

# Vyhodnocení pokryvu a využití krajiny pomocí dat DPZ

Bc. Petr Lukeš<sup>1</sup>

<sup>1</sup>Institut geoinformatiky, Hornicko-geologická fakulta, VŠB – Technická univerzita Ostrava,  
17. listopadu 15,  
708 33, Ostrava . Poruba, Česká republika  
[petr.lukes.st@vsb.cz](mailto:petr.lukes.st@vsb.cz)

**Abstrakt.** Cílem této práce je popsat možnosti klasifikace obrazových dat dálkového průzkumu Země s využitím vhodného klasifikačního schématu a zaznamenat všechny nutné kroky, které takovéto klasifikaci předchází.

V úvodu je popsáno klasifikované území a zpracovávaná vstupní data, která zásadním způsobem determinují výsledky klasifikace. Dále jsou analyzována některá z existujících klasifikačních schémat s ohledem na možnost nasazení pro zadané území. Hlavní část práce se věnuje popisu neřízené a řízené klasifikace a to včetně všech nutných kroků, které této klasifikaci předcházejí. V závěru je hodnocena přesnost klasifikace a je provedeno celkové vyhodnocení získaných výsledků.

**Klíčová slova:** dálkový průzkum Země, klasifikace obrazu, klasifikační schéma, LANDSAT, analýza obrazu

**Abstract.** The aim of this diploma thesis is to describe classification possibilities of remotely sensed data with utilisation of appropriate classification schema and to register all necessary steps, which precedes the classification.

At the beginning of this work it is described classified area and processed data, which fundamentally affect results of the classification. Furthermore there are analysed some of existing classification schemas with respect to possible apply on submitted area.

Main part of this work is dedicated to description of unsupervised and supervised classification including all necessary steps, which precedes this classification.

In the final part the classification accuracy is evaluated and overall evaluation of retrieved results is performed.

Keywords: remote sensing, image classification, classification schema, LANDSAT, image analysis

## 1 Úvod

Tato diplomová práce se zabývá vyhodnocením *pokryvu* a *využití krajiny* (povodí řeky Olše) pomocí dat *DPZ*.

Termín *krajinný pokryv*, v geoinformatice dobře zažitý pojem *landcover*, souvisí s typem vlastnosti povrchu Země. Kukuřičná pole, jezera, javory a dálnice – to jsou všechno příklady typů *landcover*. Termín *využití krajiny*, neboli *landuse* souvisí naopak s lidskou aktivitou nebo ekonomickou funkcí asociovanou se specifickou částí země. Jako příklad může sloužit úsek země na okraji obytné oblasti,

který může být použit pro stavbu rodinného domu. V závislosti na úrovni mapování potom lze jeho *landuse* popsat jako městskou krajinu, zástavbu, nebo zástavbu rodinných domů. Stejný kus země by měl *landcover* složeno ze střech, chodníků, trávy a stromů.[1]

V nejobecnějším smyslu slova *dálkový průzkum* znamená získávání informací o objektech a jevech na dálku – bez přímého kontaktu s těmito jevy či objekty, při kterém se využívá dvou základních poznatků:

- Člověk, ať již sám či za pomoci různě složitých přístrojů, je schopen získávat kvalitativní i kvantitativní informace o jevech a věcech, které ho obklopují
- Každý tento jev nebo objekt nějakým charakteristickým způsobem ovlivňuje své okolí [2]

Zatímco informace o krajinném pokryvu mohou být přímo interpretovány z příslušných dat dálkového průzkumu země, informace o lidské aktivitě v krajině (*landuse*) nemohou být často odvozeny přímo z krajinného pokryvu a vyžadují dodatečné znalosti o sledovaném území.

Jelikož jsem měl ve své práci k dispozici pouze data dálkového průzkumu Země, budeme dále mluvit spíše o *vyhodnocení pokryvu krajiny*. Toho dosáhneme pomocí zpracování, analýzy a klasifikace vstupních dat snímače Landsat 7 ETM+, jak bude popsáno v následujících kapitolách.

Výsledky této práce budou sloužit grantovému projektu GA 205/06/1037 „Využití geoinformačních technologií pro zpřesňování srážko-odtokových vztahů“, který klade požadavek na znalosti krajinného pokryvu studovaného povodí pro přesnější modelování srážko-odtokových stavů.

## 2 Klasifikační schémata

*Klasifikací* rozumíme v obecném slova smyslu zařazení zkoumaného prvku či vlastnosti do určitého logického *systému* za účelem přiřazení *informační* hodnoty zkoumanému prvku.

V případě klasifikace krajinného pokryvu digitálního obrazového záznamu si tento postup můžeme představit jako zařazení obrazové hodnoty konkrétního zkoumaného pixelu do jedné z kategorií zvoleného *klasifikačního schématu*, čímž jednoznačně identifikujeme krajinný pokryv zkoumaného pixelu. Klasifikační schéma můžeme v případě klasifikace krajinného pokryvu chápat např. jako seznam konkrétních typů krajinného pokryvu, které jsme schopni identifikovat.

Z těchto závěrů nám vyvstávají problémy, které musíme brát v potaz a to zejména:

- Volbou vhodného klasifikačního schématu, které bude dobře aplikovatelné na zpracovávaná data.[3]
- Volbou vhodného způsobu zpracování dat, postupu a algoritmů klasifikace pro přiřazení obrazového pixelu ke konkrétní třídě použitého klasifikačního schématu.[3]

## 2.1 Klasifikační schéma Markéty Hanzlové

Tato diplomová práce vychází z disertační práce ing. Markéty Hanzlové. Motivem zmíněné disertační práce bylo studium vlivu využití a pokryvu krajiny (LULC) na srážko-odtokový proces využitím dálkového průzkumu Země jako zdrojů dat LULC.

Při návrhu klasifikačního schématu využití a pokryvu krajiny s ohledem na srážko-odtokové procesy je třeba zvážit

- Aplikovanou metodu pro srážko-odtokové modelování.
- Druh využití a pokryvu krajiny mající významný vliv na změny v srážko-odtokovém procesu.
- Charakter družicových dat, která hodláme klasifikovat.

Při aplikaci schématu v daném území je pak třeba ještě vzít v úvahu

- Půdní poměry v území,
- Druh využití a pokryvu krajiny vyskytující se v území.
- Charakter družicových dat, která hodláme klasifikovat.

Uvážením a propojením těchto informací dojdeme k faktu, že při sestavování seznamu tříd takového klasifikačního schématu budeme limitováni především vlastnostmi družicových dat (prostorové a spektrální rozlišení) a naší schopností detekovat a klasifikovat potřebné informační třídy. [Hanzlová]

Tohoto klasifikačního schématu jsem nakonec využil pro klasifikaci krajinného pokryvu povodí řeky Olše.

- |                                 |
|---------------------------------|
| 1) URBANIZOVANÁ ÚZEMÍ           |
| 2) ZEMĚDĚLSKÉ PLOCHY            |
| 2.3 PASTVINY                    |
| 2.4 RŮZNORODÉ ZEMĚDĚLSKÉ PLOCHY |
| 3) LESY A POLOPŘÍRODNÍ OBLASTI  |
| 3.1 LISTNATÉ LESY               |
| 3.2 JEHLIČNATÉ LESY             |
| 3.3 SMÍŠENÉ LESY                |
| 5) VODNÍ PLOCHY                 |
| 9) OBLAČNOST                    |

Ukázka detekovaných krajinných tříd podle klasifikačního schématu

### 3 Zpracování dat krajinného pokryvu

#### 3.1 Zpracovávané snímky LANDSAT 7 ETM+

Pro potřeby analýzy krajinného pokryvu jsem měl k dispozici čtveřici satelitních snímků snímače LANDSAT 7 ETM+. Snímky byly uloženy ve formátu *Erdas Imagine* (.img) v osmi samostatných souborech (dvojice multispektrálního a panchromatického snímku pro každou scénu). Snímky pokrývají oblast Severní Moravy, podle kladu snímků systému LANDSAT je to **TRACK 189 FRAME 25**. Časově odpovídají období mezi lety 2000 a 2002.

Konkrétní datace snímků je následující:

- 02082000-189-25 – snímek z 2.8.2000, prostorové rozlišení 30m.
- 14052000-189-25 – snímek z 14.5.2000, prostorové rozlišení 25m, zachycuje pouze část území nacházející se v České republice.
- 04052002-189-25 – snímek z 4.5.2002, prostorové rozlišení 30m.
- 05062002-189-25 – snímek z 5.6.2002, prostorové rozlišení 30m.



**Obrázek 1 - ukázka zpracovávaného satelitního snímku,, znázornění hranic povodí řeky Olše**

Všechny zpracovávané snímky jsou produkty úrovně L1, tzn. že na ně byly aplikovány některé základní radiometrické a geometrické korekce. Pro zpřesnění výsledků klasifikace jsem na tato data ještě dále aplikoval některé dodatečné korekce, jako např. převod na hodnoty odrazivosti.

### 3.2 Zpracování dat DPZ

Jak jsem naznačil výše, před samotnou klasifikací krajinného pokryvu satelitních snímků LANDSAT 7 ETM+ jsem data vhodným způsobem musel před-zpracovat tak, aby provedené klasifikace vykazovaly co nejlepší výsledky. V samotném úvodu jsem snímky ořezal pro pilotní oblast řeky Olše a následně jsem na tyto výřezy aplikoval některé *obrazové korekce*.

Jednalo se zejména o **geometrické korekce** (*rektifikace snímků*), **radiometrické korekce** (*úprava kontrastu, převod hodnot z DN na hodnoty odrazivosti*) a **spektrální zvýraznění** (*PCA analýza snímku, PAN sharpening*). Popis těchto kroků uvádím dále.

#### 3.2.1 Ořez snímků pro pilotní oblast povodí řeky Olše

Dodané snímky LANDSAT7 ETM+ zachycovaly celou oblast TRACK 189 FRAME 25, která zobrazuje čtvercové území 185x185km. Naším cílem však bylo zpracovávat a klasifikovat pouze data povodí řeky Olše. Proto bylo prvním krokem při přípravě dat dálkového průzkumu Země provést ořez scény podle hranic tohoto povodí. K tomu jsem využil funkce programového prostředí ERDAS IMAGINE *subset* (Modul DataPrep – Subset image). Po zadání levého-horního a pravého-spodního rohu požadovaného výběru jsem tímto krokem získal požadovaný výřez území, které jsem dále zpracovával.



Obrázek 2 - znázornění hranic povodí řeky Olše

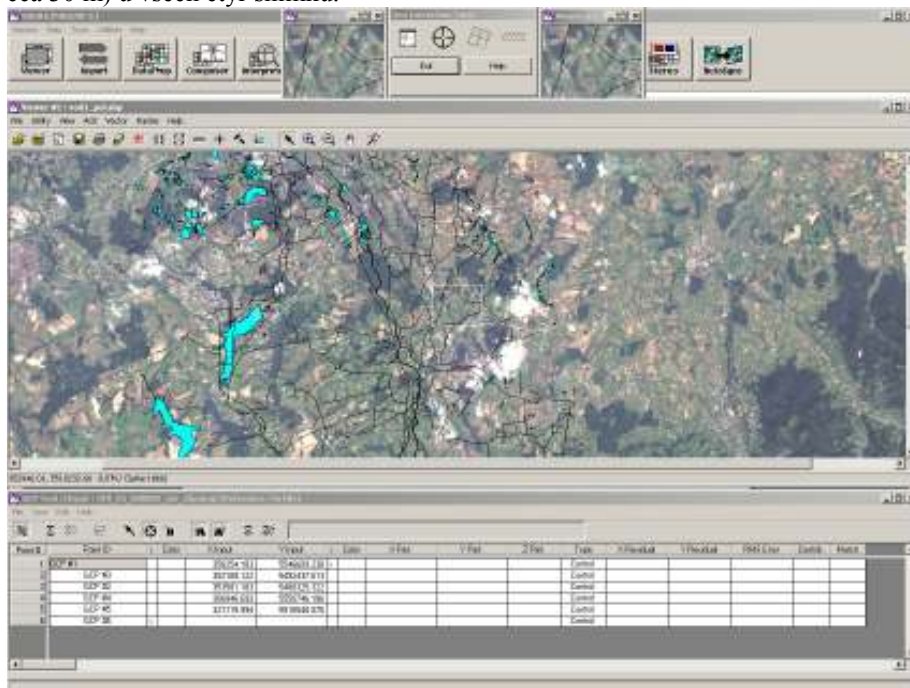
#### 3.2.2 Georeferencování snímků

Snímky LANDSAT 7 ETM+, které jsem měl k dispozici, byly (před)usazeny do souřadnicového systému WGS84/NUTM, zóny 33. Po zobrazení přesných vektorových dat, jako např. DMU25 (Digitální model území v měřítku 1:25 000) nad těmito snímky jsem došel k závěru, že snímky bude nutno dále **georeferencovat** pro dosažení lepší polohové přesnosti.

Georeferencování zpracovávaných dat LANDSAT 7 ETM+ jsem provedl v prostředí ERDAS IMAGINE modulem *Image geometric correction*. Ve vstupním dialogu volby geometrického modulu jsem zvolil již obsažený model LANDSAT a

pokračoval dále. Pokud bych měl k dispozici digitální model terénu (DMT) zpracovávaného území, mohla by být provedena i *ortorektifikace*, při které by proběhla i korekce snímku na nadmořskou výšku. Bohužel se však pro účely této práce nepodařilo sehnat patřičná data digitálního modelu terénu pro polskou stranu a tak zůstává tento úkol otevřenou kapitolou do budoucna. Místo vstupu digitálního modelu terénu do procesu rektifikace jsem byl nucen vzhledem k tomu nastavit konstantní nadmořskou výšku 300 m.n.m.

Georeferencování jsem provedl na základě identifikace reprezentativního množství tzv. GCP (ground control points – shodných bodů) zpracovávaných dat LANDSAT 7 ETM+ a vektorových dat DMÚ25 a DMÚ200. Zvolena byla metoda nejbližšího souseda (Nearest neighbourhood), která jako jediná z nabízených nemění hodnotu obrazového pixelu, což je zásadní podmínka pro budoucí klasifikaci. Podařilo si mi dosáhnout průměrné chyby RMS rovno pixelu obrazových dat (tedy do cca 30 m) u všech čtyř snímků.

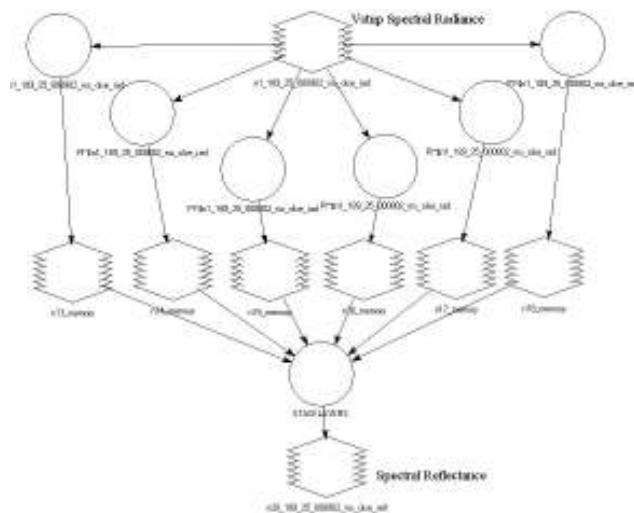


**Obrázek 3 - ukázka georeferencování snímku v prostředí ERDAS IMAGINE**

### 3.2.3 Převod z hodnot DN na odrazivost

Pro další vylepšení přesnosti klasifikace je vhodné převést naměřené nezpracované hodnoty DN na hodnoty spektrálního odrazu na nosiči. Tímto krokem se částečně odstraní vliv atmosféry jakožto rušivého elementu stojícím mezi snímačem umístěným ve vesmíru a snímaným prvkem na povrchu Země. Pro tyto účely jsem využil předem připravené modely pro zásuvný modul prostředí ERDAS – Model maker. Ty jsem měl k dispozici od ing. Pavla Hrdiny, který se danou problematikou zabýval v rámci své diplomové práce „Analýza sezónních změn

vegetace kvantifikováním vegetačního charakteru krajiny“ v roce 2006. Proto zájemce o tuto problematiku odkazují na výše uvedenou práci.



**Obrázek 4 - ukázka jednoho z modelů konverze DN na odrazivost**

Tyto korekce byly aplikovány pro všechny čtyři zpracovávané snímky.



**Obrázek 5 - srovnání výřezu původního snímku v DN (vlevo) a snímku převedeného do hodnot odrazivosti (vpravo)**


### 3.2.4 PAN sharpening

Pan-sharpening (image fusion) je technika digitálního zostření (spojení) obrazových dat, která kombinuje panchromatická (černobílá) data s vyšším

prostorovým rozlišením a multispektrální (barevná) data s prostorovým rozlišením nižším. Výsledným produktem jsou multispektrální data s rozlišením odpovídajícím původnímu rozlišení dat panchromatických.[3]

Jelikož se data snímače LANDSAT 7 ETM+ dodávají s multispektrálním i panchromatickým pásmem, které má dvojnásobné prostorové rozlišení (15m panchromatické oproti 30m multispektrální), mohl jsem přistoupit k aplikaci techniky *PAN sharpening* na multispektrální data. Tím jsem získal snímek v pravých barvách s větším prostorovým rozlišením, který jsem využil v procesu identifikace trénovacích ploch při tvorbě signatur řízené klasifikace (viz. dále).

V prostředí ERDAS IMAGINE se takováto funkce nazývá *resolution merge* (sloučení rozlišení) a nachází se v modulu *Image interpreter – Spatial enhancement*. V zobrazeném vstupním dialogu jsem vybral vstupní soubory multispektrálního a k němu odpovídajícího panchromatického snímku a název nově vzniklého „*pan sharpened*“ souboru. Algoritmus metody *pan sharpening* jsem ponechal na volbě *principal component*. Výsledkem tohoto kroku byl multispektrální obraz dvojnásobného prostorového rozlišení, který jsem dále využil pro snadnější definici trénovacích ploch.



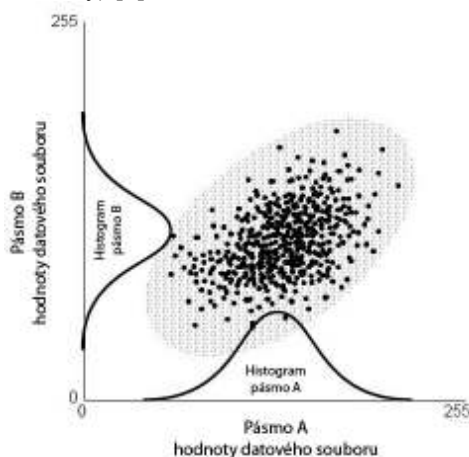
**Obrázek 6 - zvýšení prostorového rozlišení pomocí metody resolution merge**



### 3.2.5 PCA analýza snímku

Analýza hlavních komponent (PCA – Principal Component Analysis) je metoda zvýrazňování multispektrálního obrazu a používá se jednak jako prostředek zvýraznění barevného obrazu k následné vizuální interpretaci, jednak jako metoda předzpracování a zvýraznění obrazu před jeho automatickou klasifikací. Analýzou hlavních komponent lze další zpracování omezit na méně pásem bez podstatné ztráty informace – redukuje tedy rozměrnost (dimenzionalitu) zpracování.[3] PCA je statistická metoda, která rotuje osami vícerozměrného prostoru tvořícího multispektrální snímek, a to ve směru maximálního rozptylu dat.

Za předpokladu normální distribuce se zobrazují jednotlivá pásma v n-dimenzionálním histogramu jako elipsa (2 rozměry), elipsoid (3 rozměry), nebo hyperboloid (více než tři rozměry).[3]



Obrázek 7 - korelogram dvou sousedních multispektrálních pásem [3]

Nyní lze vytvořit nový souřadnicový systém, jehož první osa bude orientována ve směru maximálního rozptylu původních dat – tedy shodně s hlavní osou elipsy. Takto určená osa nového souřadnicového systému definuje pásmo nového (transformovaného) obrazu a nazývá se první **hlavní komponenta** (PC1). Druhá osa nového souřadnicového systému bude umístěna tak, aby byla kolmá k PC1, a to v místě druhého největšího rozptylu původních dat – tedy shodně s vedlejší osou elipsy, tato osa vytváří druhou hlavní komponentu (PC2) a ta obsahuje menší množství informace z původních pásem, avšak takové, která není popsána v předcházející komponentě. Naznačeným postupem lze definovat další komponenty, které jsou vždy kolmé na předcházející osu a procházejí nejširším místem elipsoidu ve vícerozměrném prostoru.[10]

V prostředí ERDAS IMAGINE se funkce PCA analýzy nachází v modulu *Spectral enhancement*. Po spuštění funkce *Principal component* jsem zvolil vstupní soubor analýzy, dále výstupní a počet komponent, které touto analýzou vzniknou.

Podle doporučení ing. Markéty Hanzlové jsem zvolil tvorbu čtyř hlavních komponent. Výsledky PCA analýzy snímku potom budou použity jako vstupní data neřízené i řízené klasifikace.



**Obrázek 8 - PCA snímek snímače LANDSAT 7 ETM+ (RGB kompozice PC3, PC2, PC1)**

### **3.2.6 Analýza feature space obrazu**


Způsob, který dovoluje vizuálně hodnotit kvalitu trénovacích ploch pro jednotlivé klasifikované třídy a také vhodnost vypočtených spektrálních příznaků pro tyto třídy, je graf korelačního pole DN hodnot mezi jakýmkoliv dvěma pásmy multispektrálního obrazu vstupujícími do klasifikace. V každém grafu jsou vyneseny DN hodnoty odpovídajících si pixelů. Osy grafu pro 8-bitová data mohou nabývat hodnot v intervalu 0 až 255. V závislosti na korelaci mezi zvolenými pásmy se v grafu vytváří obrazec různého tvaru. V případě vysoké korelace mezi dvěma pásmy má tento obrazec tvar úzké elipsy, orientované ve směru úhlopříčky. V případě korelační závislosti vytvářejí odpovídající pixely v grafu plošně rozsáhlý obrazec. Protože vycházíme z předpokladu, že pixely zahrnuté do trénovacích ploch mají normální rozdělení (a tuto normalitu lze testovat např. vykreslením histogramů), potom základní statistické charakteristiky vypočtené z pixelů trénovacích ploch pro jednotlivé třídy v obou uvažovaných pásmech – průměr a směrodatná odchylka – definují v korelogramu elipsu.[3]

#### **3.2.6.1 Feature space analýza v prostředí ERDAS IMAGINE**

V prostředí ERDAS IMAGINE můžeme provést analýzu *feature space* obrazu pomocí modulu Classification – Feature space image. V zobrazeném

dialogovém okně zvolíme pouze vstupní rastrový obraz a prefix nově vytvářených *feature spaced* kombinací jednotlivých pásem vstupního rastrového obrazu.

Tuto analýzu jsem prováděl s daty, které byly výstupem PCA analýzy. Pro vizuální hodnocení korelace jsem použil vždy kombinaci PC1 a PC2 komponenty všech čtyřech zpracovávaných scén. Dosažené výsledky a jejich interpretaci zachycuje obr.13.



**Obrázek 9 - výsledky analýzy feature space obrazu**

Závěry, které z této vizuální interpretace plynou jsou následující:

- Z hlediska spektrální separability jednotlivých pixelů se jeví jako nejlepší snímky 189\_25\_000514 a 189\_25\_020504.
- Jako zcela nevhodný se naopak jeví snímek 189\_25\_020605, který bude velice špatně separovatelný.

Teoretické pre-klasifikační závěry *feature space* analýzy obrazu jsou v dalším kroku potvrzeny či vyvráceny technikami neřízené a řízené klasifikace obrazu.

## 4 Klasifikace obrazu

Klasifikace obrazu je proces, při kterém je jednotlivým obrazovým prvkům přiřazován určitý informační význam. Jeho cílem je nahradit hodnoty radiometrických charakteristik původního obrazu, které vyjadřují spektrální vlastnosti objektů a jevů na něm zobrazených, hodnotami vyjadřujícími tzv. informační třídy. Typ a obsah nové informace (např. tematické mapy) závisí na zaměření celého projektu. Hledané informační třídy jsou definovány na počátku procesu klasifikace ve formě tzv. klasifikačního schématu – tedy legendy výsledné mapy.[3]

Klasifikace obrazu je založena na použití určitých rozhodovacích pravidel (tzv. klasifikátorů), podle nichž lze všechny prvky obrazu zařadit do určené třídy. Jak uvádí KOLÁŘ (1990), tyto klasifikátory mohou být obecně založeny na nejrůznějších vlastnostech objektů a jevů v obraze, tedy ne pouze na jejich spektrálním chování. Podmínkou však je, že jevy či objekty v obraze se v hodnotách porovnávaných vlastností vzájemně dostatečně odlišují.[3]

V současné době jsou k automatické klasifikaci obrazu nejvíce propracované a také nejvíce využívané klasifikátory založené na **spektrálním chování objektů**. K zařazení všech prvků obrazu do určité třídy používají multispektrálních dat a znalosti spektrálního chování objektů zobrazených na scéně. Vychází z předpokladu, že různé objekty budou vykazovat odlišné spektrální chování na základě svých odrazových nebo vyzářovacích vlastností. Za nejjednodušší způsob automatické klasifikace založený na znalosti odrazových a vyzářovacích vlastností využívající pouze jednoho pásma multispektrálního obrazu, lze považovat např. **techniky prahování**. Objekty podobných odrazových či zářivých vlastností se kumulují v určité části histogramu a lze je tedy oddělit od jiných objektů, které by teoreticky měly zaujímat jinou část histogramu.[3]

V důsledku mnoha vnějších i vnitřních vlivů jsou spektrální vlastnosti různých objektů v určitém intervalu spektra podobné. Použití jednoho intervalu spektra – jednoho pásma – nám dává možnost rozlišit objekty pouze na základě jedné charakteristiky. Celý koncept lze tedy zobecnit a použít pro charakterizování objektů a jevů více charakteristik – více pásem, která potom definují osy tzv. multispektrálního prostoru. Pokud naměřená či vypočtená charakteristika každého objektu v určitém pásmu (intervalu spektra) bude zároveň představovat charakteristiku, podle které bude možné objekt rozpoznat – tzv. příznak – potom lze každé pásmo označit jako jeden rozměr tzv. příznakového prostoru.[3]

Nejčastěji používané klasifikátory založené na spektrálních vlastnostech jevů a objektů se označují také jako bodové („per-pixel“) klasifikátory, protože k zařazení obrazových prvků do jednotlivých tříd nepoužívají vlastností a příznaků okolních pixelů, ale pouze pixelu klasifikovaného.[3]

Klasifikaci lze obecně dělit na **klasifikaci řízenou** a **klasifikaci neřízenou** podle toho jakým způsobem a především v kterém okamžiku zpracovatel zasahuje do procesu klasifikace. Při řízené klasifikaci zpracovatel předem specifikuje výpočetnímu algoritmu numerický popis hledaných povrchů na scéně ve formě tzv. trénovacích ploch. To jsou části obrazu, o kterých může zpracovatel na základě nejrůznějších podpůrných dat (např. mapy, letecké snímky, výsledky pozemního průzkumu apod.) bezpečně prohlásit, že představují známý povrch. Pro každou kategorii předem sestaveného klasifikačního schématu jsou vygenerovány statistické charakteristiky spektrálních příznaků. S nimi je postupně porovnáván každý obrazový prvek a podle zvoleného pravidla (klasifikátoru) je zařazen do určité třídy.[3]

## 4.1 Postup klasifikace v ERDAS IMAGINE

### 4.1.1 Neřízená klasifikace

Neřízenou klasifikaci zpracovávaných satelitních dat povodí řeky Olše jsem provedl v produktu ERDAS IMAGINE pomocí jeho modulu **Classifier**. Po zvolení vstupního klasifikovaného a výstupního klasifikovaného souboru jsem, vzhledem k použitému algoritmu ISODATA nastavil již jen několik parametrů a neřízená klasifikace proběhla dále zcela automatizovaně.

Těmito parametry byly zejména:

- Počet požadovaných výstupních *spektrálních* tříd – nastavena hodnota **30**. Je vždy lepší nastavit větší počet tříd, které následně agregujeme do reprezentativního množství tříd *informačních*.
- Maximum iterací – zvolil jsem 10 iterací. Shlukový iterační algoritmus ISODATA tedy proběhne maximálně desetkrát. Tato hodnota se mi v praxi jeví jako rozumným kompromisem mezi přesností klasifikace a dobou výpočtu. Nevhodně zvoleným velkým počtem iterací a prahem konvergence bychom neúměrně mohli prodloužit výpočet neřízené klasifikace bez významného zvýšení její přesnosti.
- Práh konvergence – nastaven na 0.950. V praxi tato hodnota znamená to, že iterační proces končí, pokud se nezmění poloha 95% (a více) zpracovávaných pixelů.

Postupně jsem provedl neřízenou klasifikaci pro všechny čtyři satelitní snímky. Ty jsem dále vhodným způsobem *reklasifikoval* za pomoci podpůrných dat CLC. Tím jsem si udělal představu o separabilitě jednotlivých tříd, čehož jsem dále využil při definování trénovacích ploch a signatur při provádění řízené klasifikace.

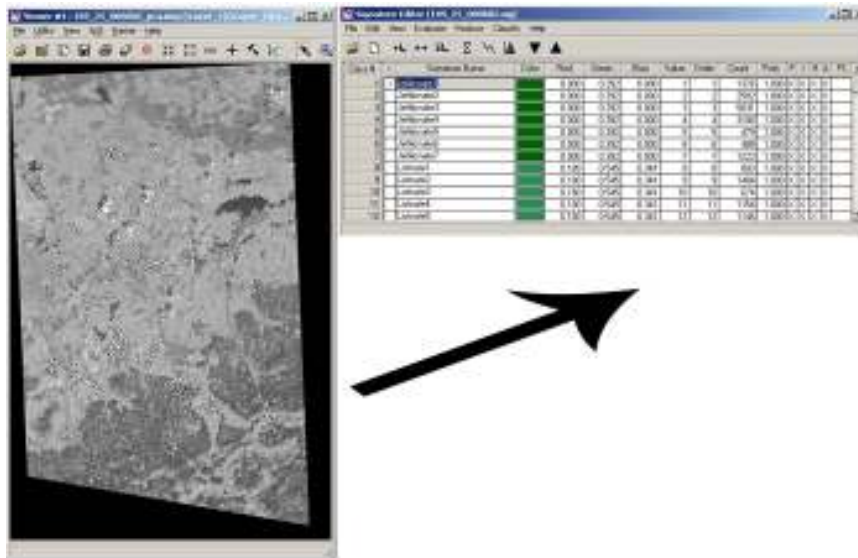
Třídy, které jsem identifikoval z výsledku neřízené klasifikace

- Jehličnatý les
- Listnatý les

- Urbanizovaná území
- Oblačnost
- Pole
- Voda
- Zeleň

#### 4.1.2 Řízená klasifikace v ERDAS IMAGINE

Jak již bylo popsáno výše v teoretickém popisu principů a postupu řízené klasifikace, každá řízená klasifikace obrazu začíná definováním vhodných reprezentativních signatur obrazu podle zvoleného klasifikačního schématu. K tomu v prostředí ERDAS IMAGINE slouží nástroj *Signature editor* obsažený v modulu *Classifier*. V něm jsem postupně vkládal nové signatury jednotlivých požadovaných identifikovaných typů krajinného pokryvu. Ty jsem identifikoval na základně **polygonového výběru** tzv. oblastí zájmu (AOI – area of interest), které jsem zvolením funkce *Create New Signature(s) from AOI* přímo vkládal do *Signature editoru*. Vstupním klasifikovaným obrazem byl výsledek PCA analýzy jednotlivých snímků.




Obrázek 1 - tvorba signatur v ERDAS IMAGINE

Jak vidíme na obr.č.15, tak každý polygonový výběr oblasti zájmu vytvoří novou spektrální signaturu, kterou musíme identifikovat a přiřadit jí námi požadovanou barvu (odstín barvy).

Po úspěšném dokončení tvorby jednotlivých signatur jsem provedl jejich spojení do požadovaného počtu *informačních tříd* (které jsou shodné s počtem a názvy tříd použitého klasifikačního schématu).

Nyní jsem mohl přistoupit k samotné řízené klasifikaci obrazu, a to za použití všech tří nabízených algoritmů. Výsledkem tohoto kroku tedy byl soubor tří rastrových obrazů zachycujících výsledky řízené klasifikace algoritmy maximální shody, minimální spektrální vzdálenosti a mahalnobisovy vzdálenosti.

Porovnáním výsledných rastrových obrazů, které produkovaly jednotlivé algoritmy jsem dospěl k závěru, že nejlepší výsledky klasifikace produkuje algoritmus maximální věrohodnosti, případně algoritmus mahalnobisovy vzdálenosti, který podává srovnatelné výsledky. Jako nevhodný naopak hodnotím algoritmus minimální spektrální vzdálenosti, který v tomto případě produkoval nereprezentativní výsledky klasifikace krajinného pokryvu. Jako nejvhodnější jsem tedy zvolil výsledky produkované algoritmem maximální věrohodnosti se kterými jsem dále pracoval a jehož výsledky prezentuji.



**Obrázek 11 - porovnání vlivu algoritmů maximální shody a minimální spektrální vzdálenosti**

#### 4.1.3 Postklasifikační úpravy

Pro interpretaci klasifikovaných dat je vhodné výstupní rastrové soubory algoritmů řízené klasifikace ještě dále post-klasifikačně upravit. Tímto termínem máme na mysli především aplikace konvolučního filtru velikosti 3x3 pixelů, který data vhodným způsobem generalizuje a vyhladí. Z obrazu jsou odstraněny osamocené pixely odlišných informačních tříd.

V prostředí ERDAS IMAGINE jsem konvoluční filtr nad danými daty provedl volbou funkce **Fuzzy convolution** modulu Classifier, parametry filtru (matice 3x3 která je aplikována na okolní pixely násobící koeficienty) jsou následující:

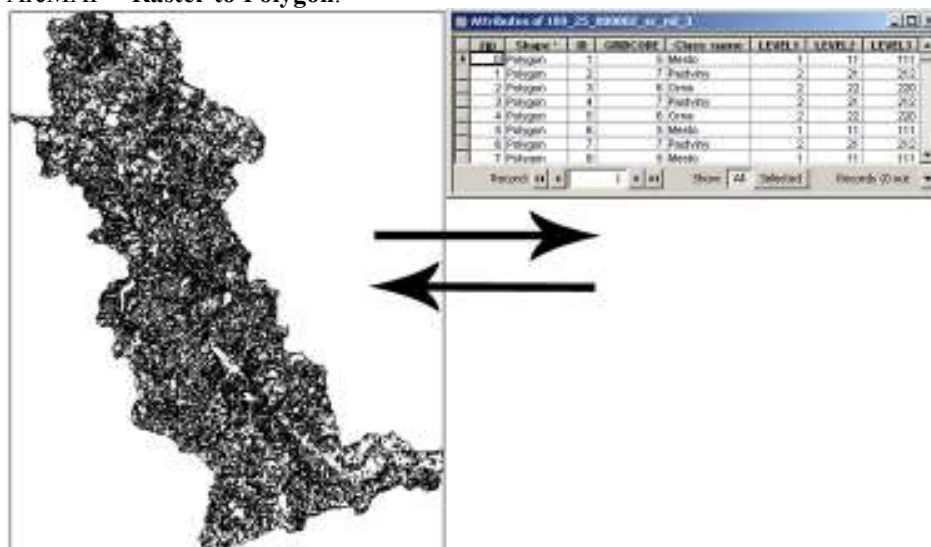
**tabulka 1 - parametry konvolučního filtru**

0.500	0.646	0.500
0.646	1.000	0.646
0.500	0.646	0.500



Obrázek 2- výsledek klasifikace před a po použití konvolučního filtru

Finální úpravou klasifikovaných dat byla konverze rastrové podoby výsledků klasifikace do podoby vektorové (polygonové). K tomu jsem použil funkci produktu ArcMAP – **Raster to Polygon**.



Obrázek 3 - vektorová podoba výsledků klasifikace s atributovou tabulkou

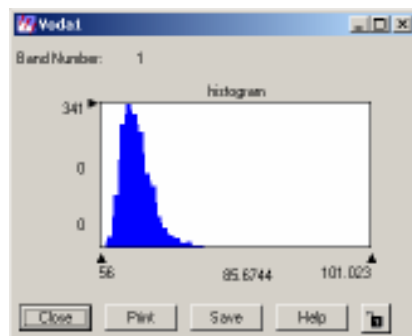
V získaných vektorových datech jsem nakonec upravil atributovou tabulku tak, aby zachycovala všechny tři úrovně použitého klasifikačního schématu. Toho jsem docílil přidáním tří nových atributů: LEVEL1, LEVEL2 a LEVEL3. Jim jsem doplnil identifikační kódy podle aktuální úrovně klasifikačního schématu a hodnoceného krajinného prvku.

#### 4.1.4 Hodnocení přesnosti klasifikace

Hodnocení vhodnosti trénovacích ploch a z nich vytvořených signatur je možné provádět několika způsoby. Spektrální příznaky mohou být zobrazeny **graficky** v mnoha formách – například jako **histogramy** pro jednotlivé třídy u nichž



sledujeme normalitu rozložení hodnot pro jednotlivé třídy a pásma klasifikovaného obrazu.[3]



**Obrázek 4 - ukázka histogramu třídy "voda" pro první pásmo zpracovávaného obrazu**

Dalšími možnostmi grafického znázornění statistických charakteristik trénovacích ploch jsou:

- **spektrogram** - ten znázorňuje pro vybrané třídy jak průměr, tak i rozptyl hodnot pixelů z trénovacích ploch v rámci každého pásma.
- **korelogram** - graf korelačního pole DN hodnot mezi jakýmkoliv dvěma pásmy multispektrálního obrazu vstupujícího do klasifikace.

[3]

O kvalitě trénovací etapy se lze přesvědčit také dalšími způsoby. Jedním z nich je například **klasifikace dat v trénovacích plochách**, kdy namísto celé scény jsou klasifikovány pouze pixely uvnitř trénovacích ploch a v tzv. **chybové matici** je zaznamenáno, kolik pixelů je správně klasifikováno. Tento přístup však pouze vypovídá o kvalitě trénovacích ploch, nic neříká o úspěchu celkové klasifikace. Celkovou úspěšnost klasifikace lze testovat na tzv. **testovacích plochách**, vymezených ve scéně mimo trénovací plochy.[3]

Vhodnosti trénovacích ploch jsem zjistil v prostředí ERDAS pomocí funkce *Contingency* obsažené v nástroji *Signature editor* modulu *Classifier*. Tímto jsem vytvořil kontingenční chybovou matici jednotlivých natrénovaných ploch, jak je popisováno výše.

**tabulka 2 - chybová kontingenční matice trénovacích ploch**

	Jehli č.	Listn .	Smíš. .	Měst o	Orn á	Pastvi ny	Vo da	Křovin y	Obl .
Jehlič.	7463	1237	3422	202	61	110	817	717	0
Listn.	1068	6118	3585	216	631	479	55	391	0
Smíš.	1736	1972	5400	595	779	249	50	360	0
Město	241	406	745	1190 2	910	877	595	105	10

<b>Orná</b>	500	1267	1057	4658	298 86	2109	299	276	13
<b>Pastviny</b>	386	1454	812	1905	292 8	10426	230	240	0
<b>Voda</b>	34	74	88	99	41	73	269 59	4	0
<b>Křoviny</b>	<b>2766</b>	<b>2440</b>	<b>3062</b>	<b>296</b>	<b>542</b>	<b>1091</b>	<b>308</b>	<b>924</b>	<b>0</b>
<b>Obl.</b>	89	7	21	147	119	137	297	16	242 4

Vyhodnocení přesnosti klasifikace pro jednotlivé krajinné prvky pomocí kontingenční chybové matice je následující:

- Dobré výsledky klasifikace (spektrální separabilitu) mají třídy **město, orná půda, pastviny, voda a oblačnost** – přesnost klasifikace se pohybuje okolo požadované hodnoty 85 procent. Tyto třídy tedy podávají reprezentativní výsledky krajinného pokryvu zpracovávaných snímků.
- Relativně dobré výsledky klasifikace podávají i jednotlivé třídy lesního porostu. Přesto jsou tyto hodnoty již zatíženy větší chybovostí, která se odráží v menší jistotě správně klasifikovaného typu povrchu.

Naprostě neuspokojivé výsledky podává třída **Křoviny**, která je velice obtížně spektrálně oddělitelná od jiných typů povrchů (převážně lesním porostem). Proto bych pro potřeby klasifikace navrhol **třídu křovin z klasifikačního schématu vyřadit**.

## 5 Závěr

Tato diplomová práce se zabývala klasifikací krajinného pokryvu povodí řeky Olše a všemi nutnými kroky, které tomu předcházely. V úvodu byla nastíněna obecná problematika klasifikačních schémat, byl představen používaný software a satelitní platforma LANDSAT se zaměřením na snímač ETM+, který je obsažen na palubě satelitu LANDSAT7. Poté byly popsány veškeré postupy, které vedly ke klasifikaci krajinného pokryvu.

Prováděné postupy začaly od nejobecnějších principů zpracování satelitního obrazového snímku snímače LANDSAT 7 ETM+ a končili samotným provedením řízené (a neřízené) klasifikace krajinného pokryvu.

V úvodu bylo nutné snímky vhodným způsobem **předzpracovat**. V této oblasti jsem provedl především aplikaci některých vhodných **radiometrických, atmosférických a geometrických** korekcí a zvýraznění. Jednalo se zejména o:

- Ořez snímků pro pilotní oblast povodí řeky Olše.
- Georeferencování snímků.
- Atmosférické korekce včetně převodu DN hodnot na hodnoty reflektance (odrazivosti).

- Resolution merge multispektrálního a panchromatického snímku pro lepší identifikaci trénovacích ploch.
- PCA analýza obrazu (snížení dimenzionality obrazu, komprese obrazového záznamu, odstranění šumu) do čtyřech hlavních komponent.
- Analýza feature space obrazu pro hodnocení vhodnosti snímků ke klasifikaci.

Poté jsem mohl provést samotnou požadovanou klasifikaci obrazu. Nejprve se jednalo o neřízenou automatizovanou klasifikaci pomocí shlukovacího algoritmu ISODATA pomocí kterého jsem si udělal představu o množství separovatelných tříd. Následně jsem přistoupil k **řízené klasifikaci obrazu**. Porovnáním výsledků všech tří algoritmů, které prostředí ERDAS IMAGINE nabízí jsem dospěl k výsledku, že nejvhodnějším bude použit algoritmus maximální shody. Následně jsem provedl některá postklasifikační úpravy klasifikovaného obrazu, konkrétně filtraci obrazu konvoluční maticí 3x3 pixelů pro vyhlazení výsledků a převod rastrové podoby výsledků do podoby vektorové (polygonové).

V závěru jsem zhodnotil výsledky klasifikace a uvedl závěry k jednotlivým identifikovaným krajinným prvkům. Přesnost klasifikace jsem hodnotil pomocí tzv. chybové matice, která hodnotí spektrální separabilitu jednotlivých tříd. Tu jsem vytvořil pro snímek ze 4.5.2002, který jsem navrhnul jako nejvhodnější pro další zpracování v rámci vstupu modelů srážko-odtokových vztahů. Detekovatelnost zvolených tříd klasifikačního schématu byla poměrně dobrá, pouze třída **křoviny** podávala zcela nejednoznačné výsledky, proto jsem navrhl její vyloučení. Diskutabilní je také použití tříd **jehličnatý les, listnatý les a smíšený les**, u kterých mohou být výsledky rovněž zatíženy větší mírou nejistoty.

## 6 Seznam referencí

1. GAJDUŠKOVÁ, Radka. *KČT Moravskoslezský kraj : rezervační a informační systém* [online]. Aktualizováno. Český Těšín : Klub českých turistů, 2004 , 18.5.2004 [cit. 2007-03-08]. Dostupný z WWW: <<http://www.kct-msk.cz/encyklopedie/objekty1.phtml?id=112026&user=24&session=58348551&menu=&lng=>>>.
2. *Olše (řeka) : Wikipedie, otevřená encyklopedie* [online]. 2007 , 5.3.2007 [cit. 2007-03-08]. Dostupný z WWW: <[http://cs.wikipedia.org/wiki/Ol%C5%A1e\\_%28%C5%99eka%29](http://cs.wikipedia.org/wiki/Ol%C5%A1e_%28%C5%99eka%29)>.
3. DOBROVOLNÝ, Petr. *Dálkový průzkum Země : Digitální zpracování obrazu*. 1. vyd. Brno : Masarykova univerzita, 1998. 208 s. ISBN 80-210-1812-7.
4. LILLESAND, Thomas M., KIEFER, Ralph W. *Remote sensing and image interpretation : Third Edition*. Barry Harmonn and Marian Provenzano; Jaime Perea. 3rd edition. USA : John Wiley & Sons, Inc., 1994. 750 s.
5. NASA, Landsat 7 Science Data Users Handbook [online]. c1998, Poslední revize 28.2 2006, [cit. 2006-03]. Dostupný z <[http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook\\_toc.html](http://ltpwww.gsfc.nasa.gov/IAS/handbook/handbook_toc.html)>.
6. VOŽENÍLEK V.: *Zásady tvorby mapových výstupů* [online]. Přírodovědecká fakulta UP Olomouc, Ostrava 2002, 42 stran. Dostupný z <[http://gis.vsb.cz/PAN/Skoleni\\_Texty/TextySkoleni/kartografie.pdf](http://gis.vsb.cz/PAN/Skoleni_Texty/TextySkoleni/kartografie.pdf)>.
7. *Landsat 7 : Wikipedia, the free encyclopedia* [online]. 2007 , 12.3.2007 [cit. 2007-03-12]. Dostupný z WWW: < [http://en.wikipedia.org/wiki/Landsat\\_7](http://en.wikipedia.org/wiki/Landsat_7)>.
8. ANDRERSON, James, et al. A Land Use And Land Cover Classification System For Use With Remote Sensor Data. In *U.S. Geological Survey Circular*. Washington : United States Government Printing Office, 1976. s. 1-41. Dostupný z WWW: <<http://landcover.usgs.gov/pdf/anderson.pdf>>.
9. *CORINE Land Cover (CLC)* [online]. Praha : CENIA, česká informační agentura životního prostředí, [2005] [cit. 2007-04-23]. Dostupný z WWW: <[http://www.cenia.cz/www/webapp.nsf/webitems/GIS\\_CORINE](http://www.cenia.cz/www/webapp.nsf/webitems/GIS_CORINE)>.
10. SCHRADER, Stacey, POUNCEY, Russ. *ERDAS Field Guide : Fourth edition, Revised and Expanded*. 4th enl. edition. Atlanta : [s.n.], 1997. 686 s. Dostupný z WWW: <<http://support.erdas.com/documentation/files/FieldGuide.pdf>>.