	3	0	0	12
	Orná půda	2	44	0	1	2	10	59
	Rybník	0	6	0	0	1	0	7
	Komunikace	0	1	0	0	0	0	1
	Les/stín	0	0	0	1	1	1	3
	Travní povrch	0	14	0	0	1	3	18
	celkem	10	66	0	5	5	14	100

Dle [12] lze určit ukazatele přesnosti následovně.

**Průměrná přesnost**  $AA_{03}$  je podíl součtu správně zařazených bodů (součtu hlavní diagonály) a počtu všech referenčních bodů.

$$AA_{03} = \frac{8 + 44 + 1 + 3}{100} = 0,56$$

**Chyba z opomenutí**  $EO_{03}$  je podíl součtu pixelů ve sloupci mimo hlavní diagonálu a počtu pixelů referenčních dat.

$$EO_{03Z} = \frac{2}{10} = 0,2, \quad EO_{03Op} = \frac{1+6+1+14}{66} = 0,33, \quad EO_{03K} = \frac{3+1+1}{5} = 1,$$

$$EO_{03L} = \frac{2+1+1}{5} = 0,8, \quad EO_{03Tp} = \frac{10+1}{14} \approx 0,79$$

**Chyba z nesprávného zařazení**  $ENZ_{03}$  je podíl součtu pixelů v řádku mimo hlavní diagonálu a počtu pixelů referenčních dat.

$$ENZ_{03Z} = \frac{1+3}{10} = 0,4, \quad ENZ_{03Op} = \frac{2+1+2+10}{66} \approx 0,38, \quad ENZ_{03K} = \frac{1}{5} = 0,2,$$

$$ENZ_{03L} = \frac{2}{5} = 0,4, \quad ENZ_{03Tp} = \frac{14+1}{14} \approx 1,07$$

**Přesnost z hlediska uživatele**  $PU_{03}$  je podíl počtu správně klasifikovaných pixelů a celkového počtu pixelů zařazených do třídy.

$$PU_{03Z} = \frac{8}{12} \approx 0,67, \quad PU_{03Op} = \frac{44}{59} \approx 0,75, \quad PU_{03R} = 0, \quad PU_{03K} = 0,$$

$$PU_{03L} = \frac{1}{3} = 0,33, \quad PU_{03Tp} = \frac{3}{18} \approx 0,17$$

**Přesnost z hlediska zpracovatele**  $PZ_{03}$  je podíl počtu správně klasifikovaných pixelů a počtu pixelů použitých pro testování dané třídy.

$$PZ_{03Z} = \frac{8}{10} = 0,8, \quad PZ_{03Op} = \frac{44}{66} \approx 0,67, \quad PZ_{03K} = 0, \quad PZ_{03L} = \frac{1}{5} = 0,2, \quad PZ_{03Tp} = \frac{3}{14} \approx 0,21$$

**Tabulka 4: Chybová matice automatické klasifikace leteckého snímku z roku 2008**

		Referenční body						
		Zástavba	Orná půda	Rybník	Komunikace	Les/stín	Travní povrch	celkem
Body klasifikovaného snímku	Zástavba	2	0	0	1	1	1	5
	Orná půda	4	52	0	0	3	15	74
	Rybník	0	9	1	0	0	0	10
	Komunikace	0	0	0	0	0	0	0
	Les/stín	1	0	0	0	2	0	3
	Travní povrch	0	2	0	0	0	6	8
	celkem	7	63	1	1	6	22	100

*Zdroj: vlastní zpracování*

Analogicky lze vypočítat dané ukazatele i pro tuto chybovou matici.

**Průměrná přesnost  $AA_{08}$**

$$AA_{08} = 0,63$$

**Chyba z opomenutí  $EO_{08}$**

$$EO_{08Z} \approx 0,71, EO_{08Op} \approx 0,17, EO_{08R} = 0, EO_{08K} = 1, EO_{08L} \approx 0,67, EO_{08Tp} \approx 0,73$$

**Chyba z nesprávného zařazení  $ENZ_{08}$**

$$ENZ_{08Z} \approx 0,43, ENZ_{08Op} \approx 0,35, ENZ_{08R} = 9, ENZ_{08K} = 0, ENZ_{08L} \approx 0,17, ENZ_{08Tp} \approx 0,09$$

**Chyba z hlediska uživatele  $PU_{08}$**

$$PU_{08Z} = 0,4, PU_{08Op} \approx 0,7, PU_{08R} = 0,1, PU_{08L} \approx 0,66, PU_{08Tp} = 0,75$$

**Chyba z hlediska zpracovatele  $PZ_{08}$**

$$PZ_{08Z} \approx 0,29, PZ_{08Op} \approx 0,83, PZ_{08R} = 1, PZ_{08K} = 0, PZ_{08L} \approx 0,33, PZ_{08Tp} \approx 0,27$$

Jak je vidět, oba výsledky automatické klasifikace nejsou příliš přesné, ale bližší informaci o přesnosti by také jistě podalo testování většího počtu referenčních bodů. Následující podkapitola zachycuje přesnost již upravené klasifikace s využitím jiných metod.

#### 4.4 Porovnání výsledků řízené automatické klasifikace a vizuální interpretace leteckých snímků

Tato práce není jediná, která se věnuje území Starých Jesenčan. V roce 2009 Tomáš Hromádko vytvořil svoji bakalářskou práci [24], ve které zpracovával toto území pomocí vizuální interpretace.

Vizuální interpretace je metoda manuální vektorizace snímku. Je tedy velmi náročná na čas a trpělivost, ale také zkušenost analytika. Na druhou stranu ovšem podává nejpřesnější výsledky. Je jisté, že výsledky automatické klasifikace budou méně směrodatné. Mnoho odchylek mohlo vzniknout méně vhodnou definicí trénovacích ploch či kvůli špatnému zařazení vytvořených polygonů. U obou metod je také riziko chybné interpretace povrchu. Tabulka 5 a 6 shrnuje kvantitativní rozdíly výstupů z obou kvalifikačních prací pro letecké snímky z let 2003 a 2008.

Největší rozdíly mezi oběma způsoby klasifikace vznikly u kategorií *Orná půda* a *Travní povrch*. Výsledky automatické klasifikace na základě výpočtu směrodatné odchylky lépe přiléhají pro rok 2008. Graficky je celkové porovnání zaznamenáno na grafu 5. Je zajímavé, že rozdíl mezi úrovněmi třídy *Les* není vzhledem k zjednodušení nahrazením lesa stínem příliš významný, a to nejvýše jedno procento.

**Tabulka 5: Porovnání výsledků klasifikace vizuální interpretací a klasifikátorem maximální pravděpodobnosti pro rok 2003**


Název informační třídy	Výměra plochy [ha]		$\Delta$ [ha]	Poměrné zastoupení [%]		$\Delta$ [%]
	Automatická klasifikace	Vizuální interpretace		Automatická klasifikace	Vizuální interpretace	
<b>Zástavba</b>	19,9948	20,0000	-0,0052	5,40	5,39	0,01
<b>Orná půda</b>	284,2529	262,0900	22,1629	76,75	70,59	6,16
<b>Travní porost</b> Sady a zahrady, louky pastviny a ostatní zeleň	49,5978	69,6700	-20,0722	13,39	18,77	-5,38
<b>Stín/les</b>	12,3006	11,7700	0,5306	3,32	3,17	0,15
<b>Rybník</b>	1,2823	1,8700	-0,5877	0,35	0,50	-0,15
<b>Komunikace</b> Silnice, nezpevněná cesta	2,9364	5,0200	-2,0836	0,79	1,35	-0,56
<b>Ostatní</b> Železnice	x	0,8500	-0,8500	x	0,23	-0,23

Zdroj: vlastní zpracování, [24]

**Tabulka 6: Porovnání výsledků klasifikace vizuální interpretací a klasifikátorem maximální pravděpodobnosti pro rok 2008**

Název informační třídy	Výměra plochy [ha]		$\Delta$ [ha]	Poměrné zastoupení [%]		$\Delta$ [%]
	Automatická klasifikace	Vizuální interpretace		Automatická klasifikace	Vizuální interpretace	
<b>Zástavba</b>	20,5372	21,2400	-0,7028	5,55	5,72	-0,17
<b>Orná půda</b>	253,5227	256,8800	-3,3573	68,51	69,19	-0,68
<b>Travní porost</b> Sady a zahrady, louky pastviny a ostatní zeleň	82,4700	73,0600	9,4100	22,29	19,68	2,61
<b>Stín/les</b>	8,6299	12,3200	-3,6901	2,33	3,32	-0,99
<b>Rybník</b>	1,9286	2,0700	-0,1414	0,52	0,56	-0,04
<b>Komunikace</b> Silnice, nezpevněná cesta	2,9764	5,04	-2,0636	0,80	1,36	-0,55
<b>Ostatní</b> Železnice	x	0,6600	-0,6600	x	0,18	-0,18

*Zdroj: vlastní zpracování, [24]*



**Graf 5: Porovnání výsledků klasifikace vizuální interpretací a klasifikátorem maximální pravděpodobnosti pro rok 2003 a 2008**

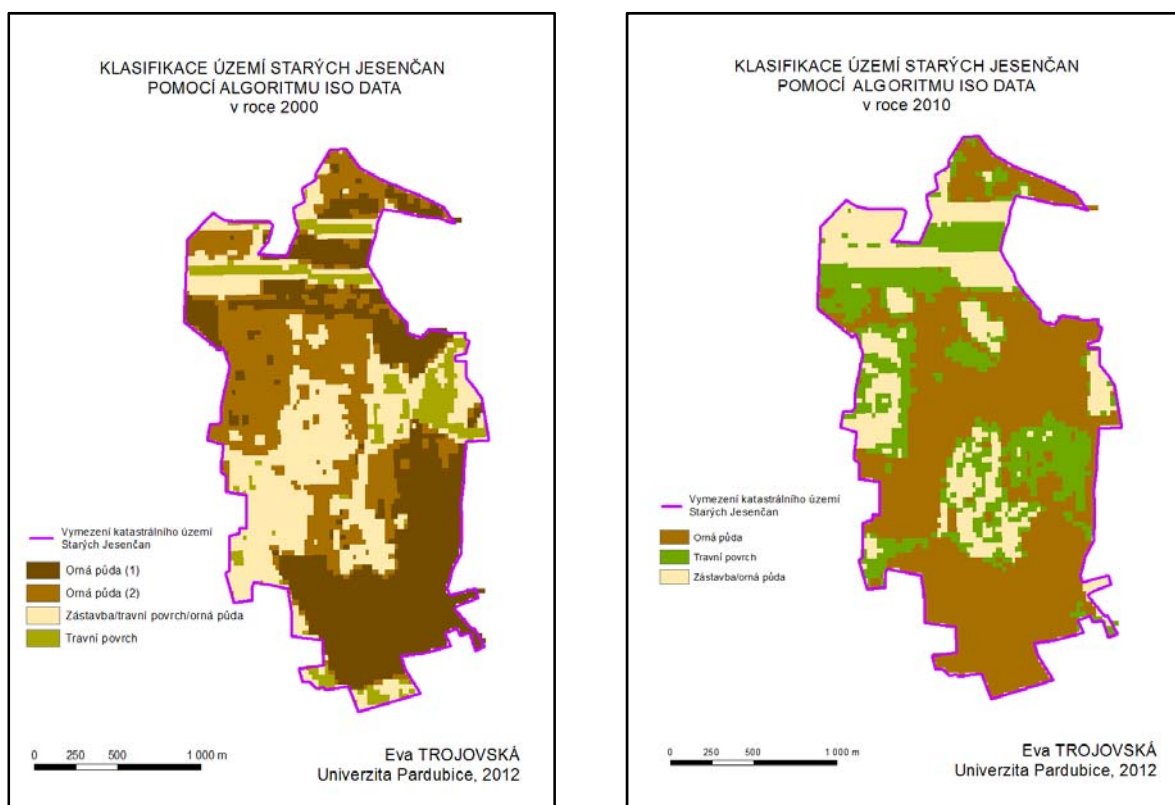
*Zdroj: vlastní zpracování*



## 4.5 Klasifikace družicových snímků



Pro klasifikaci družicových snímků byla nejprve zvolena data Landsat 7 z roku 2000 a 2010 v přirozených barvách.

Přístup ke klasifikaci je obdobný předchozímu. Nejprve byla rastrová data zkoumána pomocí ISODATA klasifikátoru s těmito parametry. Počet tříd byl navolen 4, počet iterací byl 10 a minimální počet pixelů v jedné třídě byl 6 pro oba roky. Nejdříve byl zkoušen větší počet tříd i iterací, ale klasifikace neproběhla. Výsledek klasifikace pomocí ISODATA klasifikátoru z roku 2000 a 2010 je na obrázku 7. Touto klasifikací pro rok 2000 byly spektrálním třídám přiřazeny informační třídy *Orná půda (1)*, *orná půda (2)*, *travní porost včetně zástavby obce* a *zástavbu* v severní části území. Klasifikací roku 2010 byly vytvořeny tyto tři třídy – *Orná půda*, *travní povrch* a *zástavba/orná půda*. Na klasifikované snímky byl aplikován *Majority Filter*. Kvantifikaci ploch v procentech zachycuje graf 6.



Obrázek 7: Klasifikace družicových snímků z roku 2000 a 2010 algoritmem ISODATA (zleva)

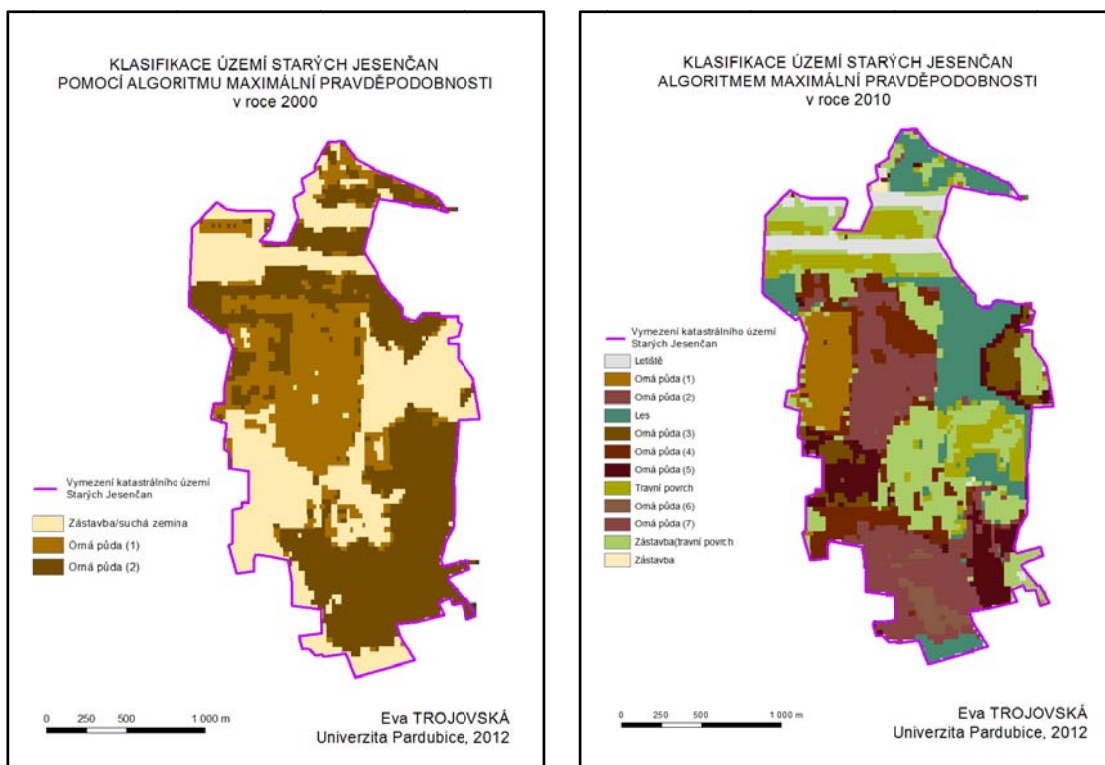
*Zdroj: vlastní zpracování*



**Graf 6: Grafy procentuelních zastoupení informačních tříd klasifikace ISODATA z let 2000 a 2010 (zleva)**


*Zdroj: vlastní zpracování*

V případě klasifikace maximální pravděpodobnosti byl postup také obdobný. Nejdříve byly vytvářeny trénovací plochy, které byly před klasifikací vhodným způsobem pomocí funkce *Merge* sloučeny. Výsledky klasifikace po několika způsobech sestavení trénovacích tříd ale nebyly uspokojivé, proto trénovací plochy dále slučovány nebyly, a tak bylo vytvořeno 12 trénovacích ploch. Výsledkem klasifikace byl rastr v počtu tří informačních tříd pro rok 2000 a rastr skutečně v počtu dvanácti tříd pro rok 2010, viz obrázek 8. Na oba snímky byl opět aplikován *Majority filter* s parametrem filtrace čtyř sousedních pixelů. Je obtížné na tato data použít automatickou klasifikaci pro dobrý výsledek, neboť lze skutečně očekávat obecně blízkost *Zástavba-pole* nebo *pole-travní povrch*. Graf 7 zachycuje opět výšečový graf procentuelního zastoupení vytvořených tříd, ale je zde uveden spíše pro ucelenost podání výsledků. Samotné výsledky pro analýzu změn v krajině nejsou již na první pohled na mapové kompozice příliš významné.



**Obrázek 8: Družicové snímky z let 2000 a 2010 klasifikované algoritmem maximální pravděpodobnosti (zleva)**

*Zdroj: vlastní zpracování*

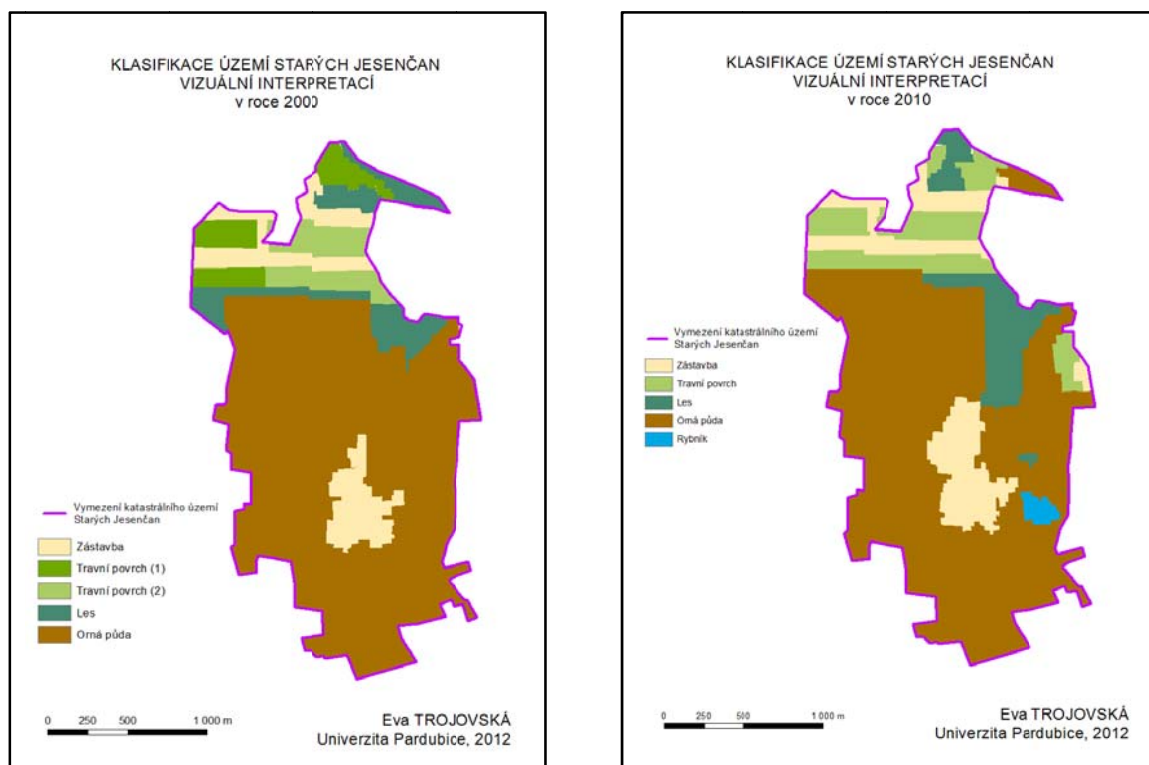


**Graf 7: Grafy procentuelních zastoupení informačních tříd klasifikátorem maximální pravděpodobnosti z let 2000 a 2010 (zleva)**

*Zdroj: vlastní zpracování*

Družicové snímky byly tedy ještě klasifikovány vizuální interpretací, omezenou na základní třídy *Travní povrch*, *Orná půda*, *Zástavba* a *Les*. Na snímku z roku 2010 byla ale ještě rozeznatelná třída *Rybník*. Samotnou automatickou klasifikaci i vizuální interpretaci


obou časových období a poměrné zastoupení těchto tříd z vizuální interpretace na území Starých Jesenčan zachycuje po řadě obrázků 9 a graf 8.



**Obrázek 9: Družicové snímky z roku 2000 a 2010 vizuální interpretací (zleva)**

*Zdroj: vlastní zpracování*

Pro vizuální interpretaci družicového snímku byl vhodnější snímek z roku 2010, na němž byly druhy povrchů krajiny lépe rozpoznatelné. V kapitole 5 jsou pro sledování změn v krajině významné výsledky vizuální interpretace. Ačkoli i ta vzhledem k nízkému rozlišení snímků může být velmi nepřesná, dává oproti automatické klasifikaci lepší výsledky.



**Graf 8: Grafy procentuelních zastoupení informačních tříd vizuální interpretací z let 2000 a 2010 (zleva)**

*Zdroj: vlastní zpracování*

Následující tabulka shrnuje všechny tři metody a vyjádření ploch po přepočtu z procent na hektary.

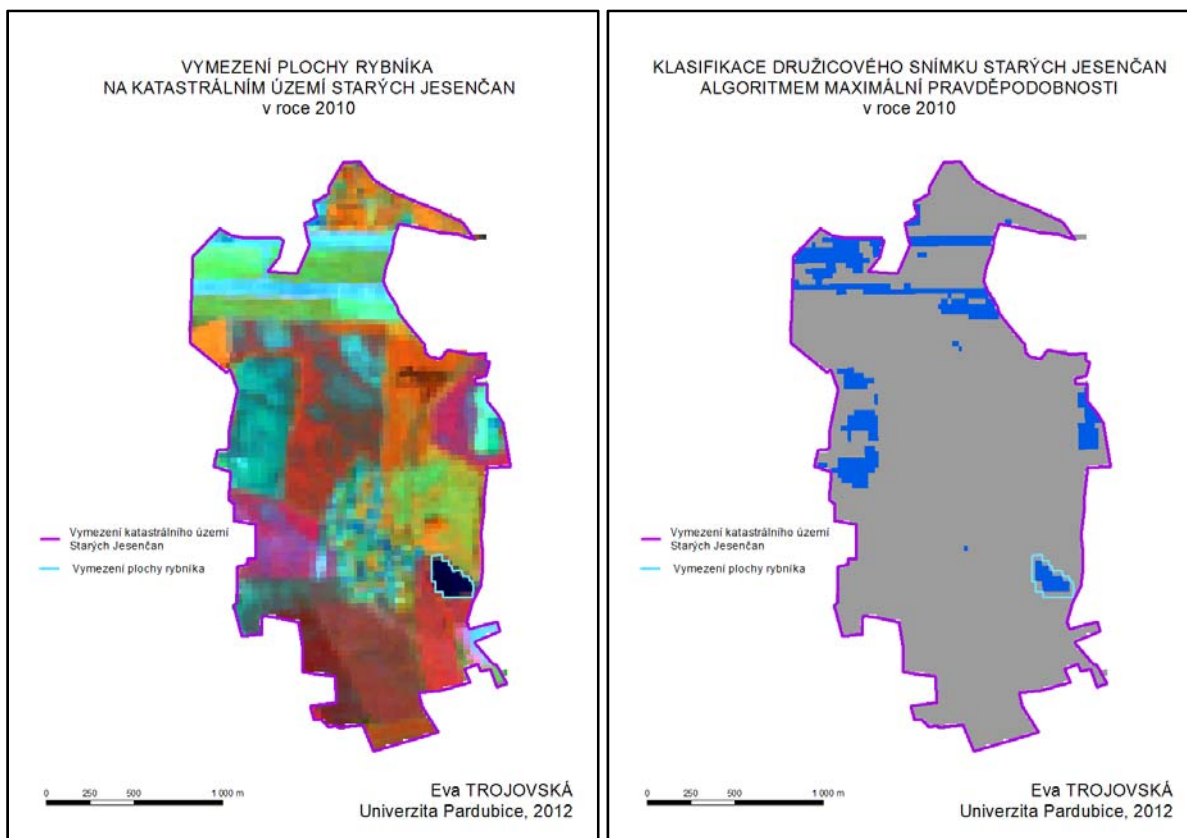
**Tabulka 7: Shrnutí výsledků různých metod klasifikace snímků z Landsat 7**

Název informační třídy	Rok 2000			Rok 2010		
	ISODATA	ML	vizuální interpretace	ISODATA	ML	vizuální interpretace
<b>Zástavba</b>	27,97	131,66	40,37	77,28	100,10	48,99
<b>Orná půda</b>	233,44	238,70	258,90	203,78	178,38	244,60
<b>Travní povrch</b>	108,95	×	40,60	89,31	33,93	40,78
<b>Stín/les</b>	×	×	30,5	×	57,95	32,44
<b>Rybník</b>	×	×	×	×	×	3,55

*Zdroj: vlastní zpracování*

#### **4.5.1 URČENÍ PLOCHY VODNÍ PLOCHY Z DAT DRUŽICE LANDSAT 7**

Z jisté znalosti o zájmovém území je vidno, že jeho součástí je chovný rybník, který ale automatickou klasifikací předchozími postupy dobře rozpoznán nebyl. Pro samotný účel zjišťování například plochy a umístění rybníka je výhodné použít kombinaci pásem multispektrálního snímku v pořadí red = 4, green = 5, blue = 3, jež odhaluje právě hranice země a vody. Výřez z této barevné kompozice včetně vizuální klasifikace a výsledek automatické klasifikace algoritmem maximální pravděpodobnosti je na obrázku 10. Přístup k automatické klasifikaci je obdobný jako v předchozích případech s tím rozdílem, že byly trénovány pouze dvě plochy (jedna pro rybník, druhá libovolná světlého odstínu) a jako vstup se volily v řadě tři odpovídající složky rastru. Z obrázku je vidět, že plocha rybníka, určená automatickou klasifikací je menší než plocha definovaná vizuální klasifikací. Pomocí nástroje *Calculate Area* bylo zjištěno, že plocha polygonu získaná vizuální interpretací je rovna 37 508 m<sup>2</sup>, zatímco vyměřená plocha je 29 820 m<sup>2</sup> a plocha určená například automatickou klasifikací z roku 2008 je naopak přibližně o 10 000 m<sup>2</sup> menší. Klasifikován byl snímek z roku 2010 s předpokladem, že plocha rybníka je v průběhu let 2000-2010 konstantní.

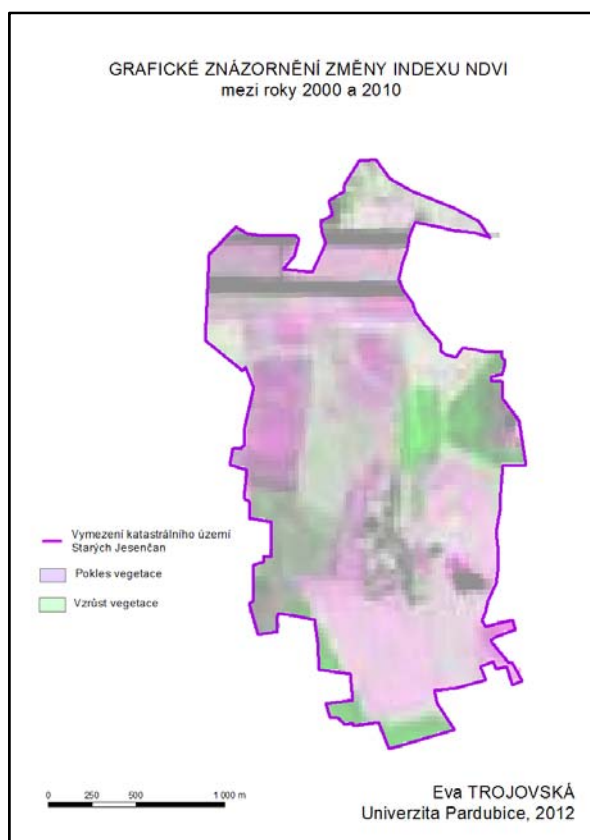


**Obrázek 10: Vymezení plochy rybníka na snímku s kombinací pásem 4-5-3 a ve výsledku automatické klasifikace, (zleva)**

*Zdroj: vlastní zpracování*

#### 4.5.2 NDVI CHANGE

Volně dostupná aplikace *Change Matters* dovoluje poznání změn v krajině takové v kontextu vegetačních indexů, pomocí kterých lze obecně v obrazu zvýraznit vegetační složku. Aplikace *Change Matters* ale umožňuje porovnání vegetace mezi dvěma časovými horizonty a graficky znázornit vývoj indexu NDVI. Plochy s vyšším NDVI indexem v pozdějším roce jsou znázorněny odstíny zelené, jež indikuje vzrůst vegetace nebo pokles úrovně vody. Plochy s nižším NDVI indexem v pozdějším roce budou v odstínu magenty ukazující naopak na pokles vegetace či vzrůst úrovně vody. Kromě prohlížení takovýchto kompozicí ve webovém prohlížeči lze opět připojit ArcGIS Desktop k serveru a pracovat s obrazy již v tomto prostředí. Pro tuto diplomovou práci byly vzhledem k předchozí analýze zvoleny obrazy zachycující změny mezi roky 2000 a 2010, viz obrázek 11.



**Obrázek 11: Vizualizace změny indexu NDVI mezi roky 2000 a 2010**

*Zdroj: vlastní zpracování*

Zřejmě došlo téměř na celém území k poklesu vegetace, ale to mohlo být ovlivněno stavem plodin na orné půdě v rozdílné době snímání povrchu. Ke zřetelnému růstu vegetace došlo na území severovýchodně od obce, kde došlo také dle předchozích výsledků k růstu lesa.

## 5 POROVNÁNÍ ZMĚN KRAJINY ZÁJMOVÉHO ÚZEMÍ

### 5.1 Změny v krajině mezi roky 2003 a 2008

V případě klasifikace leteckých snímků lze z předchozích výsledků přehledně shrnout diference mezi oběma časovými horizonty do grafu 9 a následující tabulky, v níž jsou uvedené i kvantitativní rozdíly z vizuální interpretace území. V grafické formě lze rozdíl zpodobnit digitálním zpracováním obrazů, a to jejich rozdílem. Rozdíl klasifikovaných snímků a jeho úpravu bylo provedeno v programu *Adobe Photoshop*. Mapová kompozice tohoto porovnání je vložena do přílohy E.

**Tabulka 8: Kvantitativní zachycení změn v jednotlivých kategoriích mezi léty 2008 a 2003**

Název informační třídy	Změny v jednotlivých kategoriích [ha]		Poměrné zastoupení [%]	
	Automatická klasifikace	Vizuální interpretace	Automatická klasifikace	Vizuální interpretace
<b>Zástavba</b>	0,5424	1,24	0,15	0,33
<b>Orná půda</b>	-30,7302	-5,21	-8,24	-1,4
<b>Travní porost</b> Sady a zahrady, louky pastviny a ostatní zeleň	32,8722	3,39	8,9	0,91
<b>Stín/les</b>	-3,6707	0,55	-0,99	0,15
<b>Rybník</b>	0,6463	0,2	0,17	0,06
<b>Komunikace</b> Silnice, nezpevněná cesta	0,04	0,02	0,01	0,01
<b>Ostatní</b> Železnice	x	0,6600	x	-0,05

*Zdroj: vlastní zpracování, [24]*


Nárůst vykazuje plocha zástavby, a to především v severozápadní části obce. Vizuální interpretace ale odhaluje tento nárůst více než dvakrát vyšší než automatická klasifikace. Tato chyba vznikla proto, že ve výsledcích automatické klasifikace z roku 2008 byly rozsáhlé spojité plochy třídy travního povrchu a prvky zástavby pak byly nakonec nesprávně zařazeny.

Pokles je naopak typický pro plochy orné půdy. V tomto bodě se s autorem [24] rozcháším, neboť na základě nápovědy zvýrazněných leteckých snímků jsem vytvářela trénovací plochy pro kategorii *Travní povrch*, ačkoli ve vizuální interpretaci by odpovídaly orné půdě. Taktéž webové služby společnosti Esri [13] zaměřené na vegetaci či zemědělství odhalují vyšší podíl travního povrchu. Za těchto předpokladů travní povrch rozlohou vzrostl přibližně o 33 ha.



V případě monitorování lesa se do výsledku promítá velká odchylka mezi vizuální interpretací a automatickou klasifikací pro rok 2008. Ačkoli v roce 2008 bylo vykáceno mnoho stromků a křovin okolo rybníka, na celém území mohlo dojít k malému nárůstu kategorie lesa, jak ukazuje výsledek vizuální interpretace. Pro tuto kategorii ale dává automatická klasifikace nesměrodatný údaj. Výsledek výpočtu plochy lesa za rok 2003 z automatické klasifikace je naopak velmi blízký skutečnosti.

Pro kategorii *Rybník* předpokládáme, že se jedná o prvek s téměř konstantní plochou. To, že dle automatické klasifikace dochází k nárůstu, je dáno stínem stromů na snímku z roku 2003. Růst plochy kategorie *Komunikace* je celkem zanedbatelný.




**Graf 9: Vývoj zastoupení jednotlivých kategorií v letech 2003 a 2008 v ha**

*Zdroj: vlastní zpracování*

Na základě vzorců, uvedených v podkapitole 2.2 je možné určit některé zajímavé indexy, související se změnami v krajině. Shannonův index diversity dle vzorce (6) pro rok 2003 má hodnotu  $-165,212$  a pro rok  $-160,579$ . Tento index se v čase zvyšuje, což znamená vyrovnanější procentní zastoupení kategorií. Maximální diversity pro obě období na základě vztahu (7) je dosaženo při hodnotě  $0,778$ . Index dominance (8) je pak rozdílem Shannonova indexu diversity a maximální diversity. Pro rok 2003 má tedy hodnotu  $-165,990$  a pro rok 2008 hodnotu  $-161,357$ . Sledované území je poměrně malé a nepřiliš různorodé na to, aby hodnoty těchto indexů významně přispívaly k hodnocení změn v této krajině.

Pro zachycení změn v krajině včetně výsledků z analýz družicových snímků je nevhodnější využít graf následně, viz graf 10. Na horizontální ose jsou naneseny roky 2000,

2003, 2008, 2010 a 2012. Na vertikální ose jsou naneseny hodnoty v hektarech. Ve spojnicovém grafu jsou uvedeny základní kategorie *Zástavba*, *Orná půda* a *Travní povrch*, a to s hodnotami výsledků vizuální interpretace, tedy s hodnotami nejpřesnějšími. Hodnoty z roku 2012 byly získány z dat ČÚZK [10]. Porovnání změn v krajině mezi léty 2003 a 2008 na základě automatické klasifikace již bylo znázorněno výše.



**Graf 10: Vývoj plochy zastoupení základních kategorií v hektarech**

*Zdroj: vlastní zpracování*

Pro další vývoj krajiny v obci Staré Jesenčany lze na základě dostupných i nově získaných dat konstatovat, že bude docházet k poklesu orné půdy a naopak vzrůstu plochy zástavby. To potvrzují údaje také na stránkách obce [35] o plánu hromadné výstavby rodinných domků. Letecký snímek z roku 2008 některé z těchto nových staveb zachycuje.

## ZÁVĚR

Cílem této práce bylo pomocí vybraných metod automatické klasifikace obrazu z DPZ zjistit změny v krajině v obci Staré Jesenčany. Ke splnění tohoto cíle bylo využito programu ArcGIS Desktop 10, leteckých snímků společnosti GEODIS z let 2003 a 2008, satelitních snímků z družice Landsat 7 ETM+ z let 2000 a 2010 a dalších podpůrných dat.

Metody, jež dovoluje program ArcGIS Desktop 10 provést, jsou metoda maximální pravděpodobnosti a klasifikátor ISODATA. Lepší výsledky obecně poskytuje první klasifikátor řízené klasifikace, ale algoritmu ISODATA bylo vhodné využít vzhledem k dostupným datům jako orientačního výsledku a očekávání výsledků. Takto bylo vytvořeno šest kategorií: *Zástavba*, *Orná půda*, *Travní povrch*, *Les*, *Komunikace* a *Rybník*. Katastrálním územím protéká také potok a prochází železnice, ale pomocí klasických metod automatické klasifikace jej není možné detekovat. Při řešení klasifikace daných obrazů nastal také problém s určením kategorie *Les*. Tento problém byl zjednodušen na klasifikování stínů, jež stromy vrhají. Mezi stíny samozřejmě byly zařazeny i stíny z budov, ale bylo předpokládáno jisté vykompenzování. Skutečně především při klasifikaci snímku z roku 2003 nebyl zjištěn významný rozdíl mezi výsledkem z tohoto zjednodušení a výsledky vizuální interpretace, které byly přístupné díky bakalářské práci Tomáše Hromádka. Ovšem toto platí pro kvantitativní vyjádření plochy kategorie *Les*.

Klasifikace družicových snímků byla v jistém smyslu jednodušší, ale za to velice nepřesná vzhledem k malé rozloze zájmového území a nízkému rozlišení snímků družice Landsat 7. Výhodou těchto snímků jsou ale možnosti kombinace pásem a analýza vegetačních indexů.

Závěrem z interpretace výsledků klasifikace lze říci, že klesá podíl orné půdy například v důsledku jejího rozprodávání ve prospěch nové zástavby. Také došlo k mírnému vzrůstu plochy lesů či křovin. Nepatrný vzrůst lze zjistit i u komunikace také v důsledku nové zástavby. Výsledek a zjištění výrazné změny plochy rybníka v případě automatické klasifikace leteckých snímků ale není považován za pravděpodobný. Průběh vývoje plochy travního povrchu je nejdříve rostoucí, ale v současnosti spíše klesá.

Tato diplomová práce je především určena jiným studentům zabývajícím se problematikou automatické klasifikace obrazu z DPZ, neboť jsou zde analyzovány letecké i družicové snímky a jsou zde představeny různé přístupy k danému problému. Vyvolat zájem může i u obyvatel obce Staré Jesenčany nebo jiných osob, pro které z různých důvodů může být toto území zajímavé.

## SEZNAM INFORMAČNÍCH ZDROJŮ

- [1] AGROCENZUS REGIONY 2010. *Zemědělství v Pardubickém kraji a jeho okresech*. 2011. Dostupné z:  
[http://www.czso.cz/xs/redakce.nsf/i/zemedelstvi\\_v\\_pardubickem\\_kraji\\_a\\_jeho\\_okresech\\_h\\_%28vysledky\\_agrocenzu\\_2010%29/\\$File/Agrocenzus\\_2010.pdf](http://www.czso.cz/xs/redakce.nsf/i/zemedelstvi_v_pardubickem_kraji_a_jeho_okresech_h_%28vysledky_agrocenzu_2010%29/$File/Agrocenzus_2010.pdf)
- [2] Analýza krajiny v GIS. UNIVERZITA PALACKÉHO. *Katedra geoinformatiky* [online]. 2007-2011 [cit. 2012-02-19]. Dostupné z:  
<http://www.geoinformatics.upol.cz/predmety-det.php?menu=KGI/MAKRA>
- [3] BOKR, P. *GeoWeb: Geologický informační systém* [online]. 1999-2012 [cit. 2012-02-07]. Dostupné z: <http://www.gweb.cz/>
- [4] CENIA. *CORINE Land Cover 2006 (2007-2008)* [online]. 2006 [cit. 2012-01-30]. Dostupné z:  
[http://www.cenia.cz/\\_C12572160037AA0F.nsf/showProject?OpenAgent&PID=CPRJ7T3H42O2&cat=about](http://www.cenia.cz/_C12572160037AA0F.nsf/showProject?OpenAgent&PID=CPRJ7T3H42O2&cat=about)
- [5] CÍLEK, V. Co je krajina?: O přírodě a paměti středních Čech. *Vstoupit do krajiny* [online]. 2004 [cit. 2012-02-19]. Dostupné z: <http://krajina.kr-stredocesky.cz/article.asp?id=9>
- [6] CULEK, M. *Biogeografické členění České republiky*. Praha: Enigma, 1996, 347 s. ISBN 80-853-6880-3.
- [7] ČESKÁ GEOLOGICKÁ SLUŽBA, Český úřad zeměměřičský a katastrální. *Geologická mapa 1:50 000*. 2007. Dostupné z:  
[http://www.geology.cz/app/ciselniky/lokalizace/show\\_map.php?mapa=g50&y=649400&x=1064800&r=1500&s=1&legselect=0](http://www.geology.cz/app/ciselniky/lokalizace/show_map.php?mapa=g50&y=649400&x=1064800&r=1500&s=1&legselect=0)
- [8] ČESKO. Zákon č. 114 ze dne 2. ledna 2011 o ochraně přírody a krajiny. In: *Sbírka zákonů České republiky*. 2012, částka 5, s. 196-247. ISSN 1211-1244. Dostupné z:  
<http://www.mzp.cz/www/platnalegislativa.nsf/d79c09c54250df0dc1256e8900296e32/58170589e7dc0591c125654b004e91c1?opendocument>
- [9] ČESKÝ STATISTICKÝ ÚŘAD. *Český statistický úřad* [online]. 2012 [cit. 2012-02-07]. Dostupné z: <http://www.czso.cz/>

- [10] Český úřad zeměměřičský a katastrální. ČÚZK. *K.ú.: 754412 - Staré Jesenčany - podrobné informace* [online]. 2012 [cit. 2012-07-30]. Dostupné z: [http://www.cuzk.cz/Dokument.aspx?PRARESKOD=10&MENUID=10016&AKCE=META:SESTAVA:MDR002\\_XSLT:WEBCUZK\\_ID:754412](http://www.cuzk.cz/Dokument.aspx?PRARESKOD=10&MENUID=10016&AKCE=META:SESTAVA:MDR002_XSLT:WEBCUZK_ID:754412)
- [11] Definice krajiny. In: *Ecologica plus* [online]. 2009 [cit. 2012-02-19]. Dostupné z: [http://www.ecologicaplus.cz/index.php?option=com\\_content&view=category&id=22&layout=blog&Itemid=28](http://www.ecologicaplus.cz/index.php?option=com_content&view=category&id=22&layout=blog&Itemid=28)
- [12] DOBROVOLNÝ, P. *Dálkový průzkum Země: digitální zpracování obrazu*. Brno: Masarykova univerzita, 1998, 208 s. ISBN 80-210-1812-7.
- [13] ESRI. *Landsat Imagery | ChangeMatters Viewer* [online]. 2012 [cit. 2012-07-30]. Dostupné z: <http://www.esri.com/landsat-imagery/viewer.html>
- [14] FALTYSOVÁ, H. *Pardubicko: chráněná území ČR IV*. 1. vyd. Praha: Agentura ochrany přírody a krajiny ČR, 2002, 314 s. ISBN 80-860-6444-1.
- [15] FORMAN, RICHARD T. *Krajinná ekologie*. 1. vyd. Praha: Academia, 1993, 583 s. ISBN 80-200-0464-5.
- [16] GAO, J. *Digital analysis of remotely sensed imagery*. New York: McGraw Hill, c2009, 645 s. ISBN 00-716-0465-0.
- [17] GISAT. *Gisat / cz* [online]. 2012 [cit. 2012-02-19]. Dostupné z: <http://gisat.cz/content/cz>
- [18] GREEN, K. Change Matters. *Photogrammetric Engineering & Remote Sensing* [online]. 2011, č. 4 [cit. 2012-07-30]. Dostupné z: <http://digital.ipcprintservices.com/publication/?i=65049&p=7>
- [19] GUTH, J., KUČERA, T. Monitorování z měn krajinného pokryvu s využitím DPZ a GIS. *Příroda* [online]. 1997(10), 107-124 [cit. 2012-01-30]. Dostupné z: [www.usbe.cas.cz/people/kucera/LE/TEXTY/landcov.pdf](http://www.usbe.cas.cz/people/kucera/LE/TEXTY/landcov.pdf)
- [20] HABZLOVÁ, M. et al. Klasifikace pokryvu území v povodí Bělé pro hodnocení srážko-odtokových poměrů. In: *Geoinformatika ve veřejné správě* [online]. 2006 [cit. 2012-01-30]. Dostupné z: <http://gis.vsb.cz/zsv/images/stories/publikace/HanzlovaBrno2006.pdf>

- [21] HANČAROVÁ, E. Hydrologické poměry Královehradeckého a Pardubického kraje. *Český hydrometeorologický ústav* [online]. 2006 [cit. 2012-02-18]. Dostupné z: <http://old.chmi.cz/HK/OH/hpomery.htm>
- [22] HERZOG, F. et al. *Landscape metrics for assessment of Landscape destruction and rehabilitation*. Springer-Verlag: Environmental Management, 2001, Vol. 27., No. 1.
- [23] HRADECKÝ, J., BUZEK, L. *Nauka o krajině: Učební texty Ostravské univerzity*. Vyd. 1. Ostrava: Ostravská univerzita, 2001, 215 s. ISBN 80-704-2804-X. Dostupné z: [katedry.osu.cz/kfg/user/hradecky/download/skripta.rar](http://katedry.osu.cz/kfg/user/hradecky/download/skripta.rar)
- [24] HROMÁDKO, T. Využití leteckých snímků pro analýzu vývoje krajiny v okolí obce Staré Jesenčany. Pardubice, 2009. Bakalářská práce. Univerzita Pardubice.
- [25] IDRISI Selva. CLARK LABS. *ClarkLabs -IDRISI GIS and Image Processing Software* [online]. 2012 [cit. 2012-05-15]. Dostupné z: <http://www.clarklabs.org/products/idrisi.cfm>
- [26] JAKL, J. Fytogeografie. *Příroda Náchodská* [online]. 2006 [cit. 2012-02-26]. Dostupné z: <http://priroda-nachodska.wz.cz/fytogeo.htm>
- [27] JAREŠ, V. et al. *Krajinná ekologie - učebnice* [online]. 2007 [cit. 2012-02-19]. Dostupné z: <http://www.uake.cz/frvs1269/index.html>
- [28] LIPSKÝ, Z. Praha: Karolinum, 1998, 129 s. ISBN 80-718-4545-0.
- [29] LIPSKÝ, Z. *Sledování změn v kulturní krajině: učební text pro cvičení z předmětu Krajinná ekologie*. Kostelec nad Černými lesy: Lesnická práce, 2000, 71 s. ISBN 80-213-0643-2.
- [30] MIKLÓS, L., IZAKOVIČOVÁ, Z. *Krajina ako geosystém*. 1. vyd. Bratislava: Veda, vydavateľstvo Slovenskej akadémie vied, 1997, 152 s. ISBN 80-224-0519-1.
- [31] MULKOVÁ, M. *Využití konvenčních metod DPZ při sledování antropogenních změn krajiny v poddolovaných oblastech* [online]. Brno, 2007 [cit. 2012-02-19]. Dostupné z: [http://is.muni.cz/th/54823/prif\\_d/text.pdf](http://is.muni.cz/th/54823/prif_d/text.pdf). Disertační práce. Masarykova univerzita.
- [32] Obec Staré Jesenčany. *Obec.čr* [online]. 2012 [cit. 2012-02-07]. Dostupné z: <http://www.obec.cr/stare-jesencany/575712/>
- [33] QIAN, J., ZHOU Q., ZHANG, H. Comparison of Pixel-based and Object-oriented Classification Methods for Extracting Built-up Areas in Aridzone. *ISPRS Workshop on*

- Updating Geo-spatial Databases with Imagery & The 5th ISPRS Workshop on Dynamic and Multi-dimensional GIS*. 2007(XXXVI-4/W54), 163-171. Dostupné z:  
<http://www.isprs.org/proceedings/XXXVI/4-W54/papers/157-162%20Juan%20Gu.pdf>
- [34] RINDOVÁ, K. *Temporální analýza vývoje krajiny v okolí obce Lázně Bohdaneč*. Pardubice, 2008. Dostupné z:  
[http://dspace.upce.cz/bitstream/10195/28877/1/RindovaK\\_Temporalni%20analyza\\_PS\\_2008.pdf](http://dspace.upce.cz/bitstream/10195/28877/1/RindovaK_Temporalni%20analyza_PS_2008.pdf). Bakalářská práce. Univerzita Pardubice.
- [35] STARÉ JESENČANY. *Staré Jesenčany* [online]. 2012 [cit. 2012-02-14]. Dostupné z:  
<http://www.starejesencany.cz/>
- [36] ŠÍMA, J. Terminologický oříšek: Jak správně používat výrazy “land use” a “landcover”? *GeoBusiness: srozumitelně o geoinformatice v praxi* [online]. Praha: Klaudian Praha, 2010(3), 23 [cit. 2012-01-30]. Dostupné z:  
<http://issuu.com/springwinter/docs/gb2010-03?mode=window&pageNumber=1>
- [37] THE NATURE CONSERVANCY AND THE USDA AGRICULTURAL RESEARCH SERVICE. *The Landscape Toolbox* [online]. 2008 [cit. 2012-01-24]. Dostupné z:  
<http://www.landscapetoolbox.org/>.
- [38] TOLASZ, R. *Atlas podnebí Česka: Climate atlas ofCzechia*. 1. vyd. Praha: Český hydrometeorologický ústav, 2007, 255 s. ISBN 978-80-86690-26-1.
- [39] TSO, B., MATHER, P. M. *Classification methods for remotely sensed data*. 2nd ed. BocaRaton: CRC Press, c2009, 356 s. ISBN 14-200-9072-0.
- [40] TUČEK, J. *GIS-geografické informační systémy*. Brno: Computer Press, 1998, 424 s. ISBN 80-722-6091-X.
- [41] ÚSTAV PRO VÝZKUM LESNÍCH EKOSYSTÉMŮ. *Czech Terra* [online]. 2009 [cit. 2012-02-19]. Dostupné z: <http://www.czechterra.cz/>
- [42] VOSTRACKÁ, B. *Mapování změn zástavby s využitím DPZ*. Praha, 2008. Dostupné z:  
[http://www.suburbanizace.cz/diplomky/Vostracka\\_DP.pdf](http://www.suburbanizace.cz/diplomky/Vostracka_DP.pdf). Diplomová práce. Univerzita Karlova v Praze.
- [43] VÝZKUMNÝ ÚSTAV SILVA TAROUČY PRO KRAJINU A OKRASNÉ ZAHRADNICTVÍ. *Změny využívání krajiny* [online]. 2011 [cit. 2012-02-19]. Dostupné z: <http://www.zmeny-krajiny.cz/>

- [44] VÝZKUMNÝ ÚSTAV SILVA TAROUČY PRO KRAJINU A OKRASNÉ ZAHRADNICTVÍ PRŮHONICE. *Projekt VaV MŠMT Kačina 2006 - 2011* [online]. 2012 [cit. 2012-02-19]. Dostupné z: <http://www.projektkacina.estranky.cz/>
- [45] WENG, Qiaho. *Advances in environmental remote sensing sensors, algorithms, and applications*. BocaRaton, FL: CRC Press, 2011. ISBN 978-142-0091-816.



## **SEZNAM PŘÍLOH**

Příloha A: Katastrální území obce staré Jesenčany z roku 2003 a 2008 (letecké snímky)

Příloha B: Klasifikace území Starých Jesenčan pomocí ISODATA klasifikátoru v roce 2003 a 2008

Příloha C: Klasifikace leteckého snímku území Starých Jesenčan pomocí algoritmu maximální pravděpodobnosti v roce 2003 a 2008

Příloha D: Klasifikace leteckého snímku území Starých Jesenčan pomocí algoritmu maximální pravděpodobnosti v roce 2003 a 2008 (po úpravě)


Příloha E: Katastrální území Starých Jesenčan po odečtu obrazů z roku 2008 a 2003

## Příloha A

### LETECKÝ SNÍMEK OBCE STARÉ JESENČANY

v roce 2003




 Vymezení katastrálního území  
Starých Jesenčan

0 250 500 1 000 m  


Eva TROJOVSKÁ  
Univerzita Pardubice, 2012

# LETECKÝ SNÍMEK OBCE STARÉ JESENČANY

v roce 2008



—  
Vymezení katastrálního území  
Starých Jesenčan

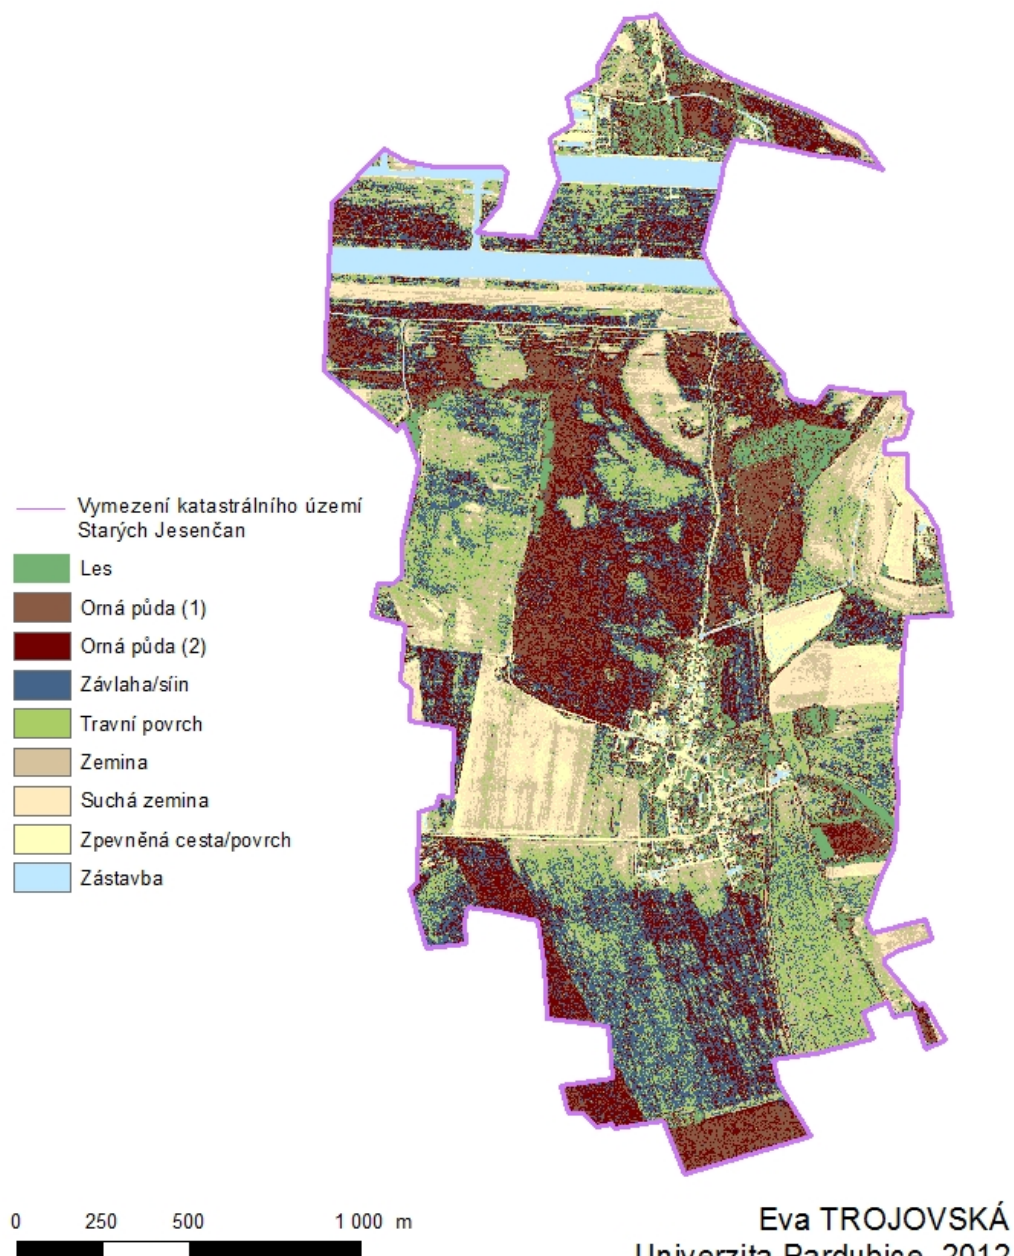
0 250 500 1 000 m

Eva TROJOVSKÁ  
Univerzita Pardubice, 2012

## Příloha B

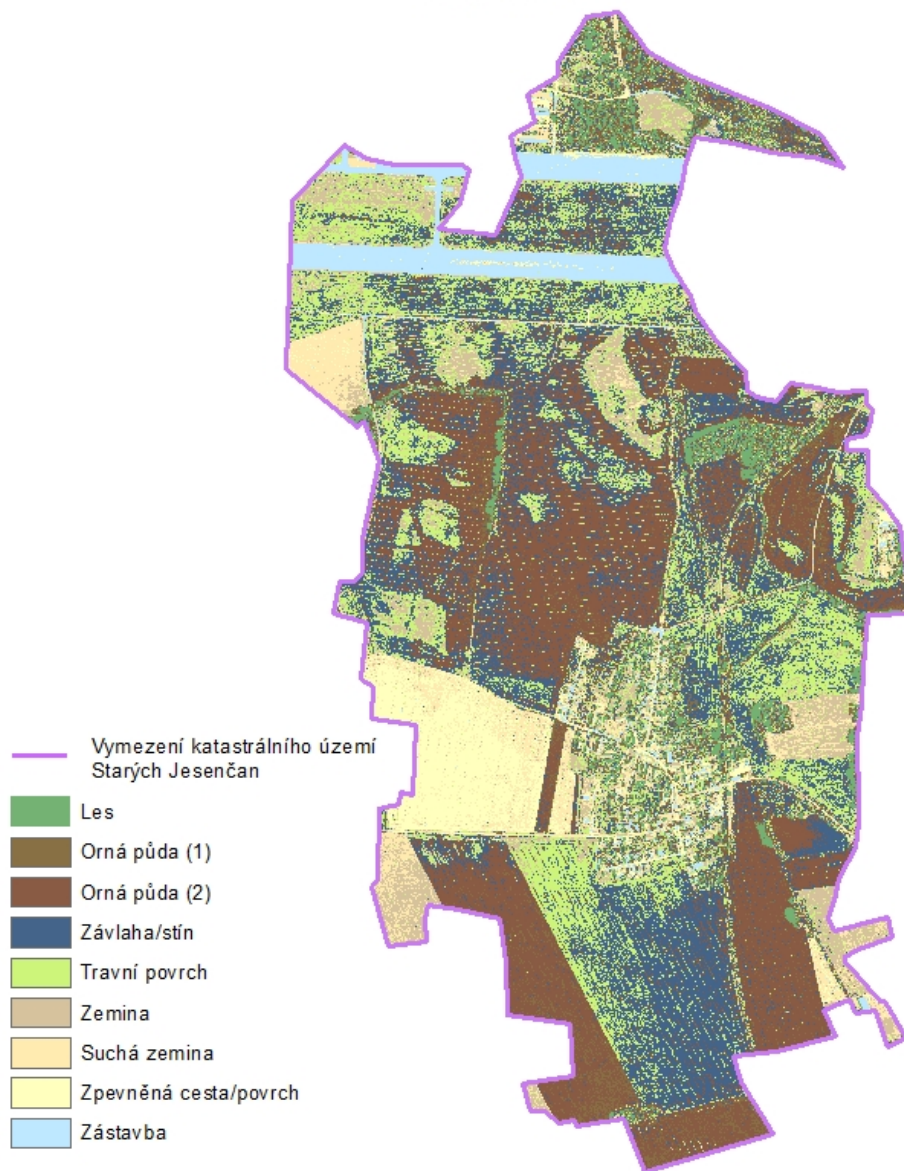
### KLASIFIKACE ÚZEMÍ STARÝCH JESENČAN POMOCÍ ISO DATA KLASIFIKÁTORU

v roce 2003



# KLASIFIKACE ÚZEMÍ STARÝCH JESENČAN POMOCÍ ISO DATA KLASIFIKÁTORU

v roce 2008



0 250 500 1 000 m

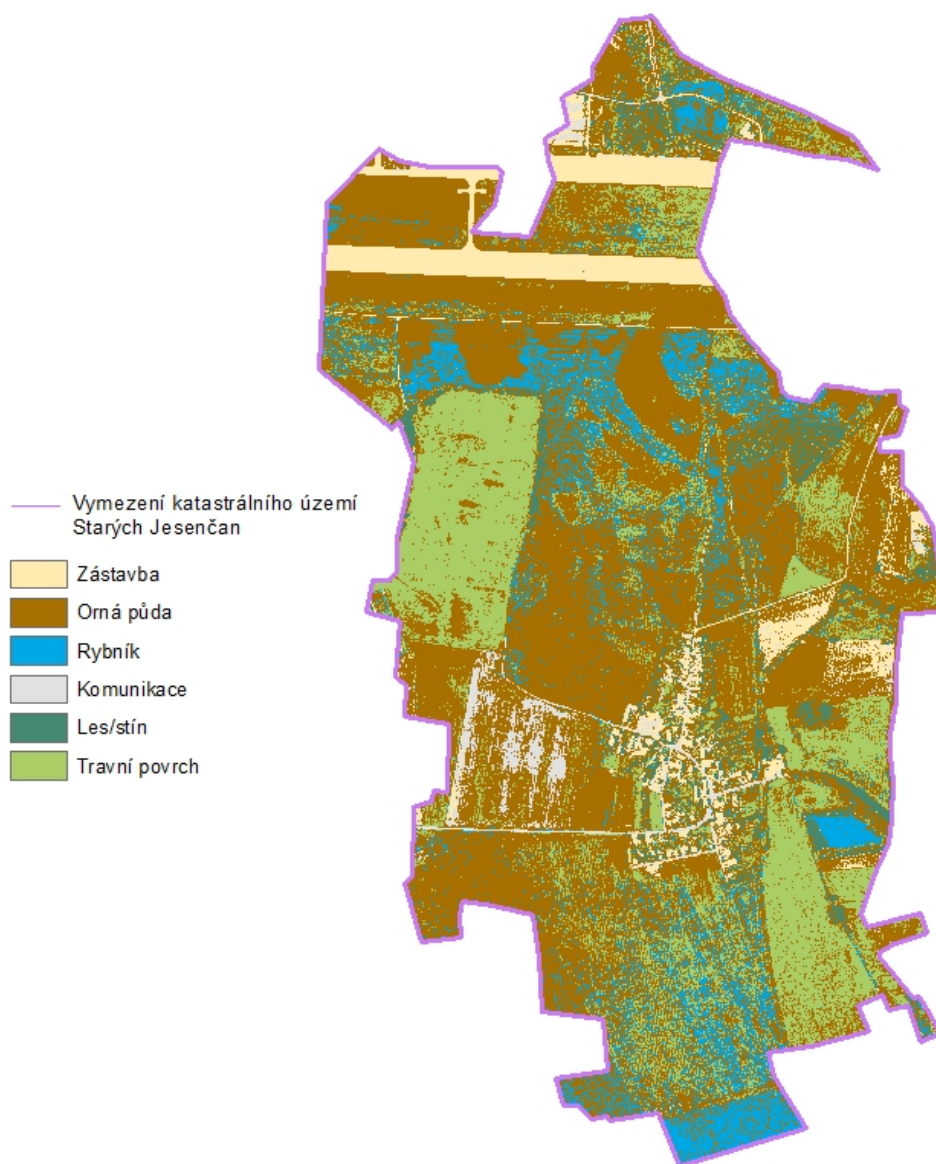


Eva TROJOVSKÁ  
Univerzita Pardubice, 2012

## Příloha C

### KLASIFIKACE ÚZEMÍ STARÝCH JESENČAN POMOCÍ ALGORITMU MAXIMÁLNÍ PRADĚPODOBNOTI

v roce 2003



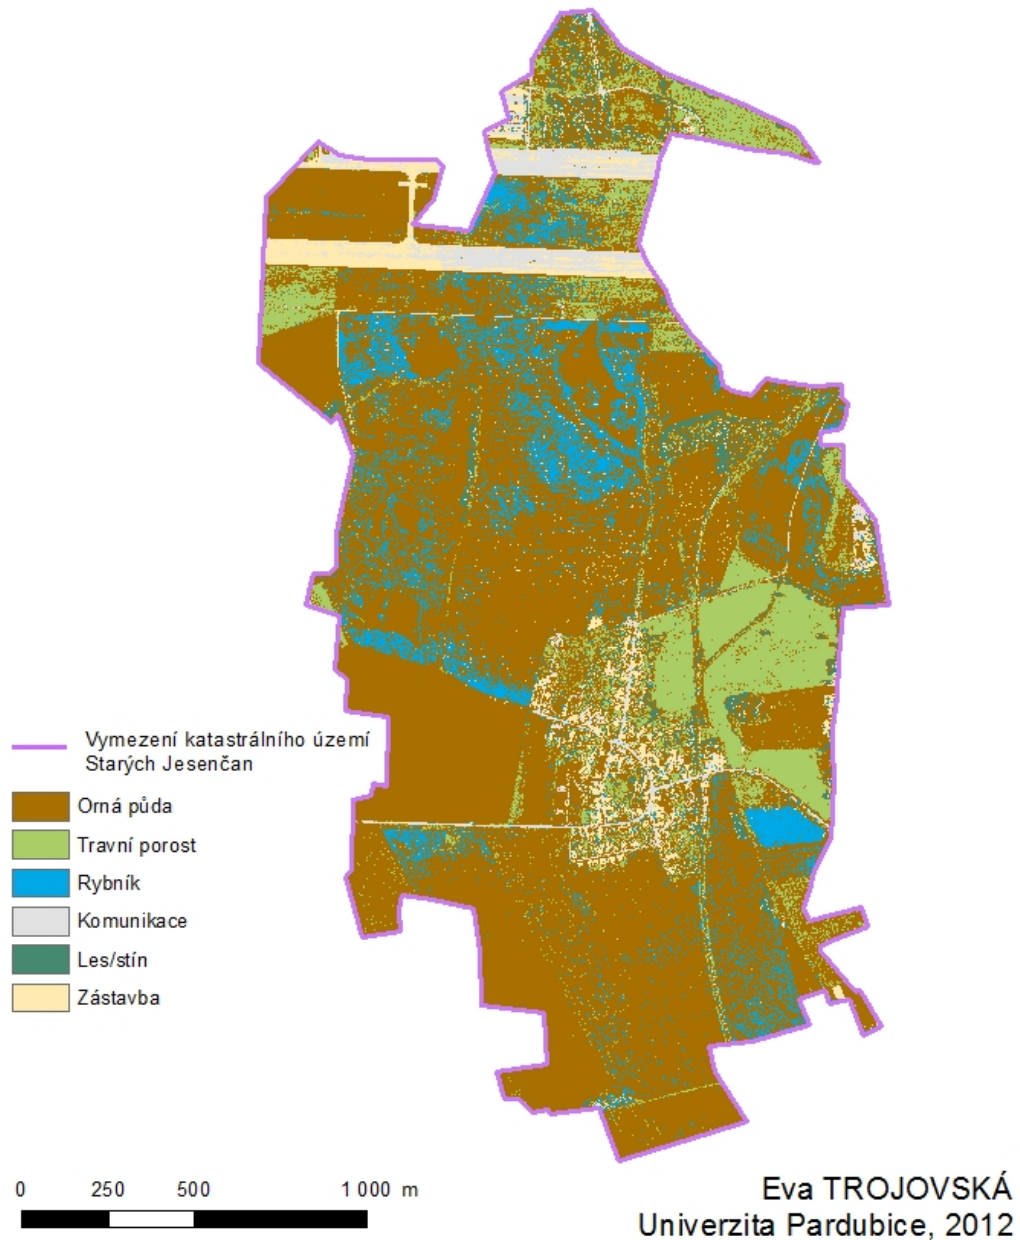
0 250 500 1 000 m



Eva TROJOVSKÁ  
Univerzita Pardubice, 2012

# KLASIFIKACE ÚZEMÍ STARÝCH JESENČAN POMOCÍ ALGORITMU MAXIMÁLNÍ PRAVDĚPODOBNOTI

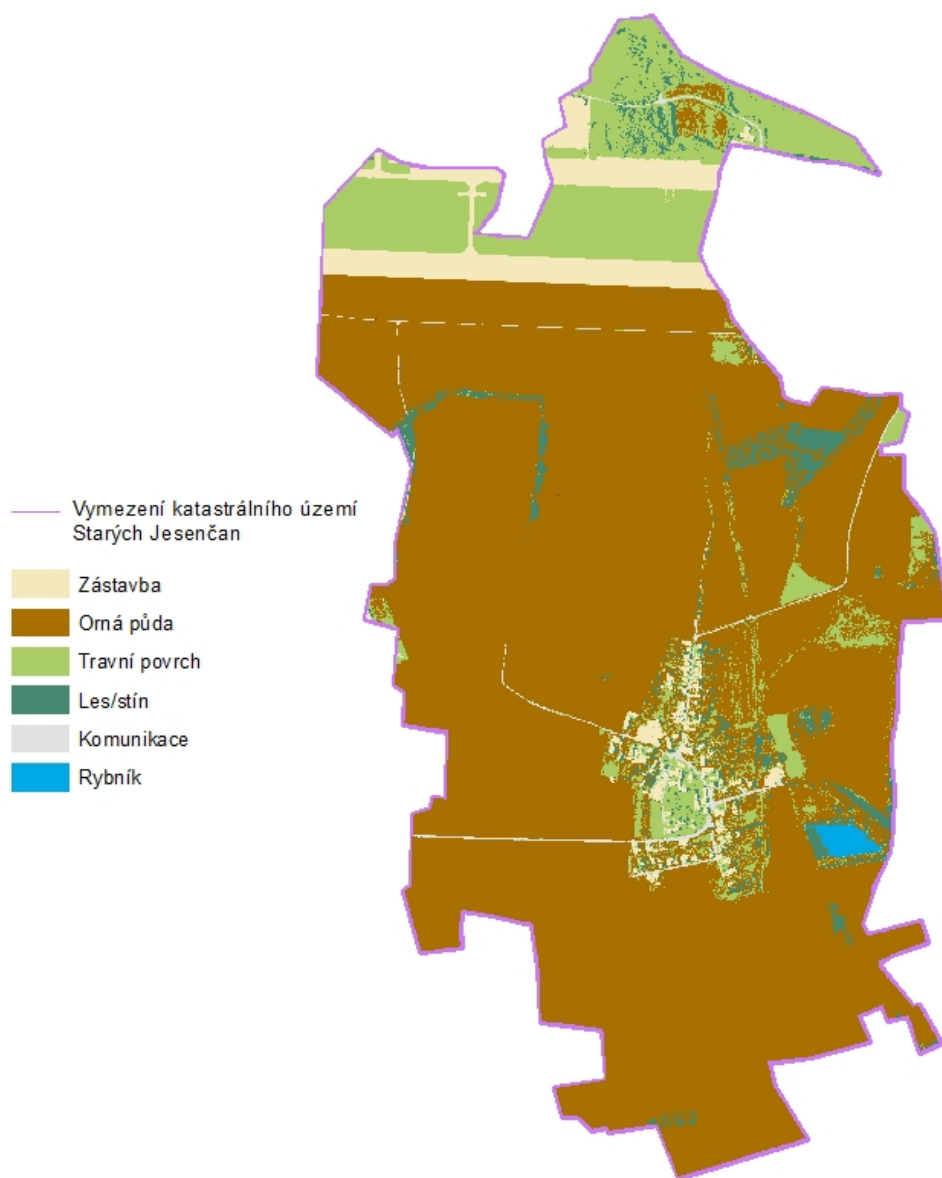
v roce 2008



## Příloha D

### KLASIFIKACE ÚZEMÍ STARÝCH JESENČAN POMOCÍ ALGORITMU MAXIMÁLNÍ PRADĚPODOBNOSTI

v roce 2003



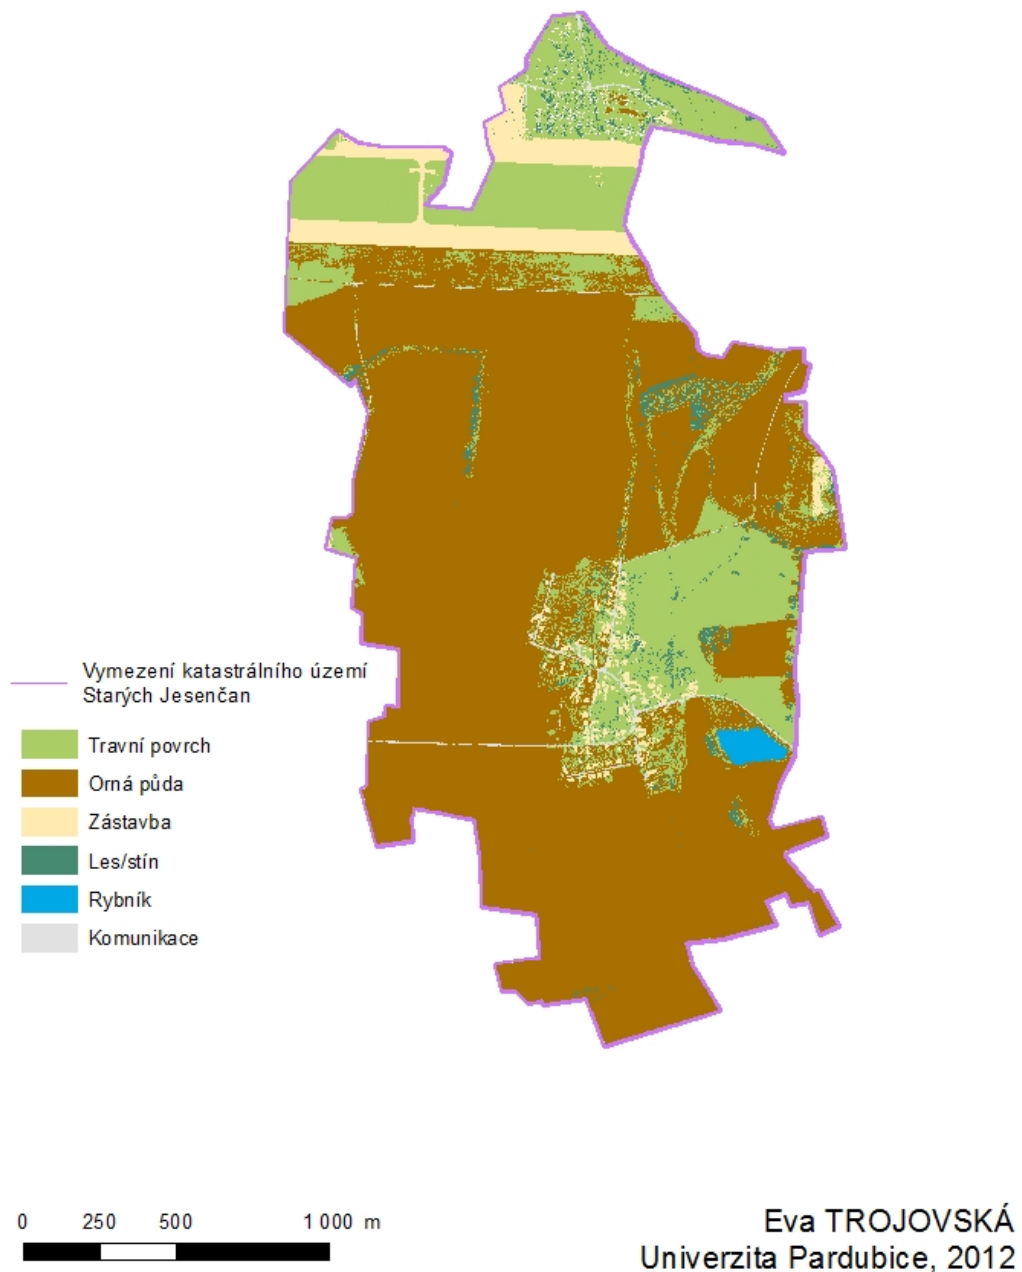
0 250 500 1 000 m

Eva TROJOVSKÁ  
Univerzita Pardubice, 2012




# KLASIFIKACE ÚZEMÍ STARÝCH JESENČAN POMOCÍ ALGORITMU MAXIMÁLNÍ PRAVDĚPODOBNOTI

v roce 2008



KATASTRÁLNÍ ÚZEMÍ STARÝCH JESENČAN  
PO ROZDÍLU KLASIFIKOVANÝCH OBRAZŮ  
z roku 2008 a 2003



0 250 500 1 000 m

Eva TROJOVSKÁ  
Univerzita Pardubice, 2012