

UNIVERZITA KARLOVA V PRAZE

Přírodovědecká fakulta

katedra aplikované geoinformatiky a kartografie



**KLASIFIKACE LAND COVER Z HYPER SPEKTRÁLNÍCH
DAT V REKULTIVOVANÝCH OBLASTECH
SOKOLOVSKÉ HNĚDOUHELNÉ PÁNVE**

Diplomová práce

Hana Málková

srpen 2010

Vedoucí práce: Ing. Markéta Potůčková, Ph.D.

Zadání diplomové práce

pro Hanu Málkovou
obor Kartografie a geoinformatika

Název tématu: Klasifikace land cover z hyperspektrálních dat v rekultivovaných oblastech Sokolovské hnědouhelné pánve

Zásady pro vypracování

Diplomová práce si klade za cíl vytvořit metodiku podrobné klasifikace vegetačního pokryvu z hyperspektrálních dat za účelem vytvoření podkladové mapy pro studium vlivu těžby na zdravotní stav vegetace v okolí povrchových lomů a na rekultivovaných výsypkách. Zájmové území o rozloze 200 km² v oblasti Sokolovska bylo snímkováno v červenci 2009 senzorem HyMap s rozlišením 5 m.

V prvním kroku bude ve spolupráci s odborníky v oblasti botaniky definována legenda v takovém stupni podrobnosti, aby vyhovovala potřebám dalších výzkumů. Vlastní klasifikace bude řešena s využitím software ENVI. Vzhledem k velikosti pixelu a požadované podrobnosti výsledku by měly být vyzkoušeny možnosti subpixelové klasifikace a měla by být zodpovězena otázka, jaké míry podrobnosti klasifikace lze s danými daty dosáhnout. Pro verifikaci výsledků budou využity stávající mapy lesních porostů a výsledky terénního šetření. Výsledky práce budou součástí řešení projektu Grantové agentury Akademie věd „Assessment of Mining Related Impacts Based on Utilization of ARES Airborne Hyperspectral Sensor“.

Rozsah grafických prací: mapy vegetačního pokryvu zájmového území

Rozsah průvodní zprávy: 60 stran textu

Seznam odborné literatury:

ENVI, 1997: *ENVI Tutorial: Vegetation Hyperspectral Analysis*. Colorado. 14 p. Dostupné z [http://www.itvis.com/portals/0/tutorials/envi/Vegetation_Analysis.pdf]

BAJCSY, P., GROVES, P., 2004: *Methodology for hyperspectral band selection*. *Photogrammetric Engineering and Remote Sensing journal*, University of Illinois, vol. 70, number 7, July 2004, p. 793-802

CHANG, CHEIN-I, 2003: *Hyperspectral imaging: techniques for spectral detection and classification*. New York, Kluwer Academic. 370 p.

KAYITAKIRE, F., DEFOURNY, P. 2004: *Forest type discrimination using multi-angle hyperspectral data*. Department of Environmental Sciences and Land Use Planning, Université Catholique de Louvain, Belgium. 13 p.

LUMME, J.H., 2004: *Classification of vegetation and soil using imaging spectrometer data*. Institute of Photogrammetry and Remote Sensing, Helsinki University of Technology. 5 p.

TONG, Q., JIAO, Q., ZHANG, X., 2002: *Forest Species Classification Based on Hyperspectral and Multitemporal CHRIS Images*. Chinese Academy of Science, Beijing. 5p

Vedoucí diplomové práce: Ing. Markéta Potůčková PhD. (KAGIK PŘF UK)

Konzultant diplomové práce: Ing. Jan Hanuš (ÚSBE AV ČR v.v.i.)

Datum zadání diplomové práce:

Termín odevzdání diplomové práce: podzim 2009

Platnost tohoto zadání je po dobu jednoho akademického roku.

.....
Vedoucí diplomové práce

.....
Vedoucí katedry

V Praze dne

Prohlášení kvalifikační práce

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně a že jsem všechny použité prameny řádně citovala.

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

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

V Jablonci nad Nisou dne 1. září 2010

.....

Hana Málková

Klasifikace land cover z hyperspektrálních dat v rekultivovaných oblastech Sokolovské hnědouhelné pánve

Abstrakt

Předkládaná diplomová práce si klade za cíl vytvořit metodiku klasifikace vegetačního pokryvu z hyperspektrálních dat ze senzoru HyMap. Výstupem práce je podkladová mapa pro studium vlivu těžby na zdravotní stav vegetace v okolí povrchových lomů Sokolovské hnědouhelné pánve. Na data bylo aplikováno pět různých klasifikačních algoritmů a nejlepší výsledek byl zpřesněn druhým kolem klasifikace. Vzhledem k velikosti pixelu a požadované podrobnosti výsledku byly vyzkoušeny možnosti subpixelové klasifikace a byla zodpovězena otázka, jaké míry podrobnosti klasifikace lze s danými daty dosáhnout. Výsledky práce jsou součástí řešení projektu „Assessment of Mining Related Impacts Based on Utilization of ARES Airborne Hyperspectral Sensor“.

Klíčová slova: hyperspektrální data HyMap, klasifikace land cover, klasifikační algoritmy, subpixelová analýza, Sokolovská hnědouhelná pánev

Land cover classification from hyperspectral images in recultivated area of the Sokolov lignite basin

Abstract

The aim of the dissertation is to establish a methodology for vegetation classification from hyperspectral data of the HyMap sensor. The final output is a supporting map for the investigation of mining impacts on vegetation health in the vicinity of surface quarries at the Sokolov lignite basin. Five different classification algorithms were applied on the data and the best result was put more precisely in the second classification round. Given the pixel size and desired result details, subpixel classification options were tested and the question of what level of classification details could be achieved with given data was answered. The results are part of the project "Assessment of Mining Related Impacts Based on Utilization of Airborne Hyperspectral Sensor ARES“.

Keywords: hyperspectral image data HyMap, land cover mapping, the classification algorithm, subpixel analysis, Sokolov lignite basin

OBSAH

Seznam obrázků	6
Seznam tabulek	7
1 Úvod a cíle práce	8
2 Oblast zájmu – Sokolovská hnědouhelné pánve	10
2.1 Přírodní podmínky	10
2.2 Historie a současnost těžby	11
2.3 Vliv těžební činnosti	12
3 Hyperspektrální data	14
3.1 Hyperspektrální obrazová data	14
3.2 Hyperspektrální obrazové senzory	16
3.3 Využití a studie zpracovávající hyperspektrální obrazová data	18
4 Spektrální vlastnosti krajinných objektů a klasifikace	21
4.1 Spektrální vlastnosti krajinných objektů	21
4.1.1 Vegetace	21
4.1.2 Vodní plochy	23
4.1.3 Holý povrch bez vegetace	24
4.2 Klasifikace	25
4.2.1 Klasifikátor minimální vzdálenosti („minimum distance“)	26
4.2.2 Klasifikátor maximální věrohodnosti („maximum likelihood“)	26
4.2.3 Klasifikátor neuronových sítí („neural net“)	28
4.2.4 Klasifikátor spektrálních úhlů („spectral angle mapper“)	30
4.3 Subpixelová klasifikace	31
5 Zpracování obrazových dat HyMap	35
5.1 ENVI	35
5.2 Obrazová data HyMap	35
5.3 Předzpracování obrazových dat	35
5.4 Mozaikování obrazových dat	37
5.5 Klasifikace obrazových dat	38
5.6 Postklasifikační úpravy obrazových dat	43

5.7 Subpixelová analýza obrazových dat	44
6 Hodnocení a porovnání klasifikací obrazových dat HyMap	46
6.1 Porovnání přesnosti klasifikací obrazových dat	46
6.2 Porovnání relativního zastoupení tříd v klasifikaci	47
6.2.1 Hodnocení klasifikace algoritmem neurálních sítí	47
6.2.2 Hodnocení klasifikace algoritmem spektrálních úhlů	49
6.2.3 Hodnocení klasifikace algoritmem minimální vzdálenosti	50
6.2.4 Hodnocení klasifikace algoritmem maximální věrohodnosti	51
6.2.5 Hodnocení klasifikace algoritmem Mahalanobisovy vzdálenosti	51
6.2.6 Hodnocení subpixelové analýzy Linear Spectral Unmixing	52
6.3 Porovnání vybraných modelových území	52
6.4 Shrnutí dosažených výsledků	56
7 Diskuze postupu zpracování a výsledků	58
8 Závěr	63
Seznam použitých zdrojů	65
Seznam příloh	70

SEZNAM OBRÁZKŮ

Obr. 1	Zájmová oblast Sokolovské hnědouhelné pánve	9
Obr. 2	Vývoj těžby uhlí a skrývky v Sokolovské pánvi	11
Obr. 3	Pohled na Lomnickou výsypku a výsypku Lítov	12
Obr. 4	Plochy ukončených rekultivací	13
Obr. 5	Ukázka spektrálních křivek odrazivosti pro vegetaci a pro holou půdu	15
Obr. 6	Hyperspektrální skener HyMap	17
Obr. 7	Spektrální křivky vegetace	22
Obr. 8	Spektrální křivka vody	24
Obr. 9	Spektrální křivky holé půdy	25
Obr. 10	Struktura biologického neuronu	29
Obr. 11	Struktura umělého neuronu	29
Obr. 12	Znázornění spektrálního úhlu mezi dvěma materiály A a B v rámci dvou kanálů ...	31
Obr. 13	Znázornění spektrálně mixovaného pixelu	32
Obr. 14	Nákres Overlay Annotation	38
Obr. 15	Grafické znázornění směrodatné odchylky v závislosti na počtu iterací	42
Obr. 16	Síťový filtr	44
Obr. 17	Ukázka analýza Linear Spectral Unmixing pro třídu lesů ve stáří nad 40 let	45
Obr. 18	Verifikace klasifikace algoritmem neurálních sítí podle lesnické mapy	48
Obr. 19	Porovnání klasifikace první modelové oblasti severně od Sokolova	53
Obr. 20	Porovnání klasifikace druhé modelové oblasti východně od obce Háj	54
Obr. 21	Porovnání klasifikace třetí modelové oblasti východně od obce Vřesová	55

SEZNAM TABULEK

Tab. 1	Porovnání multispektrálních a hyperspektrálních dat	15
Tab. 2	Přehled nejběžněji používaných hyperspektrálních senzorů	17
Tab. 3	Příklad funkčnosti umělého neuronu za použití aktivační funkce TLU	30
Tab. 4	Přehled klasifikovaných tříd z obrazových dat HyMap	40
Tab. 5	Přehled celkových přesností klasifikací	46
Tab. 6	Relativní zastoupení tříd v klasifikaci algoritmem neurálních sítí v 1. kole	49
Tab. 7	Relativní zastoupení tříd v klasifikaci algoritmem neurálních sítí v 2. kole	49
Tab. 8	Relativní zastoupení tříd v klasifikaci algoritmem spektrálních úhlů	50
Tab. 9	Relativní zastoupení tříd v klasifikaci algoritmem minimální vzdálenosti	50
Tab. 10	Relativní zastoupení tříd v klasifikaci algoritmem maximální věrohodnosti	51
Tab. 11	Relativní zastoupení tříd v klasifikaci algoritmem Mahalanobisovy vzdálenosti	51
Tab. 12	Relativní zastoupení tříd po aplikaci subpixelové analýzy	52

KAPITOLA 1

Úvod a cíle práce

Intenzivní těžba hnědého uhlí je podstatným faktorem, který ovlivňuje životní prostředí v Sokolovské pánvi. Vlastní těžba i následující zpracování jsou provázeny negativními vlivy na životní prostředí a způsobují transformaci a degradaci krajiny, zpracováním se zatěžuje životní prostředí emisemi znečišťujících látek vypouštěných do ovzduší a do vody. Jedním z negativních projevů důlní činnosti je zánik původních ekosystémů v důsledku jejich odtěžení či překrytí výsypkovými substráty. Prostředkem pro zahlazení vlivů těžební činnosti jsou rekultivace krajiny, jejichž cílem je dosažení maximální diversity (rozmanitosti) a estetické hodnoty rekultivované krajiny. Cílem rekultivačních činností na Sokolovsku je vznik biologicky hodnotných ekosystémů na vzniklých výsypkách, přičemž jedním ze základních předpokladů je obnova půd.

Další stěžejní částí rekultivačních prací je ochrana, rozvoj a obnova lesního fondu. Výsadba lesních porostů tvoří z celkové plochy téměř dvě třetiny z celkových rekultivací, které byly realizovány v regionu do konce roku 2007. Celkově tak lesnické rekultivace proběhly na ploše 1 830 ha a dovolily tak vzniku unikátních biotopů, např. arboretum vytvořené na výsypce v prostoru sokolovského gymnázia (Sokolovská uhelná, a. s., 2007).

Předkládaná diplomová práce je součástí řešení projektu Grantové agentury Akademie věd „Assessment of Mining Related Impacts Based on Utilization of ARES Airborne Hyperspectral Sensor“, který se zabývá hodnocením vlivu těžební činnosti na krajinu Sokolovska, a to především zdravotní stav vegetace v okolí současné i již ukončené těžby.

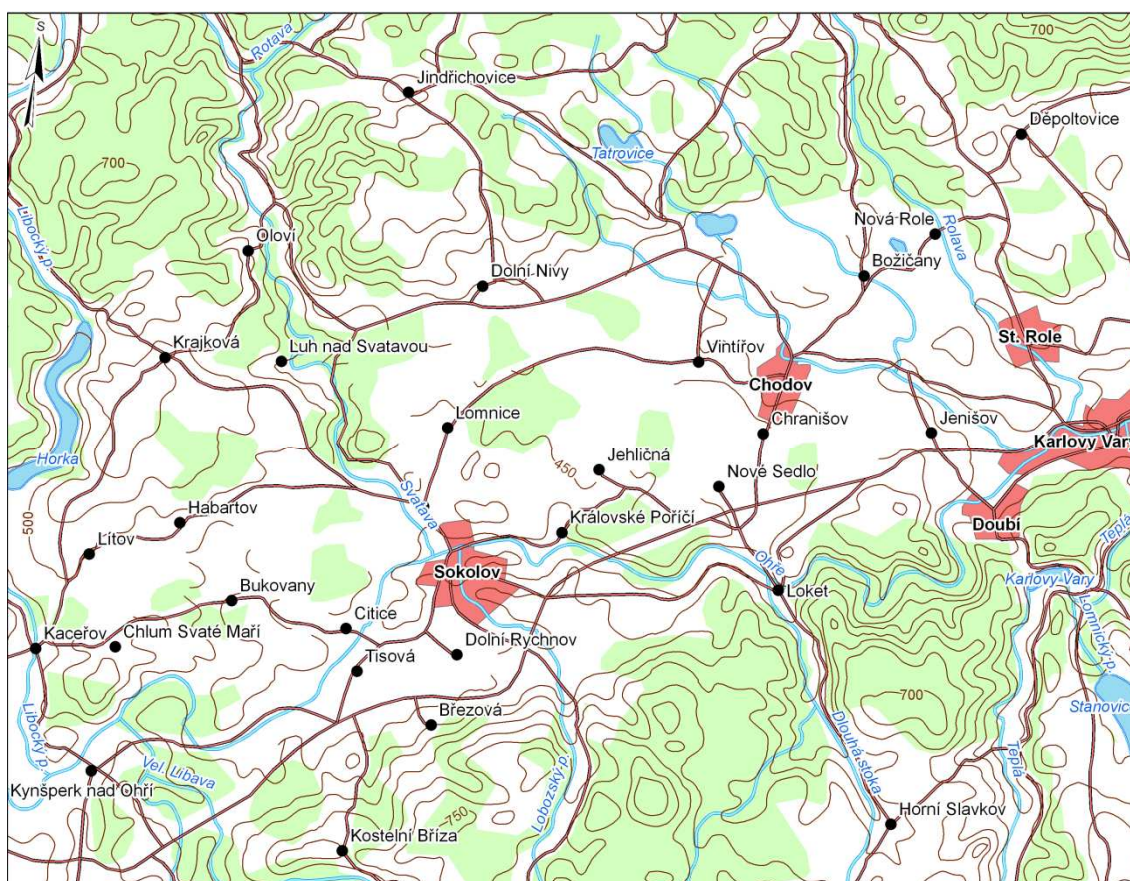
Primárním podkladem pro zhodnocení vlivu těžby na krajinu v Sokolovské pánvi jsou hyperspektrální letecké snímky, které byly pořízeny v červenci 2009 leteckým hyperspektrálním senzorem HyMap a data získaná z pozemní kampaně, která probíhala souběžně s leteckým snímkováním. Rozloha zájmového území je přibližně 200 km².

Diplomová práce si klade za cíl vytvořit metodiku podrobné klasifikace vegetačního pokryvu za účelem vytvoření podkladové mapy pro studium vlivu těžby na zdravotní stav vegetace v okolí povrchových lomů a na rekultivovaných výsypkách.

Hlavním výstupem práce je vytvoření podkladových map land use zájmové oblasti a také porovnání výsledků klasifikačních algoritmů (klasifikátor neuronových sítí, maximální věrohodnosti, minimální vzdálenosti, spektrálních úhlů a Mahalanobisovy vzdálenosti), pomocí nichž budou data analyzována. Dílčím cílem je zjištění možností subpixelové klasifikace k zodpovězení otázky, jaké míry podrobnosti klasifikace lze

s danými daty dosáhnout. K verifikaci výsledků budou využity porostní mapy a výsledky terénního šetření.

Úvodní část práce bude zaměřena na teoretický pohled na danou tematiku, rešerši a diskuzi dostupných pramenů a zdrojů dat a návrh legendy dle potřeb dalšího vypracování projektu. V další části bude zpracována metodika, jež byla na data aplikována, postup prací a dosažené výsledky. Dále bude následovat porovnání výsledků a určení přesnosti klasifikace a zhodnocení.



Obr. 1 Zájmová oblast Sokolovské hnědouhelné pánve

Zdroj: autorka, ArcGIS 9.3.

KAPITOLA 2

Oblast zájmu – Sokolovská hnědouhelná pánev

2.1 Přírodní podmínky

Zájmové území Sokolovské pánve se rozkládá na ploše přes 200 km² (8-9 km šířky a 36 km délky) v oblasti západně od Karlových Varů k Liticím a Habartovu, přičemž osu oblasti tvoří řeka Ohře protékající od západu k východu. Terén pánve se zvedá k severu k podhůří Krušných hor a k jihu k Slavkovskému lesu. Hlavními geologickými epochami, které utvářely a formovaly vzhled Sokolovské pánve, bylo období starších třetihor a čtvrtohor. Sokolovská pánev náleží ke krušnohorskému bloku Českého masivu a nachází se v jihozápadní části podkrušnohorské příkopové propadliny. Lze ji charakterizovat jako stupňovitý, oboustranný a příčně asymetrický příkop. Od Chebské pánve, se kterou sousedí na jihozápadě, je oddělena hřbetem krystalických břidlic. Od Severočeské hnědouhelné pánve, se kterou sousedí na severovýchodě, je oddělena stratovulkánem Doupovských hor. Severní strana přechází v krušnohorský zlom a jižní strana pánve v Ohářecký zlom (Rothbauer et al., 2003).

Podloží je tvořeno krystalikem a karlovarskou žulou. Vlastní uhelné souvrství je tvořeno třemi uhelnými slojemi – Josef, Anežka a Antonín (sloj Josef dosahuje v centrální části mocnosti 20 až 40 metrů, při okrajích až 17 metrů). Uhlí Sokolovské pánve obsahuje uhlí převážně středního stupně prouhlení (Průmysl u nás, 2005).

Sokolovská pánev náleží k mírně teplé klimatické oblasti, která je charakterizována jako pahorkatiná mírně teplá, mírně vlhká s mírnou zimou. Průměrné roční teploty se pohybují mezi 5,1° C až 7,2° C. Průměrné roční úhrny srážek jsou 526 až 947 mm. V celoročním průměru připadá nejvíce srážek na měsíc červenec (78-103 mm), naopak nejméně na únor a březen (26-76 mm) (Rothbauer et al., 2003).

Oblast Sokolovské pánve spolu s Chebskou pávní náleží do Chebsko-sokolovského bioregionu. Pánev je vyplněna kyselými pískami a jíly s podmáčenými stanovišti a biotou narušenou povrchovou těžbou. Vegetace je tvořena duby a jehličnatými stromy, acidofilními doubravami, olšinami a slatinami. Cenné jsou dochované nivní louky a bory. Charakteristickým prvkem oblasti jsou chybějící bučiny. Většina regionu byla odlesněna a v současnosti převažuje druhotná skladba dřevin (smrk a borovice). Dříve se zde nacházely také hojně zastoupené luhy, pastviny a orná půda, dnes jsou však více

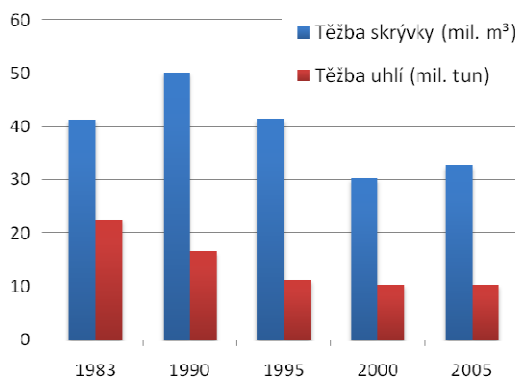
charakteristické antropogenní krajinné tvary např. povrchové doly, výsypky a odkaliště (Sokolovská uhelná, a. s., 2007).

Aktuální využití krajiny Sokolovské pánve je z 1/3 zastoupeno plochami těžebními, 30 % celkové rozlohy pánve zaujímá zemědělská půda (z toho jen 39 % je zorněno a 55 % je tvořeno trvalými travními porosty), 31 % představují lesy a 2 % zaujímají vodní plochy. Lze předpokládat, že rozloha lesních ploch v oblasti bude v budoucnu růst spolu s postupem rekultivací a útlumem těžby. Současná druhová skladba lesních porostů je z 80 % zastoupena smrkem, duby a borovice jsou potlačeny především z hospodářských důvodů. Na zalesněných výsypkách a v okolí sídel naleznete smrky, borovice, olše a břízy (Rothbauer et al., 2003).

2.2 Historie a současnost těžby

Historie soustavného hnědouhelného dolování na Sokolovsku sahá až do poloviny 18. století a to především ze sloje Josef. Rozmach a sláva hornictví v oblasti je spjata s objevem kvalitního uhlí sloje Anežka. Hnědé uhlí uložené v pánvi ve třech nepravidelně vyvinutých slojích s mocností několika desítek metrů s nadložím stovky metrů, bylo zpočátku těženo hlubinným dobýváním. V současnosti probíhá těžba uhlí výhradně lomovým způsobem s vysokou výrubností a energetickou účinností. Skutečný moderní vývoj těžby uhlí je datován výstavbou železničních drah v regionu do roku 1871. Po druhé světové válce bylo na Sokolovsku provozováno 39 hlubinných dolů a 15 malodolů.

Těžba na Sokolovsku dosáhla svého vrcholu v polovině 80. let 20. století. Od té doby objem těžby klesá, v současnosti se těží pouze ve východní části Sokolovské pánve – v lokalitě Jiří a Družba. Z výsypce je aktuálně používána pouze Smolnická výsypka, na Krušnohorské výsypce bylo zakládání ukončeno roku 2003. Z lomu Jiří je každoročně vytěženo okolo 8 mil. tun uhlí, vytěžené zásoby činily k 1.1.2003 cca 159 mil. tun. Lom Družba vytěží ročně kolem 2 mil. tun a v současnosti představuje nejmenší lomovou hnědouhelnou lokalitu v Česku (Sokolovská uhelná, a. s., 2007).



Obr. 2 Vývoj těžby uhlí a skřívky v Sokolovské pánvi

Zdroj: Sokolovská uhelná, a. s., 2007

2.3 Vlivy těžební činnosti

Povrchová těžba uhlí ovlivnila negativně nejen vzhled krajiny, ale i mezoklima oblasti. Tím, že byla krajina zbavena vegetačního krytu na rozsáhlých plochách, došlo k jejímu odvodnění, v létě tedy nestoupá z pánve vlhký vzduch, jak tomu bylo v minulosti, ale naopak vzduch suchý. Povrchová těžba a činnosti s ní spojené narušily přirozený způsob toku sluneční energie. Snížený podíl vody, který obíhal v krajině v tzv. krátkém cyklu, způsobuje v létě přehřívání rozsáhlých ploch. Umělé změny terénní morfologie zahlubováním dolů a zvyšováním výsypek podporují vznik přirozených i průmyslových inverzí. V takto zasaženém území se negativní vlivy projeví na fauně i flóře. Při těžbě i na výsypkách vznikají půdy zasolené, kyselé a často se zvýšenou koncentrací těžkých kovů. Tyto plochy pak často vykazují absenci souvislého vegetačního krytu.

V důsledku zahloubení těžebních jam a vzniku výsypek dochází ke změně nadmořských výšek. Nejvyšší místa Podkrušnohorské výsypky dosahují výšky 600 m n. m., naopak v lomech dosahují nejnižší body výšek kolem 290 m n. m. (pro srovnání se hladina řeky Ohře v této oblasti pohybuje okolo hodnot 400 m n. m.).

Morfologii oblasti výrazně ovlivnily vzniklé výsypky. Mezi nejvýznamnější patří Podkrušnohorská výsypka, která vznikla sloučením dříve samostatných výsypek (Lomnická, Boucí, Vintřovská, Matyáš, Týn a Pastviny). Její rozloha je okolo 1997 ha a nachází se na okraji Krušných hor. Změnu reliéfu dokládá rozdíl nadmořských výšek – původní terén 480 - 540 m n. m., současný terén 600 m n. m. (maximální mocnost výsypky je 87 m).

Výsypka Lítov – Boden se nachází v západní části Sokolovské pánve a zaujímá rozlohu 720 ha. Původní výšky se zde pohybovaly v rozmezí 470 – 540 m n. m., v současnosti má nejvyšší bod výšku 567 m n. m. (Sokolovská uhelná, a. s., 2007).



Obr. 3 Pohled na Lomnickou výsypku (vlevo) a výsypku Lítov (vpravo)

Zdroj: Kopačková, 2009

Ve východní části pánve nalezneme Smolnickou výsypku, na kterou se ukládají skrývkové hmoty. Nachází se severně od obce Chodov a zaujímá plochu cca 616 ha. Terén původní krajiny stoupal plynule od jihu k severu od výšek 450 – 540 m n. m., po ukončení prací je plánována výšky v nejvyšším místě maximálně 550 m.


Loketská výsypka, která se nachází v nejvýchodnější části pánve, dosahuje rozlohy až 500 ha. Původní terén se pohyboval v rozmezí hodnot 415 – 485 m n. m., výsypka má kónický tvar a nejvyšší bod má hodnotu 500 m n. m.

Mezi další výsypky v oblasti patří např. Gustav – Dvory, Čistá a Radvanov v rámci lomu Medard – Libík, výsypka lomu Silvestr, Výsypka Michal (jižně od Sokolova) a Antonín (západně od Sokolova). Dalším významným krajinným prvkem oblasti jsou lomy – Jiří a Družba, po ukončení těžby by měla vzniknout jedna společná zbytková jáma, která bude zatopena vodou (Rothbauer et al., 2003).

Zahlazování následků hornické činnosti se provádí sanačními a rekultivačními pracemi. Vlastní rekultivační činnost je v regionu prováděna déle než 50 let. Na Sokolovsku jsou prováděny rekultivace lesnické, zemědělské a vodní. Lesnické rekultivace jsou prováděny především na svazích. Z listnatých stromů patří mezi nejčastěji vysazované olše šedá a černá, javor klen, jasan ztepilý a dub zimní a letní. Z jehličnatých porostů převládají v rekultivačních pracích borovice lesní, smrk ztepilý a modřín evropský. Součástí rekultivací a sanací je i vytváření vhodných biotopů pro chráněné druhy rostlin a živočichů.

Při rekultivacích se stále častěji budují menší vodní nádrže sloužící k zachycování přívalových dešťů a k úpravě povrchových vod. Velká jezera, která vznikla ve zbytkových jámách lomů, umožňují provozovat rekreační aktivity (např. budoucí jezero Medard – Libík o ploše 485,5 ha, jehož napouštění se plánuje v letech 2010 – 2013).

Poslední velká zbytková jáma, která vznikne po těžbě uhlí po lomech Jiří a Družba, bude pravděpodobně po roce 2036 také zatopena. Vznikne tak jezero o ploše 1 322 ha a s maximální hloubkou 93 m (Sokolovská uhelná, a. s., 2007).



Obr. 4 Plochy ukončených rekultivací

Zdroj: Sokolovská uhelná, a. s., 2007

KAPITOLA 3

Hyperspektrální data

3.1 Hyperspektrální obrazová data

Dálkový průzkum Země (DPZ) vychází ze skutečnosti, že každý objekt ovlivňuje dopadající vlnění přirozeného nebo umělého původu. Sledováním jejich charakteristik je možné zjistit údaje o objektu bez přímého kontaktu s ním. Multispektrální obrazová data spolu s progresivně nastupujícími hyperspektrálními obrazovými daty patří mezi moderní nástroje dálkového průzkumu Země.

Nositelem informace v dálkovém průzkumu Země je elektromagnetické záření. Mezi přírodní zdroje elektromagnetického záření patří Slunce a Země. Intenzita odraženého i emitovaného (vyzářeného) záření je závislá na elektromagnetických charakteristikách objektů. Objekt je charakterizován odrazivostí, z ní lze určit, o jaký povrch se jedná.

Rozdíl mezi multispektrálními a hyperspektrálními obrazovými daty je především v počtu a šířce spektrálních kanálů použitých pro sběr dat. Rozdíl je patrný na příkladu multispektrálního senzoru ETM+ na družici Landsat 7 ETM+, kdy využívaný interval elektromagnetického záření od 0,52 – 12,50 μm je pokryt osmi spektrálními kanály, hyperspektrální senzor však pokryje stejnou šířku intervalu počtem spektrálních pásem v řádu stovek. Tyto spektrální kanály jsou poté užší a zobrazení spektrálních křivek odrazivosti pro jednotlivé materiály se jeví téměř jako spojité. Řada specifických rysů spektrálního chování objektů je u běžně používaných multispektrálních snímků potlačena hrubým spektrálním rozložením obrazových záznamů (spektrální křivky se zobrazují nespojitě), jelikož snímky jsou pořizovány v širokém intervalu vlnových délek.

Mezi faktory ovlivňující intenzitu záření patří atmosféra (záření je při průchodu atmosférou modifikováno). Intenzita odraženého záření závisí na druhu látky či objektu (na jeho chemickém složení), na fyzikálním stavu (vlhkost) a na stavu jeho okolí (propustnost atmosféry).


	Multispektrální obrazová data	Hyperspektrální obrazová data
Počet spektrálních pásem	jednotky, maximálně desítky	stovky
Šířka spektrálních pásem (nm)	desítky, spíše stovky	desítky

Tab. 1 Porovnání multispektrálních a hyperspektrálních dat

Zdroj: autorka

Data obrazové spektrometrie vytvářejí velké množství záznamů daného území ve velmi úzkých intervalech spektra elektromagnetického záření. Další nespornou výhodou je možnost snazšího identifikování objektů na snímcích.

Obrazové charakteristiky povrchů v závislosti na vlnové délce, fyzikálních a chemických vlastnostech formují jejich tzv. *spektrální chování*. Pro každý objekt je možné sestavit závislosti mezi jeho odrazivostí a vlnovou délkou a průběh této závislosti bude pro vybraný objekt typický. Tato charakteristika se označuje jako tzv. *spektrální křivka odrazivosti*. V souvislosti s hyperspektrálními daty vznikly tzv. *spektrální knihovny*, které uchovávají laboratorně zjištěná spektra odrazivosti pro nejběžnější materiály a druhy povrchů. Tyto spektrální knihovny se používají pro interpretaci spektrálních křivek získaných dálkovým průzkumem Země. Spektrální knihovny obsahují informace o hodnotách odrazivosti a lze je použít jako „vzorová“ spektra materiálů.



Obr. 5 Ukázka spektrálních křivek odrazivosti pro vegetaci (vlevo) a pro holou půdu (vpravo)

Zdroj: ENVI

Dokladem celosvětového rozšíření hyperspektrálních obrazových dat je studie autorů Tong et al., (2004). Nový trend dálkového průzkumu v Číně udává posun od použití panchromatických a multispektrálních snímků k datům hyperspektrálním a posléze i ultraspektrálním. V poslední dekádě nachází široké uplatnění především hyperspektrální

obrazová data, která se v Číně využívají především pro zemědělské aplikace a pro monitorování životního prostředí, naopak v městském prostředí je dosažení vysoké přesnosti relativně obtížné. Novým senzorem, který byl vyvinut v Číně, je PHI (Pushbroom Hyperspectral Imager) využívající se především pro studie vegetace (Tong et al., 2004).

3.2 Hyperspektrální obrazové senzory

Poslední tři desetiletí se oblast výzkumu dálkového průzkumu Země soustředí především na vývoj hyperspektrálních technologií, jež progresivně nastupují místo tradičních multispektrálních obrazových dat.

Hyperspektrální senzory, též označovány jako spektrometry, jsou založeny na principu snímání zemského povrchu za využití velkého počtu spektrálních pásem, která jsou relativně úzká. Obrazové spektrometry mají charakter spíše skenerů, obraz území tedy není pořízen najednou jako leteckou kamerou, ale postupným snímáním řádků. Nosičem spektrometru může být letadlo (letecké spektrometry) či družice (družicové spektrometry). Pro pozemní snímání existují také pozemní spektrometry, pomocí nichž lze snímat data i při terénních šetřeních.

Mezi nejběžněji používané senzory patří např. HyMap, AISA – Dual, ARES, AVIRIS či Hyperion a CHRIS. V předkládané diplomové práci jsou zpracovávána data ze senzoru *HyMap*. Jedná se o letecký hyperspektrální senzor, který byl vyvinut v Austrálii společností Integrated Spectronics' a v současnosti slouží především pro komerční účely.

První HyMap senzor, který byl vyvinut měl 96 spektrálních kanálů, a operoval v intervalu vlnových délek 0,55 – 2,5 μm . Tento první HyMap senzor byl optimalizován pro geologické aplikace. Další vývoj senzoru znamenal rozšíření počtu spektrálních pásem na 126 a také zvětšení snímaného intervalu vlnových délek na 0,44 – 2,5 μm . Dále přibyla dvě termální pásma ve vlnových délkách 3 – 5 μm a 8 – 10 μm . Šířka spektrálních pásem je přibližně 10 – 20 nm. Tato zlepšení nacházejí v současnosti uplatnění také ve studiích zabývajících se znečištěním životního prostředí, zemědělstvím a lesnictvím, dále v mapování půd a vegetace.

Senzor se vyznačuje širokým zorným polem, tím je možné nasnímat širší pás území najednou, ovšem za cenu toho, že snímání probíhá z vyšší letové výšky a dochází tak ke snížení prostorového rozlišení snímaných dat, které je 5 m/pixel. Jedna scéna pokryje území o rozloze 2,3 \times 20 km.

HyMap je mechanický skener pracující ve třech osách, je vybaven několika subsystemy (napájecí, kontrolní, navigační a záznamový) a je opatřen optikou SM2000 Zeiss. Kapacita záznamového zařízení je 80 GB, přičemž senzor zaznamená za sekundu asi 2,5 MB. Ideálním nosičem je lehké dvoumotorové letadlo např. Cessna, která létá ve výškové hladině 2000 – 5000 m (Cocks et al., 1998).



Obr. 6 Hyperspektrální skener HyMap

Zdroj: Galka, 2009

Senzor	Provozovatel	Počet spektrálních pásem	Šířka snímaného spektra (nm)	Šířka spektrálního pásma (nm)	Šířka řádku (pixely)
Letecké senzory:					
AISA –Dual ¹	Spectral Imaging, Finsko	256 ² 264 ³	400 – 2 450	2,3 ² 5,8 ³	1 024 ² 320 ³
ARES	Integrated Spectronics', Austrálie	150	450 – 2 450 8 100 – 12 100	12 – 15 ⁴ 122 ⁵	813
AVIRIS	NASA, USA	224	400 – 2 500	10	614
HyMap	Integrated Spectronics', Austrálie	128	440 – 2 500	10 - 20	512
Družicové senzory:					
Hyperion (družice EO – 1)	NASA, USA	242	375 – 2 579	10	256
CHRIS (družice Proba)	Evropská kosmická agentura	63	410 – 1 050	1,3 - 12	

Tab. 2 Přehled nejběžněji používaných hyperspektrálních senzorů

Zdroj: Spectral Imaging Ltd., 2009; Deutsches Zentrum für Luft- und Raumfahrt, 2007; NASA, 2009; Arcdata Praha, 2010; ESA, 2010

Pozn. ¹ AISA Dual obsahuje dvě části AISA Eagle a AISA Hawk² AISA Eagle³ AISA Hawk⁴ pro interval vlnových délek 450 – 2 450 nm⁵ pro interval vlnových délek 8 100 – 12 100 nm

3.3 Využití a studie zpracovávající hyperspektrální obrazová data

Největší využití nacházejí hyperspektrální data v aplikacích, kde je potřeba podrobného porovnávání spektrálních vlastností látek. Typickým příkladem jsou studie zaměřující se na geologické aplikace a výzkum hornin, minerálů, půd a vyhledávání ložisek nerostných surovin (studium vlastností, složení, obsahu vody atd.). Další využití nacházejí hyperspektrální data v biologických studiích při sledování vegetace – druhové zastoupení, stáří, zdravotní stav či obsah chlorofylu. Nezastupitelnou roli hrají také hyperspektrální obrazová data v mapování výskytu znečišťujících látek nebo v mapování pobřežních zón.

Příkladem studie mapující pobřežní zóny je aplikace autorů Hirany et al., (2003) z university ve státě Georgia v USA. Projekt mapuje oblast národního parku Everglades na Floridě. Oblast zájmu byla nasnímána v březnu 1996 senzorem AVIRIS s prostorovým rozlišením 20 m/pixel. Jako verifikační data byla využita podrobná vegetační databáze oblasti (přesnost přes 90 %), která vznikla s využitím leteckých snímků z prosince 1994.

Pro klasifikaci bylo vytvořeno osm tříd – lesy, podrosty (zakrslé stromky), savany, prairie, močály a mokřiny, křoviny, exotické rostliny a ostatní. Na hyperspektrální obrazová data byla posléze aplikována atmosférická korekce (algoritmus ATREM), dále byl odstraněn šum v obraze pomocí MNF transformace (*minimum noise fraction*), jejímž výsledkem jsou vlastní čísla, znázorňující kolik informace nesou jednotlivé kanály (v tomto případě je nejvíce informace soustředěno ve dvanácti kanálech). Dále byla data ze senzoru AVIRIS rektifikována pomocí panchromatických snímků ze senzoru SPOT za použití algoritmu nejbližšího souseda pro převzorkování (nedojde tím, k přepočítání hodnot jako při použití jiného algoritmu). Následovalo oddělení „spektrálně nečistých“ pixelů („*mixed pixel*“), tedy těch, jejichž radiometrická hodnota je složena z odrazivosti více druhů materiálů. Naopak „spektrálně čisté“ pixely („*spectrally pure pixel*“) nesou informaci pouze z jednoho druhu materiálu. Výpočet indexu čistoty pixelu „*Pixel Purity Index (PPI)*“ z dat korigovaných šumem posloužil k nalezení spektrálně čistých pixelů v obraze. Díky této segregaci lze poté určit trénovací množiny pixelů, které lépe a jednoznačněji charakterizují třídu. Klasifikace byla provedena v software ENVI za použití klasifikátoru spektrálních úhlů „*Spectral angle mapper (SAM)*“. Spektrální úhel byl vypočten jako úhel mezi vektorem zjišťovaného pixelu a vektorem charakterizujícím třídu. Úhel mezi zmíněnými vektory znamenal pravděpodobnost příslušnosti pixelu do dané třídy. U pixelů, kde se nacházelo více druhů materiálů, byla počítána relativní příslušnost k více třídám. Pixel byl poté přiřazen ke třídě, kde byla pravděpodobnost největší. Dosažené výsledky ukázaly, že přes 40 % plochy území zabírají porosty mangrove. Hodnocení přesnosti proběhlo na 537 vygenerovaných pixelech a přesnost klasifikace se pohybovala od 40 – 100 % v závislosti na vegetačním druhu. Chyby v klasifikaci byly přičítány především prostorovému rozlišení obrazových dat (Hirano et al., 2003).

Studii zpracovávající zemědělskou oblast v jižním Německu, která využívá senzor HyMap, zpracovali autoři Mader et al., (2006). Zmínění autoři diskutují možnosti a nevýhody zpracování hyperspektrálních obrazových dat za použití tradičních algoritmů. Další oblastí studie bylo zpracování problematiky počtu pixelů trénovacích množin vzhledem k počtu spektrálních dat obrazu a s tím souvisejícím výpočtem spektrálních statistik a problémem zvaným Hughesův jev. Na data byla použita analýza hlavních komponent – PCA (*principal component analysis*), která snížila počet spektrálních pásem vhodných pro následné zpracování a také snížila vliv Hughesova jevu. Hughesův jev vznikne, pokud jsou pro klasifikaci použity příliš malé trénovací soubory v porovnání s dimenzionalitou dat, tento fakt může vést k velké směrodatné odchylce. Obecně lze uvést, že doporučeným počtem pixelů v trénovací množině jedné třídy je $2n+1$, kde n odpovídá počtu spektrálních pásem použitých v klasifikaci, především při použití algoritmu neuronových sítí (ENVI, 2009).

Na data byla dále aplikována geometrická a poté i atmosférická korekce FLAASH (modul je součástí ENVI). Výsledkem atmosférické korekce bylo odstranění osmi spektrálních kanálů, které obsahovaly šum. Pro klasifikaci bylo stanoveno šest tříd – louky, kukuřice, ozim, jař, řepka a brambory. A jako vstupní data bylo využito 67 pásem (především ta pásma, kde je patrný nárůst množství chlorofylu v blízké infračervené části spektra). Na data byl použit algoritmus maximální věrohodnosti, přičemž nejvyšší přesnosti klasifikace (83,3 %) bylo dosaženo na datovém souboru s 67 vybranými pásmy, na která nebyla použita analýza hlavních komponent. Přesnost klasifikace na kompletním souboru dat s PCA transformací je o 2 % nižší, stejné přesnosti bylo dosaženo i při klasifikaci datového souboru vybraných 67 pásem s aplikací PCA transformace (Mader et al., 2006).

Aplikace zpracovávající lesní porosty v okolí Willapa Bay ve státě Washington byla zpracována autory Bolus et al., (1997). Lesní porosty v této oblasti se vyznačují převahou smrků a červeného cedru. Hlavním cíle projektu byla detekce a odlišení smrku od ostatních konifer a oddělení zdravých stromů od porostů trpících „stresem“. Primárním zdrojem dat pro tuto studii byly hyperspektrální snímky ze senzoru HYDICE, který snímá interval vlnových délek 400 – 2500 nm pomocí 210 spektrálních kanálů. Senzor se vyznačuje také vysokým spektrálním (10 nm) i prostorovým (3 m) rozlišením. Hyperspektrální obrazová data byla získána z přeletu, který se uskutečnil v červenci 1996 a byla zpracována v software ENVI. Oddělení smrků od jiných druhů konifer proběhlo na základě předpokladu, že smrky se vyznačují na rozdíl od jiných jehličnanů nižší odrazivostí v oblasti vlnových délek nad 1000 nm. Hlavním příznakem pro vyčlenění stromů trpících stresem byl opad kůry na kmenech.

Výsledky klasifikace byly porovnány s pozemním měřením odrazivosti, přičemž správně byly klasifikovány především starší a větší stromy. Naopak mladší stromy obklopené jinou vegetací byly častěji oklasifikovány špatně. Chyby v klasifikaci autoři přičítají především prostorovému rozlišení, nejvhodnější pro klasifikaci se tedy jeví

vegetace v otevřené krajině nebo při vodním toku. Hůře klasifikovatelné jsou smrky mladé, které jsou obklopeny jinou jehličnatou vegetací. Porovnání pozemního měření odrazivosti s odrazivostí získanou z hyperspektrálních dat ukazuje, že věk a zdravotní stav mají značný vliv na spektrální příznaky vegetace (Bolus et al., 1997).

KAPITOLA 4

Spektrální vlastnosti krajinných objektů a klasifikace

4.1 Spektrální vlastnosti krajinných objektů

Principem zjišťování informací metodou dálkového průzkumu je znalost zářivých vlastností krajinných objektů, které dovolují z naměřených hodnot odrazivosti nebo emisivity stanovit o jakou látku jde. Intenzita odraženého i emitovaného záření je závislá na elektromagnetických vlastnostech látky, na fyzikálním stavu objektu i jeho okolí.

Zářivé vlastnosti objektu popisuje spektrální charakteristika, která vyjadřuje závislost odrazivosti nebo emisivity dané látky na vlnové délce. Spektrální charakteristiky objektů jsou zjišťovány experimentálně v laboratořích, ale i v terénu. Současně s tím, je také zapotřebí zjišťovat druhové¹ a stavové² parametry, kterým odpovídá jedna spektrální charakteristika. Ze znalosti spektrální charakteristiky a stavových vlastností lze odvodit nejvhodnější spektrální pásma pro měření.

Rozmanitost krajiny způsobuje i rozličnost spektrálních vlastností objektů a jim odpovídajících spektrálních křivek. Spektrální odrazivosti lze rozdělit do čtyř základních skupin – holý povrch bez vegetace, povrch s vegetací, voda a plynné látky. Výsledná naměřená odrazivost bývá nejčastěji kombinací více látek. Se změnou stavových parametrů objektů v čase se také mění spektrální charakteristiky, např. růst vegetace je charakteristickým rozpoznávacím příznakem, která souvisí i s ročním obdobím (Kolář et al., 1997).

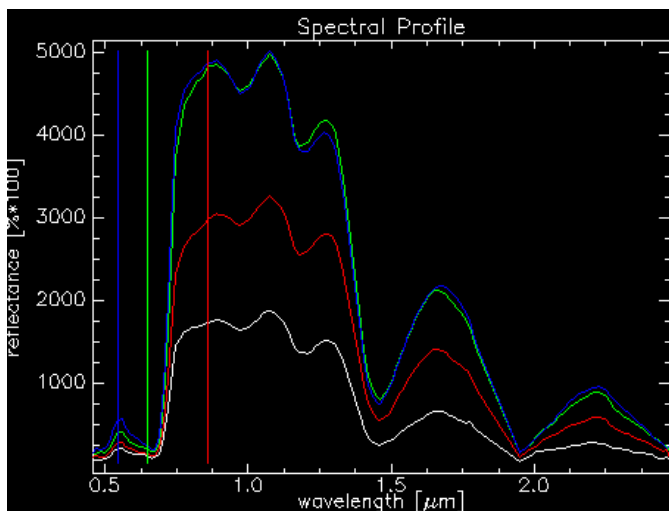
4.1.1 Vegetace

Vyjma pouštních a polárních oblastí je vegetace dominantním pokryvem pevného zemského povrchu především ve formě travních porostů, zemědělských plodin a stromových kultur. Spektrální projev porostu je tvořen nejen samotnou rostlinou (kmeny, větve a především listy), ale i půdou. Obecně však platí, že průběhy spektrálních křivek různých druhů rostlin jsou si podobné a vykazují společné rysy, přičemž průběh spektrální

¹ Druhové parametry mají kvalitativní povahu (např. silnice, jezero, louka atd.) a určují příslušnost k určitému druhu.

² Stavové parametry udávají stav látky a mají spíše kvalitativní charakter (např. teplota, vlhkost, stáří atd.).

křivky lze rozdělit na tři oblasti (oblast pigmentační absorpce, oblast vysoké odrazivosti a oblast vodní absorpce).



Obr. 7 Spektrální křivky vegetace (bílá – jehličnatý les starší 40 let, červená – jehličnatý les mladší 40 let, modrá – louka, zelená – listnatý les)

Zdroj: ENVI

Oblast pigmentační absorpce (0,4 – 0,7 μm) ovlivňují především pigmentační látky v listu, tedy především chlorofyl (často tvoří až 65 % listového pigmentu). Nejvíce zářivé energie pohlcuje chlorofyl v modré (0,45 μm) a červené (0,65 μm) oblasti světla, tzv. absorpční pásy, mezi nimi se nachází maximální hodnota odrazivosti (zelená oblast světla 0,54 μm) ve viditelné části spektra. Spektrální křivku odrazivosti rostlin ovlivňuje množství chlorofylu, které lze částečně korigovat přidáváním dusíku do půdy. Změna ročních období ovlivňuje množství a druh pigmentačních látek, na podzim se uplatňuje vliv karotenu a xanthofylu, které postupně převažují nad chlorofylem. Tyto pigmenty mají jedno absorpční pásmo v modré oblasti světla. Červené zbarvení listům dodává na podzim antokyan (Kolář et al., 1997).

Oblast vysoké odrazivosti neboli buněčné struktury (0,7 – 1,3 μm) je ovlivňována morfologickou strukturou listu a nízkou pohltivostí buněk. Uvnitř listu dochází k několikanásobnému odrazu a tím je odrazivost v blízké infračervené části spektra vysoká.

Oblast vodní absorpce (1,3 – 3 μm) je ovlivňována absorpčními pásy vody ve vlnových délkách 1,4 μm, 1,9 μm a 2,7 μm (hlavní vibrační absorpční pás vody). V pásmu vlnových délek nad 3 μm je pohltivost listů vysoká.

Odrazivost vegetace ovlivňuje výrazným způsobem také množství vody v rostlině, obecně platí, že spektrální odrazivost se zvyšuje s poklesem obsahu vody. Odlišnosti od normálního průběhu spektrální křivky odrazivost mohou být také způsobeny nevyhovujícím obsahem minerálů v půdě. Rostliny, které jsou dlouhodobě vystaveny působení těžkých kovů, jsou často postiženy nedostatkem chlorofylu. Tělo rostliny trpí

nedostatkem železa, které je vytlačeno jiným kovem, tento stav je nazýván chloróza (Kolář et al., 1997).


Jako indikátor přítomnosti zelené hmoty se používají vegetační indexy, které jsou založeny na rozdílu odrazivosti v červené a blízké infračervené části spektra. Pokud však porost není příliš hustý, v hodnotě odrazivosti se projevuje i odrazivost půdy, v tomto případě se používá výpočet listového indexu (LAI – plocha všech listů k ploše půdy) a jeho hodnota je závislá nejen na hustotě porostu, ale i na orientaci listů vzhledem ke Slunci. Největšího kontrastu mezi vegetací a půdou je dosaženo v oblasti blízkého infračerveného záření.

4.1.2 Vodní plochy

Voda v krajině je v rámci dálkového průzkumu Země sledována jak ve stavu kapalném, pevném, ale i plynném. Spektrální vlastnosti vody jsou v celém oboru elektromagnetického spektra značně odlišné od ostatních látek. Voda, která je v objektech obsažena, tak mění spektrální projevy. Voda v kapalném stavu (vodní toky a vodní plochy) se vyznačuje nízkou odrazivostí ve všech vlnových délkách, to způsobuje absorpce slunečního záření, které proniká pod hladinu. Maximální propustnost vody je na vlnové délce 0,48 μm , ta poté klesá až do oblasti tepelného záření. Vyšší propustnost v oblasti viditelného záření (0,5 – 0,6 μm) může sloužit k získání informace o dnu vodních ploch až v hloubce 15 m. Naopak téměř nepropustná se voda stává pro infračervené záření.

K vyšší odrazivosti vody může přispívat zvýšený obsah mechanických nebo biologických látek přítomných ve vodě např. plankton obsahující chlorofyl. Tím dojde ke snížení odrazivosti v modré části spektra a naopak ke zvýšení odrazivosti v žlutozelené oblasti. Lze tak sledovat koncentrace vodních řas a sinic ve vodě. Z mechanických látek přispívá ke zvýšené odrazivosti také suspenze, která posouvá maximum odrazivosti k delším vlnovým délkám. Naopak nevýhodou přítomnosti suspenze může být potlačení některých vlastností dna.

V případě pevného skupenství vody, tedy sněh a led, dochází k vysokému odrazu jak v oblasti viditelného tak blízkého infračerveného záření. Odrazivost sněhu a ledu převyšuje odrazivost ostatních objektů na zemi, podobnou odrazivost mají jen horní vrstvy oblaků. Minima v odrazivosti odpovídají absorpčním pásmům vody (pokles odrazivosti je až 90 %). Odrazivé vlastnosti sněhu ve viditelné části spektra ovlivňuje obsah prachových příměsí (odrazivost se snižuje se zvýšením obsahu nečistot) a velikost sněhových částic (nižší odrazivost je způsobena většími částicemi). Odrazivost rovněž závisí na stáří sněhu, čerstvý sněh má vyšší odrazivost než starší sněh (Kolář et al., 1997).



Obr. 8 Spektrální křivka vody

Zdroj: ENVI

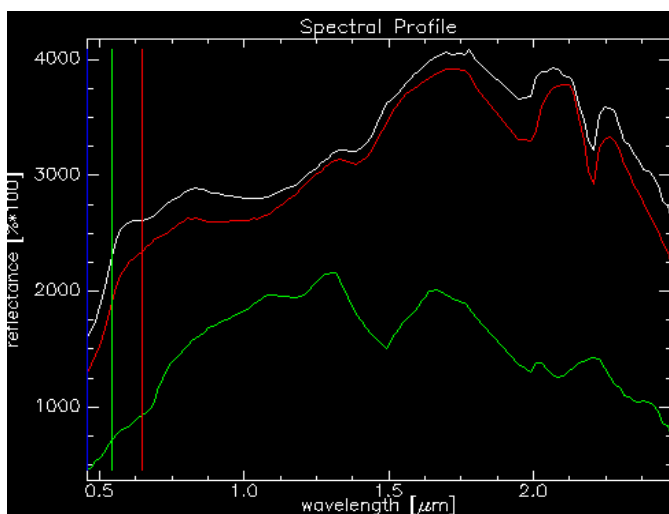
4.1.3 Holý povrch bez vegetace

Mezi holé povrchy bez vegetace patří nejen skalní objekty, ale i aridní oblasti, zemědělská půda a umělé povrchy. Ve viditelné části spektra dochází k postupnému nárůstu odrazivosti s vlnovou délkou. Konkrétní hodnota odrazivosti je závislá na chemickém složení a struktuře objektu.

Odrazivost půd se postupně zvyšuje s rostoucí vlnovou délkou v oboru viditelného a blízkého infračerveného záření až k absorpčním pásům vody. Parametrem, který ovlivňuje odrazivost půdy je voda a vlhkost, obsah humusu, struktura a složení půdy. Zvýšení obsahu vody v půdě se projeví celkově sníženou odrazivostí a výraznějšími minimy v oblastech absorpčních pásem vody. Obecně platí, že jíly a hlíny jsou vlhčí než písčité půdy a mají tedy i nižší odrazivost.

Dalším faktorem majícím vliv na odrazivost holé půdy je i struktura povrchu půdy. Půda, která je tvořena menšími částicemi, je hladší a její odrazivost je větší. Další nezanedbatelný vliv na odrazivost půdy je obsah humusu. Vyšší obsah humusu v půdě snižuje odrazivost ve viditelné části spektra. Nesporný vliv má také vegetace, přičemž záleží na její hustotě.

V případě minerálů a hornin závisí spektrální odrazivost především na chemickém složení. Dalším důležitým faktorem je přítomnost vody v minerálech a také množství křemíku (SiO_2) v horninách, čím větší obsah křemíku, tím jsou horniny světlejší a maximum se posouvá ke kratším vlnovým délkám (Kolář et al., 1997).



Obr. 9 Spektrální křivky holé půdy (bílá – výsypka, červená – lom, zelená – orná půda)

Zdroj: ENVI

4.2 Klasifikace

Obrazová data získaná dálkovým průzkumem Země bývají často zpracovávána metodou klasifikace. Nejinak je tomu i v této diplomové práci. Klasifikací se nazývá proces rozdělení a přiřazení obrazových dat podle klasifikačních pravidel do tříd, které vykazují určité charakteristické vlastnosti (druhové i stavové), jedná se tedy o zařazení pixelů pomocí vhodného rozhodovacího pravidla do tříd.

Existují dva typy klasifikace – řízená a neřízená klasifikace. Principem *řízené klasifikace* je výběr trénovacích ploch (vzorové plochy jako představitelé jednotlivých tříd) operátorem. Na základě trénovacích souborů a výběru algoritmu je poté provedena klasifikace. Je tedy důležité, aby tréninková data byla reprezentativní a kompletní. Podstatou řízené klasifikace je předem známý počet tříd. Metoda řízené klasifikace nabízí řadu algoritmů, např. klasifikátor minimální vzdálenosti („minimum distance“), klasifikátor maximální věrohodnosti („maximum likelihood“), klasifikátor rovnoběžníků („parallelepiped“), Bayesův klasifikátor či klasifikátor Mahalanobisovy vzdálenosti atd.

Neřízená klasifikace nepracuje s trénovacími soubory, přičemž operátor pouze určí požadovaný počet tříd. Neřízená klasifikace je založena na principu, že pixely s podobnými spektrálními vlastnostmi jsou přiřazovány do jednoho shluku (cluster). I v tomto případě je možné volit z vícera algoritmů, např. klasifikátor „k-means“ nebo „isodata“.

Obecně však platí, že častěji bývá využívána řízená klasifikace. Pro zpracování obrazových dat v této diplomové práci bylo využito celkem 5 algoritmů, které nabízí program ENVI 4.7. Kromě vybraných tradičních výše zmíněných klasifikátorů řízené klasifikace byl využit i algoritmus neurálních sítí („neural net“) a klasifikátor „spectral angle mapper“ (SAM).

4.2.1 Klasifikátor minimální vzdálenosti („minimum distance“)

Klasifikátor minimální vzdálenosti náleží mezi tradiční algoritmy a může mít více podob, které se liší výpočtem vzdálenosti. *Klasifikátor minimální vzdálenosti k těžišti* je založen na výpočtu těžiště pro jednotlivé třídy (metodou aritmetického průměru), přičemž se využívá vzorce pro výpočet euklidovské vzdálenosti:

$$d = \sqrt{(X_p - X_t)^2 + (Y_p - Y_t)^2},$$

kde X_p, Y_p jsou souřadnice určovaného pixelu a X_t, Y_t jsou souřadnice těžiště třídy.

Pixel je přiřazen k té křídě, která má nejmenší euklidovskou vzdálenost k těžišti. Analogie s metodou minimální vzdálenosti k těžišti je Voronoi teselace, která představuje rozdělení množiny bodů na uzavřené či otevřené oblasti takové, že každý bod v oblasti má nejbližší k centru vlastní buňky než k jakémukoliv jinému centru. Body, které leží na hranici Voronoiových buněk jsou od centra těchto sousedních buněk stejně vzdáleny (v případě klasifikace tedy dojde k nejednoznačnému přiřazení). Pokud bychom tedy ztotožnily centra Voronoiových buněk s těžišti třídy, dojde k vymezení hranice, kam padnou určované pixely.

Druhou metodou je *klasifikátor založený na výpočtu minimální vzdálenosti k nejbližšímu sousedovi (NN klasifikátor)*. Pixel je přiřazen do té třídy, k jejímuž náhodnému bodu má určovaný pixel nejmenší vzdálenost. Nejednoznačnost klasifikace může nastat, pokud vzdálenost pixelu je stejná pro více sousedů z různých tříd.

Výše zmíněný problém nejednoznačné klasifikace výpočtem minimální vzdálenosti k nejbližšímu sousedovi, lze odstranit výpočtem *minimální vzdálenosti ke k nejbližším sousedům* (k-nearest neighbours). V tomto případě nebereme v úvahu jen jeden nejbližší pixel, ale k nejbližších pixelů. Přiřazení pixelu je tedy závislé na převládajícím počtu sousedů jedné třídy nad ostatními. Výhodou je odstranění nejednoznačnosti, které mohou vzniknout při použití metody výpočtu k jednomu nejbližšímu sousedovi.

4.2.2 Klasifikátor maximální věrohodnosti („maximum likelihood“)

Klasifikátor maximální věrohodnosti je řazen taktéž mezi tradiční klasifikátory a patří mezi nejběžněji využívané. Prvním krokem je výpočet souřadnic těžiště pro všechny třídy, následně jsou určeny kovarianční matice pro třídy.

Kovarianční matice je vyjádřena tímto vztahem:

$$S = \begin{pmatrix} \text{var}(X) & \text{cov}(X, Y) \\ \text{cov}(Y, X) & \text{var}(Y) \end{pmatrix}$$

Pro výpočet pravděpodobnosti je důležité určit tzv. Mahalanobisovu vzdálenost:

$$(X - M_C) \cdot S_C^{-1} \cdot (X - M_C)^T,$$

kde S_C je kovarianční matice dané třídy a M_C je střední hodnota z prvků dané třídy, přičemž vektory X a M_C se chápou jako řádkové.

Dále je použita funkce, která popisuje pravděpodobnost příslušnosti pixelu k dané třídě:

$$P_C(X) = \frac{1}{2\pi\sqrt{\det S_C}} \exp\left(-\frac{1}{2}(X - M_C) \cdot S_C^{-1} \cdot (X - M_C)^T\right)$$

Určovaný pixel je tedy přiřazen do třídy s nejvyšší pravděpodobností $P_C(X)$, toho je dosaženo v případě, že Mahalanobisova vzdálenost je nejmenší.

Rozšířením metody maximální věrohodnosti je využití Bayessova klasifikátoru. Klasifikátor maximální věrohodnosti je založen na předpokladu, že pravděpodobnost výskytu je pro všechny třídy stejná. Naopak Bayessův klasifikátor zohledňuje i možnost, že pravděpodobnosti výskytu nemusí být stejné.

Pravděpodobnost $P(X | A)$ je určena pomocí vzorce:

$$P(X|A) = \frac{1}{2\pi^{\frac{n}{2}}\sqrt{\det S_A}} \exp\left(-\frac{1}{2}(X - M_A) \cdot S_A^{-1} \cdot (X - M_A)^T\right),$$

kde S_A je již dříve vypočtená kovarianční matice třídy A , M_A je již dříve vypočtené těžiště třídy A .

Celková pravděpodobnost $P(A | X)$ je pravděpodobnost, že pixel patří do třídy A , pokud je hodnota rovna X . Celková pravděpodobnost se vypočte pomocí Bayessovy věty:

$$P(A|X) = \frac{P(X|A) \cdot P(A)}{\sum P(X|T) \cdot P(T)},$$

kde $\sum P(X | T) \cdot P(T)$ vyjadřuje součet pravděpodobností $P(X | A) \cdot P(A)$ přes všechny určované pixely.


4.2.3 Klasifikátor neuronových sítí („neural net“)

Primárním předpokladem použití klasifikátoru neural net bylo dosažení nejlepšího a neoptimálnějšího výsledku klasifikace, především proto, že se jedná o nový a progresivní algoritmus, který již dříve poskytl ověřené a přesné výsledky.

Termín neuronová síť zahrnuje spojení několika neuronů s níže zmíněnými vlastnostmi. Čím jednodušší bude funkce realizovaná neuronem, tím bude muset být vyšší počet neuronů. Hodnoty signálů přenášených mezi jednotlivými prvky se mění v závislosti na nastavených parametrech tzv. váhových koeficientech, které zesilují nebo zeslabují signál přicházející z příchozích neuronů. Prvek sčítá všechny předchozí hodnoty vážených spojení a produkuje výslednou hodnotu, která je nelineární funkcí součtu (Lantora, Vašková, 2006).

Mezi výhody umělých neuronových sítí oproti tradičním algoritmům patří nezávislost na statistickém rozložení dat, přičemž neuronové sítě dokážou odhadnout nelineární vztah mezi vstupními a výstupními daty. Další výhodou neuronových sítí je odolnost proti chybám, schopnost „učit se“ (asociativní učení) a generalizovat. Naopak nedostatkem neuronových sítí je problematika návrhu architektury sítě, dlouhá doba „učení“, problémy lokálního minima a nastavení úvodních náhodných vah synapsí (Lantora, Vašková, 2006).

Neurony, které se nacházejí v biologických nervových soustavách, jsou navzájem propojeny výběžky tzv. dendrity, na jejichž koncích se nacházejí synapse. Dendrity přenášejí signál mezi neurony, tvoří tedy vstup do neuronu. Výstup z neuronu je tvořen přes tzv. axonový výběžek. Z obr. 10 tedy vyplývá, že vstupů je do neuronu více (až v řádu tisíců), zatímco výstup přes axon je pouze jeden. Obdobnou strukturu vykazuje i uměle vytvořený neuron, podstatu neuronu tvoří funkce, jež transformuje vstupy na výstupy. Důležitost a vlastnosti vstupů do neuronu je vyjádřena pomocí synaptických vah, kterými je každý vstup vynásoben a poté přenesen do neuronu. Zde jsou jednotlivé složky sečteny, výsledná suma je označována jako tzv. aktivační funkce neuronu. Pokud vypočtená suma překročí přednastavenou prahovou hodnotu, dojde k aktivaci neuronu. Naopak pokud je suma hodnot příliš malá a nepřekročí tak prahovou hodnotu, neuron se neaktivuje (Gurney, K., Gurney, K. N., 1997).



Obr. 10 Struktura biologického neuronu


Zdroj: webové stránky Wikipedie

Umělé neuronové sítě používané v DPZ se vyznačují podobou s biologickými neuronovými sítěmi, avšak tyto uměle vytvořené sítě by měly být schopny chovat se stejně nebo alespoň podobně jako jejich biologické vzory. Základní složkou neuronové sítě je neuron, který má několik vstupů a výstupů, mezi kterými je vytvořena určitá funkce. Biologická neuronová síť pracuje na principu elektrických impulsů, které zvyšují napětí. Náboj se objevuje ve výstupech, přičemž každý výstup má odlišný náboj. Po vstupu do následujících neuronů se hodnota náboje změní. Neuron tedy provádí tři akce – sumuje vstupy z jiných neuronů, provádí prahování a posílá výstup do jiných neuronů (Lantora, Vašková, 2006).

Matematicky lze umělý neuron ve vícevrstvé síti vyjádřit vztahem (Ajith, 2005):

$$O = f(\text{net}) = f\left(\sum_{j=1}^N w_j x_j\right),$$

kde O je výstupní signál, $f(\text{net})$ vyjadřuje aktivační funkci neuronu, proměnná (net) je definována jako součet vážených vstupů, x_j představuje vstupní signál, w_j značí hodnotu synaptické váhy.



Obr. 11 Struktura umělého neuronu

Zdroj: Ajith, 2005

Pro aktivaci neuronu je potřeba nadefinovat přenosovou funkci, mezi nejjednodušší patří skoková funkce, která vrací hodnotu jedna, pokud dojde k překročení stanoveného prahu a hodnotu nula, pokud prahová hodnota překročena nebyla. Gurney, K. a Gurney, K. N. (1997) uvádí jednoduchý příklad s dvěma vstupy s různými vahami (0,3 a 0,7) za použití aktivační funkce TLU (Threshold Logic Unit) se stanoveným aktivačním prahem 0,5. Mezi složitější aktivační funkce patří např. funkce hyperbolické tangenty nebo radiální báze (Gurney, K., Gurney, K. N., 1997).

$x_1 (w_1=0,3)$	$x_2 (w_2=0,7)$	α	Y
0	0	0	0
1	0	0,3	0
0	1	0,7	1
1	1	1	1

Tab. 3 Příklad funkčnosti umělého neuronu za použití aktivační funkce TLU

Zdroj: Gurney, K., Gurney, K. N., 1997


Umělé neuronové sítě mají široké využití nejen v dálkovém průzkumu Země, ale i v identifikaci rukopisu nebo v rozpoznávání textur. Rozdíly lze hledat v typu neuronu nebo v architektuře neuronové sítě – architektura feedforward a feedback. V prvním případě se signál šíří pouze jedním směrem. Architektura feedback může obsahovat i smyčky a signál se tak může pohybovat vpřed i vzad. Příkladem architektury feedforward je síť nazývaná „perceptron“ obsahující jednoduché neurony podle McCulloch – Pitts modelu. Charakteristickým rysem je uspořádání ve vrstvách. Na počátku jsou vstupní hodnoty, na konci jsou výstupy, tedy každé třídě, do níž data klasifikujeme, odpovídá jeden uzel. Při průchodu signálu sítí je výstupním uzlům přiřazena hodnota, klasifikovaný pixel je přiřazen k uzlu, u něhož je tato hodnota největší (Gurney, K., Gurney, K. N., 1997).

Pro nastavení synaptických vah je potřeba získat trénovací data, vzorové pixely pro jednotlivé třídy. Při samotné klasifikaci je vzorový pixel klasifikován neuronovou sítí, výsledek je pak porovnán s výsledkem přiřazení od operátora. Následně je vypočtena chyba klasifikace, u pixelů, kde se výsledek klasifikací lišil, dojde k jeho návratu na začátek. Posléze se upraví hodnoty synaptických vah a tím se následující iterace klasifikace více přiblíží skutečnosti. Celý tento proces se opakuje až do doby, dokud není dosaženo maximálního počtu iterací nebo počet chyb neklesne pod zadaný práh (Ajith, 2005).

4.2.4 Klasifikátor spektrálních úhlů („spectral angle mapper“)

Algoritmus „spectral angle mapper“ (SAM) je moderní a progresivní klasifikátor, který je jedním z nejčastěji využívaných algoritmů pro klasifikace půd, minerálů a hornin (Chan, Canters, 2007). Klasifikátor je založen na odrazivosti každého pixelu, kterou si lze

představit jako n -dimenzionální vektor, kde n představuje počet spektrálních pásem obrazu. Délka vektoru reprezentuje jas a směr vektoru udává spektrální charakteristiku objektu. Změna osvětlení ovlivňuje především délku vektoru, a proto je klasifikace založena na směru vektoru (Lumme, 2004).



Obr. 12 Znárodnění spektrálního úhlu mezi dvěma materiály A a B v rámci dvou kanálů (i, j)

Zdroj: Lumme, 2004

Klasifikace je tedy založena na porovnávání spektrálních úhlů mezi spektrem klasifikovaného pixelu a spektrem, které bylo získáno sběrem trénovacích souborů nebo ze spektrální knihovny. Pixel je poté přiřazen ke třídě, ke které má nejmenší spektrální úhel. Nevýhodou algoritmu je, že nerozlišuje hodnoty pozitivní a negativní korelace, ale pracuje pouze s absolutní hodnotou (Lumme, 2004).

Klasifikátor SAM tedy porovnává radiometrickou hodnotu pro každý pixel v každém pásmu se spektrem trénovacího souboru nebo se spektrem ze spektrální knihovny. Spektrální úhel je tedy úhel vypočtený mezi vektorem určovaného pixelu a vektorem, který reprezentuje třídu. Čím menší spektrální úhel, tím větší je pravděpodobnost příslušnosti pixelu ke třídě.


Klasifikátor „spectral correlation mapper“ (SCM) zlepšuje vlastnosti algoritmu SAM a odstraňuje výše zmíněnou nevýhodu pozitivní a negativní, princip fungování SAM a SCM algoritmu je velmi podobný (Lumme, 2004).

4.3 Subpixelová klasifikace

Subpixelová klasifikace je založena na předpokladu, že na ploše pixelu je zachyceno více druhů povrchu. Hodnota odrazivosti je určena jako kombinace odrazivostí jednotlivých složek, tedy materiálů, které jsou obsaženy v pixelu. Opakem je „spektrálně čistý pixel“, jehož odrazivost je tvořena jen jedním materiálem nebo povrchem.

Obecný příklad „spektrálně nečistého pixelu“ uvádí ENVI Tutorial (2009) – pixel je tvořen z 25 % materiálem A, z 25 % materiálem B a z 50 % materiálem C. Celkové

spektrum tohoto pixelu se vypočte jako vážený průměr z jednotlivých materiálů, přičemž jako váhy slouží procentuální zastoupení materiálů v pixelu.



Obr. 13 Znázornění spektrálně mixovaného pixelu

Zdroj: ENVI, 2009

K určení „spektrálně čistých pixelů“ slouží výpočet Pixel Purity Index (PPI), který najde nejvíce spektrálně čisté pixely (extrémy). Tyto pixely jsou posléze vhodné k použití i jako trénovací soubory. Nejčastěji probíhá výpočet PPI na datech, na která byla aplikována MNF transformace (Minimum Noise Fraction Transform). Algoritmus pracuje na principu iterativního výpočtu, kdy dochází k projekci n-dimenzionálního scatter plot na jednotkový vektor. V každé projekci jsou vybrány a označeny extrémní pixely.

Výpočet probíhá v následujících krocích: nejprve je odstraněn šum v obraze a redukována dimenzionalita obrazových dat. Ve druhém kroku je vypočítán index čistoty pixelu pro každý bod obrazové kostky. Následně jsou vybrány extrémní pixely, které jsou vyhodnoceny jako spektrálně čisté (ENVI, 2009).

Většina pixelů, která byla pořízena hyperspektrálním senzorem, je spektrálně „nečistých“, tedy že hodnota odrazivosti pixelu je kombinací odrazivostí materiálů, které se na pixelu nacházejí. Důvodem spektrálně mixovaných pixelů může být několik, avšak mezi hlavní důvody je řazeno prostorové rozlišení. Pro subpixelové zpracování obrazu se často využívá analýzy „linear spectral unmixing“. Výsledkem analýzy je obraz, který poskytuje procentuální zastoupení jednotlivých frakcí (druhů povrchů) na ploše pixelu, např. hodnota 0,45 indikuje 45% zastoupení povrchu v pixelu. V případě, že se velké množství hodnot pohybuje nad jedna nebo pod nulu, nejspíše nebyly vhodně vybrány referenční pixely (ENVI, 2009).

Ačkoli „linear mixture model“ má mnoho výhod, jako je snadná implementace a flexibilita pro různé aplikace, najdou se i aplikace, kdy lepší výsledky poskytuje

„nonlinear mixture model“. Na výsledek analýzy mají vliv nasbírané trénovací soubory (Plaza et al., 2007).

Výsledkem metody „linear spectral unmixing“ jsou obrazy, které rozloží pixely na jednotlivé frakce pro každý referenční soubor pixelů. Pro každý pixel jsou určeny podíly jednotlivých složek z celkové hodnoty odrazivosti (Yang et al., 2007).

Obdobnou definici pro analýzu spektrálně mixovaných pixelů uvádí i Zeng et al., (2007): „linear spectral mixing model“ se využívá pro výpočet procentuálního zastoupení jednotlivých druhů povrchů na ploše pixelu. Celková odrazivost pixelu se vypočte jako lineární kombinace jednotlivých referenčních spekter (Zeng et al., 2007).

Příkladem využití metody je zpracování hyperspektrálních dat s prostorovým rozlišením 1,3 m, která zachycují zemědělské plochy sorgha v Texasu. Kolektiv autorů uvádí, že se jedná o techniku, která má potenciál v případě, že pixel není spektrálně čistý, ale hodnota jeho odrazivosti je určena kombinací odrazivosti jednotlivých povrchů, které se na ploše pixelu nacházejí (nejčastěji se jedná o holou půdu v kombinaci s vegetací). Jedinečné a spektrálně čisté pixely je možné využít jako pixely s referenčním spektrem. Jako referenční spektrum lze použít spektrální hodnoty pozemního měření, hodnoty získané ze spektrálních knihoven nebo i hodnoty určené přímo z obrazu. Podle autorů jsou pro model nejvhodnější hodnoty získané přímo z obrazu, jelikož s nimi lze počítat přesněji a bez chyb z kalibrace. Jelikož se stav a vzrůst vegetace mění s ročním obdobím, je možné použít tato referenční spektra jen pro daná obrazová data (Yang et al., 2007).

Algoritmus „linear spectral unmixing“ je dán matematickým vztahem (Yang et al., 2007):

$$y_i = \sum_{j=1}^m a_{ij}x_j + \varepsilon_i, i = 1, 2, \dots, n,$$

kde y_i vyjadřuje referenční hodnotu v pásmu i pro pixel, a_{ij} je známá hodnota odrazivosti v pásmu i pro referenční pixel j , x_j je neznámá hodnota pro referenční pixel j , ε_i značí rozdíl mezi měřenou a modelovanou odrazivostí pro pásmo i , m značí číslo referenčních pixelů a n je počet spektrálních pásem.

Správnost analýzy „linear spectral unmixing“ lze ověřit pomocí hodnoty RMS (střední chyba). Obraz má m pixelů a střední chyba je vypočtena pro každý pixel v obraze. Čím vyšší hodnota, tím vypočtený model popisuje data méně přesně. Hodnota RMS chyby tedy částečně popisuje a hodnotí výběr referenčního spektra, které bylo v analýze použito. Sekundárním výsledkem analýzy je chybový obraz, který udává hodnoty kvantitativní chyby pro každý pixel v obraze.

Výpočet RMS hodnoty je dán matematickým vztahem (Alemie, 2005):

$$RMS = \sqrt{\frac{\sum_{i=1}^m (\varepsilon_t^2)}{m}}$$

kde m znamená počet pixelů v obraze a ε_t je reziduální chyba mezi zjišťovaným a modelovým spektrem.

Analýza „linear spectral unmixing“ není jedinou metodou, kterou software ENVI nabízí. Obdobný algoritmus pro subpixelovou analýzu nabízí také „mixture tuned matched filtering“. Jedná se o hybridní algoritmus, který je založen na kombinaci dobře známého signálu a teorie „linear mixture“, tedy kombinace metody, která nevyužívá znalost referenčního spektra s metodou, jež je založena na lineární kombinaci komponent tvořících odrazivost pixelu. Výsledkem je hodnota, která uvádí shodu mezi referenčním spektrem a pixelem, přičemž hodnota jedna znamená perfektní shodu.

Metoda „matched filtering“, kterou lze využít také při subpixelové analýze hyperspektrálních dat, je silně ovlivněna výběrem referenčního spektra uživatelem (ENVI, 2009).

KAPITOLA 5

Zpracování obrazových dat HyMap

5.1 ENVI

Předkládaná diplomová práce byla zpracována za použití software ENVI verze 4.7. Program je produktem firmy ITT Visual Information Solutions, která se specializuje na softwarová řešení a analýzy obrazových dat dálkového průzkumu. ENVI je využíván širokou veřejností a kombinuje nejnovější metody vizualizace a analýzy obrazového zpracování spolu s uživatelsky přívětivým prostředím pro získání maxima informace z obrazu.

5.2 Obrazová data HyMap

Data, která zpracovává předkládaná diplomová práce, byla pořízena v červenci 2009 senzorem HyMap. Celkem bylo pořízeno devět obrazových linií z letové výšky cca 2580 m, přičemž interval vlnových délek 440 – 2 500 nm je pokryt 128 spektrálními pásmy. Současně s leteckou kampaní probíhala i pozemní kampaň, která probíhala na výsypkách v oblasti Lomnice a Lítova. Pozemní kampaň byla zaměřena především na sběr biologických vzorků z náletových bříz, borovic na výsypkách a ze smrkových porostů v okolí lomů. Součástí pozemní kampaně bylo také měření spektrálních vlastností referenčních cílů spektrometrem.

Obrazová data dosahují prostorového rozlišení 5 m/pixel, které pravděpodobně neumožní přesněji určit druhové složení vegetace (např. konkrétní druhy stromů v lesních porostech). Pro potřeby projektu a dalšího zpracování je potřeba odlišit co nejpřesněji především porosty smrků starších a mladších 40 - ti let.

5.3 Předzpracování obrazových dat

Předzpracování dat proběhlo v Ústavu systémové biologie a ekologie AV ČR Ing. Janem Hanušem. Níže je uvedena metodika, kterou na data aplikoval. Na obrazová byla aplikována atmosférická korekce ATCOR-4. Atmosférická korekce ATCOR-4 je implementací fyzikálního modelu atmosféry MODTRAN-4 a byla vyvinuta společností ReSe Applications Schäpfer a Deutschlandes Zentrum für Luft – und Raumfahrt. Jedná se

o aplikaci, která slouží k atmosférické, topografické a BRDF korekci (obousměrná distribuční funkce odrazivosti) leteckých obrazových dat (Hanuš, 2010).

V tomto případě byla na data použita pouze atmosférická korekce, bez použití topografické nebo BRDF korekce. Nejdůležitějšími parametry pro výpočet atmosférické korekce je *typ aerosolů* a *viditelnost* v době pořízení dat. Hodnota viditelnosti byla určena z měření Microtops II Sunphotometer, které taktéž proběhlo v době letecké kampaně. Typ aerosolů, který se v zájmovém území nachází, byl určen s ohledem na dominantní typ zemského povrchu. Jako referenční body bylo využito celkem šest druhů povrchů (umělé i přírodní) – 2 druhy asfaltu, travní porost, hřiště na plážový volejbal, bazén a beton. Odrazivost těchto cílů byla měřena spektrometrem ASD FieldSpec-3 (Hanuš, 2010).

Hodnota viditelnosti byla nastavena na 60 km, přičemž byla spočtena jako konstantní pro celou oblast zájmu. Typ aerosolů v zájmové oblasti byl zvolen jako zemědělský (venkovský). Pásma (konkrétně 22, 31-38, 45-52, 63-69 a 93-96), která se nacházejí v pásmu vodní absorpce, byla interpolována. Interpolační algoritmus ovšem z neznámých důvodů vypočetl pro pásma 31 a 45 černé pixely, proto není doporučeno s pásmy 31-38 a 45-52 dále pracovat (Hanuš, 2010). Hodnoty odrazivosti povrchu vypočtená po atmosférické korekci byla vynásobena hodnotou 100 (tedy při 25% odrazivosti vznikne hodnota 2500).

Georeferencování a ortogonalizace dat proběhla v software PARGE. Pro geometrickou korekci a georeferencování bylo využito pozemních měření získaných během letecké kampaně a digitálního modelu terénu zájmového území, převzorkování bylo provedeno metodou nejbližšího souseda. Výsledná obrazová data byla georeferencována do zobrazení UTM (33 zóna, elipsoid WGS-84). Přesnost georeferencování byla určena pomocí 20 kontrolních bodů (*GCP* – „*ground control points*“), jejichž souřadnice byly odečteny z ortofotomapy. Hodnota směrodatné odchylky je 2,7 m, přičemž chyba narůstá ve směru nadíru spolu se vzrůstající chybou digitálního modelu terénu (Hanuš, 2010).

Posléze proběhlo učení kvality obrazových dat HyMap prostřednictvím statistického výpočtu průměru, minima, maxima a směrodatné odchylky. Výsledek poukazuje na dynamický rozsah scény (Hanuš, 2010).

Dále bylo z dat vypočteno množství šumu (*SNR* – „*signal to noise ratio*“), které způsobuje nejčastěji nesystematické zkreslení obrazových dat. Šum v obraze byl definován jako absolutní směrodatná odchylka od vybrané oblasti. Hodnota SRN byla vypočtena ze vzorce (Hanuš, 2010):

$$SNR = \frac{\mu_m(ROI)}{c_{mm}(ROI)}$$

kde, μ znamená průměrnou hodnotu záře pásma m a c představuje směrodatnou odchylku záře pásma m .

Hodnota SRN byla vypočtena z homogenní vodní plochy o velikosti 334 pixelů. Z výpočtu vyplývá, že okrajová pásma od 2,3 μm do 4 μm obsahují velké množství šumu, současně se jedná o již dříve zmíněné pásma vodní absorpce a je vhodné je tedy vyloučit z další práce.

Na závěr části, která se věnuje předzpracování dat, byla určena přesnost odrazivosti zemského povrchu. Přesnost byla určena z atmosféricky korigovaných dat a byla ověřena pomocí pěti referenčních cílů (asfalt, bazén, hřiště na plážový volejbal, travní porost). Rozdíl mezi odrazivostí referenčních cílů zaměřenou na zemském povrchu a odrazivostí získanou z obrazu byla do 9 %. Rozdíl tvarů spektrálních křivek z pozemního měření a z hyperspektrálního snímku se lišily jen mírně (do 1 %) především v intervalu 670 - 1470 nm. Rozdíl je relativně malý a neměl by ovlivnit data při další práci s nimi (Hanuš, 2010).

5.4 Mozaikování obrazových dat


Dále bylo nutné rozhodnout, zda budou data klasifikována po jednotlivých páslech nebo budou sloučeny v jeden obraz pomocí mozaikování linií. Tyto možnosti jsou značně ovlivněny atmosférickými podmínkami v době snímkování. Pokud se v době pořízení dat vyskytuje velká oblačnost, která vrhá stíny na povrch, poté je vhodnější data nespojovat a klasifikovat po liniích. Ačkoli je tato varianta více časově náročná a je nutno nasbírat trénovací soubory pro každou linii, tato metoda se zdá jako vhodné řešení pro data s oblačností.

V případě, že data jsou pořízena za bezoblačných podmínek a osvětlené celé scény je konstantní a rovnoměrné, je vhodné spojit data do jednoho obrazu a klasifikovat najednou. V případě dat zpracovávaných v této diplomové práci panovalo jasné a bezoblačné počasí, data byla pořízena v relativně krátkém časovém úseku 1 a ¼ hodiny (10:45-12:03) a proto se atmosférické podmínky po dobu snímání příliš nezměnily.

Pro vznik mozaiky byl využit software PCI Geomatica, kde byla získána maska z každého snímku (algoritmus *THR: Thresholding Image to Bitmap*), poté byly sousedící masky navzájem vynásobeny (*ARI: Image Channel Arithmetic*) a vznikly tak úzké pásy překrytu. Tento úzký pás překryvu byl posléze vložen do ENVI 4.7, kde bylo využito funkce *Overlay Annotation*, která umožní rozříznout překryv uprostřed. Tímto krokem dojde k odstranění krajních a nejvíce zdeformovaných pixelů v obou páslech a alespoň částečně je potlačen vliv zakřivení Země.

Vzniklá *Annotation Line* slouží pro ořez neoznačené části snímku při následném kroku mozaikování. Samotné mozaikování (*Base Tool – Mosaicing – Georeferencing – Import with properties*) proběhlo směrem od spodu - tedy od posledního snímku, ke kterému byly následně přidány další linie, které obsahovaly výše zmíněnou ořezovou linii. V dialogu byla nastavena hodnota pozadí jako nula, důležitým parametrem bylo nastavení algoritmu

pro převzorkování – Nearest Neighbor, který zachová radiometrické hodnoty. Nedojde tedy k nežádoucímu přepočtení a změně radiometrických hodnot, které by ovlivnily výsledek klasifikace.



Obr. 14 Návrh Overlay Annotation – odstranění krajních zdeformovaných pixelů tím, že Annotation Line vedeme uprostřed překryvu dvou snímků

Zdroj: autorka

5.5 Klasifikace obrazových dat

Na data byla aplikována MNF transformace (Minimum Noise Fraction Transformation), která se používá k odstranění šumu, nadbytečné informace a redukci dimenzionality dat. Mezikrokem při výpočtu je určení vlastních čísel, které určují množství informace nesené určitým spektrálním kanálem. MNF transformace je založena na transformaci hlavních komponent (*PCA – Principal Component Analysis*), která rozdělí vstupní data na dvě části – pásma s velkými vlastními čísly, kterou nesou velké množství informace v obraze a poté pásma, která mají vlastní čísla malá a obsahují hodně šumu. Pro následnou klasifikaci bylo použito celkem 85 % informace nesené 78 pásmy. Pásma, která mají vlastní číslo blízké hodnotě jedna, obsahují více šumu, než ta s vyšší hodnotou (ENVI, 2009). Touto volbou jsou odstraněna okrajová pásma, která mohou obsahovat šum, jenž by při klasifikaci mohl způsobit nepřesnosti. Klasifikace tedy byla provedena pouze na kanálech 1 (455,4 nm) – 78 (1599,5 nm)¹.




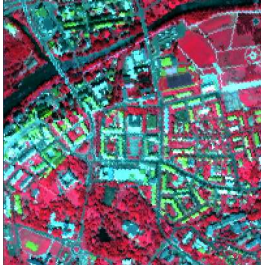

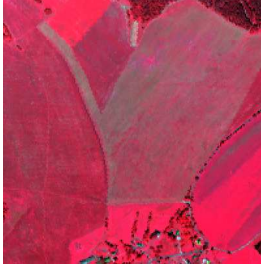





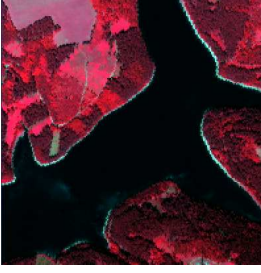
Samotná klasifikace byla provedena v ENVI 4.7, přičemž bylo využito pět klasifikačních algoritmů. Zvoleny byly jak tradiční a již dlouhodobě používané (klasifikátor maximální věrohodnosti, klasifikátor minimální vzdálenosti a klasifikátor Mahalanobisovy vzdálenosti), tak nové a progresivní algoritmy (klasifikátor spektrálních úhlů a klasifikátor neuronových sítí). Před aplikací klasifikátoru byly nasbírány trénovací množiny (v tomto případě *ROI:Region of Interests*). Stejný trénovací soubor byl vstupem do všech klasifikací využívajících různé algoritmy, tak jsou výsledky porovnatelné.




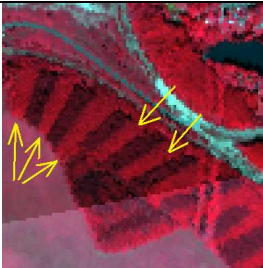

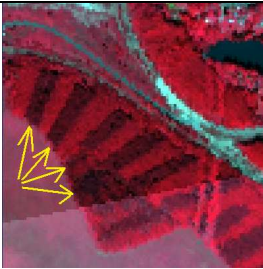


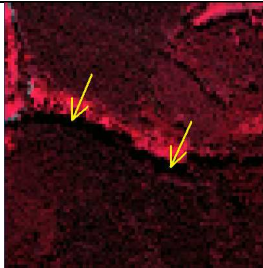
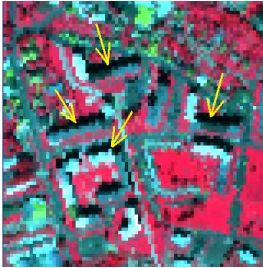
¹ Výsledek klasifikace za využití pásem 1-78 se nelišil od výsledku klasifikace, při které byla použita následující pásma 1-30, 39-44 a 53-78

Pro úspěšný výsledek klasifikace je nutné dodržet hranici minimální počtu pixelů v trénovací množině. Pokud je tento fakt nedodržěn, může často vznikat tzv. Hughesův jev (*Hughes phenomenon*). Hughesův jev vzniká, pokud jsou pro klasifikaci použity relativně malé trénovací soubory v porovnání s dimenzionalitou dat, tento fakt může vést k velké směrodatné odchylce. Příliš malé trénovací soubory mohou vést k nepřesné klasifikaci s velkou hodnotou směrodatné odchylky. Výsledek klasifikace tedy nezáleží pouze na kvalitě a přesnosti určení trénovacích souborů, ale také na velikosti souboru (Hsieh, Landgrebe, 1998). Obecně lze uvést, že doporučovaným počtem pixelů v trénovací množině jedné třídy je $2n+1$, kde n odpovídá počtu spektrálních pásem použitých v klasifikaci, především při použití algoritmu neuronových sítí (ENVI, 2009).

Pro výběr trénovacích tříd je výhodné využít kromě zobrazení obrazu v pravých barvách (*True Color*) také v zobrazení CIR (*Color Infrared Image*). ENVI zobrazuje snímek v pravých barvách, přičemž využívá barevnou kombinaci pásem ve vlnových délkách 0,6-0,7 μm pro červenou část spektra, 0,5-0,6 μm pro zelenou část spektra a 0,4-0,5 μm pro modrou část. Při zobrazení v barevné kombinaci CIR je využito pásem blízké infračervené části spektra (0,76-0,9 μm) a dále pásem v červené a zelené části spektra. Pokud nejsou k dispozici odpovídající pásma pro zobrazení CIR, ENVI vybere nejbližší možná pásma. Obraz v barevné kombinaci CIR zobrazuje bujnou a rostoucí vegetaci s velkým množstvím chlorofylu jako jasně červenou (různé odstíny mohou rozlišovat listnaté, jehličnaté stromy nebo stáří vegetace), naopak tyrkysově modrá barva, šedá a černá zobrazují povrchy bez obsahu chlorofylu (viz Tab. 4). CIR se tedy dobře hodí pro rozlišení základních druhů a stáří vegetace, které by byly ze snímku v pravých barvách těžko rozpoznatelné.

Kvalitu a odlišnost nasbíraných trénovacích souborů lze ověřit pomocí parametru „*Signature separability*“ (rozdílnost, oddělitelnost tříd). Tato hodnota je počítána jako rozdíl mezi dvěma spektrálními znaky a určuje kvalitu sběru trénovacích ploch. Výsledkem je hodnota v intervalu nula až dva, přičemž hodnota nula znamená naprostý překryv dvou tříd (naprosto shodné trénovací plochy), naopak hodnota dva znamená absolutní rozdílnost tříd. Vyšší hodnota tedy může indikovat dobrý výsledek klasifikace. Hodnota „*Signature separability*“ lze spočítat za předpokladu dostatečného počtu pixelů nasbíraných v trénovacích souborech. V případě zpracování výše zmíněných obrazových dat HyMap bylo přistoupeno ke klasifikaci pouze tehdy, pokud hodnota „*Signature separability*“ byla vyšší než 1,98. V ostatních případech klasifikace nebyla dokončena, jelikož výsledky by byly pravděpodobně méně přesné.

<i>třída</i>	<i>RGB (14, 7, 1)</i>	<i>CIR (29, 14, 7)</i>
povrchová těžba		
zástavba a infrastruktura		
louky a pastviny		
holá půda		
zemědělské plochy		
vodní plochy		


listnaté stromy		
smrky ve stáří do 40 let		
smrky ve stáří nad 40 let		
stíny (stromů a budov)	 	 

Tab. 4 Přehled klasifikovaných tříd z obrazových dat HyMap

Zdroj: autorka, ENVI

Klasifikátor neuronových sítí (*Neural Net*) je založen na architektuře feedforward-backpropagation, přičemž obsahuje jednu vrstvu neuronů. Výpočet je nastaven tak, že probíhá tak dlouho, dokud hodnota směrodatné odchylky neklesne pod 0,1 nebo není dosaženo tisíce iterací. K situaci, kdy by směrodatná odchylka klesla pod zmíněnou prahovou hodnotu, došlo pouze jednou, v ostatních případech proběhlo všech tisíc iterací.

Směrodatné odchylky při zpracování obrazových dat HyMap dosahovaly nejběžněji hodnot 0,12-0,25.



Obr. 15 Grafické znázornění směrodatné odchylky v závislosti na počtu iterací (RMS=0,09 při průběhu 956. iterace)

Zdroj: autorka, ENVI

Algoritmus maximální věrohodnosti (*Maximum Likelihood*) patří mezi nejčastěji využívané klasifikátory. Pixel je přiřazen k té třídě, u které byla vypočtena největší pravděpodobnost příslušnosti. Mezi nastavitelné parametry algoritmu v ENVI patří nastavení prahu pravděpodobnosti, tedy minimální hodnoty pravděpodobnosti, při které je pixel ještě klasifikován. Pokud tuto prahovou hodnotu pravděpodobnosti příslušnosti ke třídě nepřesáhne, není klasifikován. Zde nebyla nastavena žádná hodnota, tím byly všechny pixely klasifikovány.

Klasifikátor minimální vzdálenosti (*Minimum Distance*) v ENVI pracuje na základě výpočtu Euklidovské vzdálenosti mezi klasifikovaným pixelem a průměrem třídy. Každý pixel je klasifikován na základě minimální vzdálenosti, jestliže není specifikována maximální hodnota směrodatné odchylky nebo maximální dovolená vzdálenost (obojí lze nastavit v parametrech klasifikace). Pokud jsou nastaveny zmíněné parametry, opět může dojít k situaci, kdy některý z klasifikovaných pixelů nemůže být přiřazen, jelikož nesplňuje podmínky. I v tomto případě nebyla zadána žádná hodnota a tím tedy byly klasifikovány všechny pixely.

Dalším použitým klasifikátorem byl algoritmus spektrálních úhlů (*Spectral Angle Mapper*). V ENVI je tento klasifikátor založen na porovnání podobnosti dvou spekter pomocí úhlu mezi vektorem určovaného pixelu a vektorem referenčního spektra. I v tomto případě je možné nastavit maximální prahovou hodnotu úhlu, ENVI neklasifikuje pixel, pokud je spektrální úhel větší než nastavená hodnota. ENVI má defaultně nastavenou hodnotu 0,1 radiánu, která nebyla při klasifikaci změněna.

Posledním klasifikátorem využitým v této práci byl algoritmus Mahalanobisovy vzdálenosti (*Mahalanobis Distance*). Tento klasifikátor je obdobou klasifikátoru maximální věrohodnosti, přičemž zavádí do výpočtu statistické vlastnosti dat. Všechny pixely jsou v ENVI klasifikovány k nejbližší třídě, pokud není specifikována maximální prahová hodnota vzdálenosti, poté nemusí být všechny pixely klasifikovány.

5.6 Postklasifikační úpravy obrazových dat

Dle očekávání nejlepší výsledky (dle vizuálního porovnání) vykazuje algoritmus neuronových sítí. Přesnost klasifikace dosahovala 69,75 %, pro zpřesnění výsledku bylo přistoupeno k druhému kolu klasifikace. Prvním krokem je vytvoření masky vybrané třídy z prvního kola klasifikace např. maska smrků ve stáří nad 40 let (*Masking – Built Mask – Options – Import Data Range – Data Min Value, Data Max Value obojí nastavit na hodnotu třídy, která charakterizuje klasifikaci*). Dále bylo nutné ověřit veškeré povrchy spadající do této třídy, tedy povrchy, které byly vyklasifikovány správně tj. jako smrky ve stáří nad 40 let, ale i povrchy, které byly vyklasifikovány špatně tj. jiný druh povrchu, který byl špatně přiřazen ke třídě smrků ve stáří nad 40 let, ačkoli se o tyto smrky nejedná. Následuje výběr nových trénovacích souborů, v tomto konkrétně uvedeném příkladě by vznikla třída smrků ve stáří nad 40 let a pak např. třída louka, která byla chybně zařazena do třídy smrků ve stáří nad 40 let. Samotné druhé kolo klasifikace je zpracováno pouze v rámci již zmíněné masky. Tímto postupem je možné odstranit některé drobné nepřesnosti, které vznikly v prvním kole klasifikace. Nakonec byly jednotlivé soubory druhých kol klasifikací sloučeny do jednoho obrazu. V prvním kroku bylo potřeba vytvořit masky jednotlivých tříd (*Built Mask*), v případě, že jedna třída je rozdělena do více částí (více souborů) je potřeba tyto soubory sloučit „sečtením“ do jednoho pomocí funkce *Band Math*. Z tohoto součtu byla vytvořena nová maska. Maska vybrané třídy má hodnotu jedna, okolí se vyznačuje hodnotou nula, aby byly jednotlivé třídy odlišitelné, je nezbytné přiřazení konkrétní číselné hodnoty, kterou si třída uchová (*Apply Mask*).

Výsledek druhého kola lze ještě částečně upravit pomocí síťového filtru. Síťový filtr („*Sieve filter*“) pracuje s ohledem na okolí pixelu (resp. skupiny pixelů). Síťový filtr sleduje, zda daný pixel (resp. skupina pixelů) sousedí s pixelem (resp. skupinou pixelů) stejné třídy, či s pixelem (resp. skupinou pixelů) jiné třídy. Před aplikací filtru je nutné nastavit dva parametry – maximální velikost skupiny, která může být z obrazu ještě vyloučena, a počet směrů výpočtu (tedy směry, v nichž budou hodnoty sousedních pixelů sledovány). Touto hodnotou může být 4 (tedy směr nahoru-dolu a vpravo-vlevo) nebo 8 (navíc je uvažováno se směry přes rohy). Výsledkem je odstranění samostatných pixelů nebo malých skupin, které jsou obklopeny pixely jiné třídy a přitom velké skupiny pixelů nejsou nijak ovlivněny (na rozdíl od jiných filtrů).

V tomto případě byla jako maximální velikost skupina nastavena hodnota 4 (tj. skupiny čtyřech a méně pixelů s hodnotou 1, které jsou obklopeny pixely jiných tříd s hodnotou 0, budou odstraněny), přičemž výpočet bude probíhat všemi osmi směry.

1	0	0	0	0
1	0	0	0	0
0	0	1	0	0
0	0	0	1	1
0	0	1	1	1

Obr. 16 Síťový filtr (červené šipky – výpočet proveden ve čtyřech směrech, prostřední pixel bude odstraněn; zelené a červené šipky – výpočet proveden v osmi směrech, prostřední pixel bude zachován)

Zdroj: autorka, ENVI

5.7 Subpixelová analýza obrazových dat

Metoda *Linear Spectral Unmixing* slouží k subpixelové analýze dat. U každého pixelu je analyzován relativní výskyt materiálů, které jsou zobrazeny v obrazových datech, na základě spektrálních vlastností materiálů. V tomto případě je velikost pixelu 5 m, většina pixelů tedy není spektrálně čistých, ale plocha pixelu je tvořena více druhy povrchů.

Dobrý výsledek analýzy je založen na kvalitě trénovacích souborů, které jsou importovány do dialogu. Dále je možný výběr ze dvou metod – neomezenou (mohou být předpokládány i negativní hodnoty hojnosti) a částečně omezující (možnost nastavení proměnné hodnoty součtu zlomků). Částečně omezující metoda umožňuje nastavit hodnotu váhového faktoru (přednastavena hodnota jedna). Tutoriál ENVI doporučuje aplikovat analýzu na data, na která byla použita MNF transformace.

Výsledkem analýzy je obraz pro každou třídu trénovacích souborů, přičemž hodnota udává zastoupení materiálu na ploše pixelu. Spektrálně čisté pixely se vyznačují hodnotou okolo jedné, v obraze se tyto pixely jeví jako bílé (při součtu relativní hojnosti materiálů jedna). Pokud většina hodnot v obraze po analýze přesahuje jedna nebo je nižší než nula, pravděpodobně nebyly vhodně zvoleny trénovací soubory.



Obr. 17 Ukázka analýzy *Linear Spectral Unmixing* pro třídu lesů ve stáří nad 40 let (v obraze se jeví světlejší)

Zdroj: autorka, ENVI

Výsledky subpixelové analýzy byly následně zpracovány tak, aby tvořily jeden celistvý obraz. Pro každou třídu byla vytvořena maska, která zachycovala charakteristický výsledek pro danou třídu, byla tedy vytvořena maska, jež zachycovala plochy zvýrazněné analýzou. Tato území se vyznačují hodnotou mezi 0,75-1,00, tj. pixel je tvořen ze 75 % - 100 % zjišťovanou třídou. Následně byla maskám přiřazena hodnota, která ji při další práci bude charakterizovat. Poté byly všechny tyto masky sloučeny do jednoho obrazu pomocí nástroje *Band Math*, kdy byly všechny masky sečteny.

KAPITOLA 6

Hodnocení a porovnání klasifikací obrazových dat HyMap

V této části diplomové práce budou porovnány dosažené výsledky zpracování hyperspektrálních dat na základě postupů popsanych v kapitole 5 s cílem najít nejvhodnější algoritmus pro klasifikaci těchto dat z hlediska přesnosti a spolehlivosti. Porovnání získaných výsledků bude mít několik částí – porovnání přesnosti klasifikace jednotlivých algoritmů, dále porovnání relativního zastoupení tříd v klasifikaci pro jednotlivé algoritmy a v neposlední řadě také porovnání vybraných modelových území.

6.1 Porovnání přesnosti klasifikací obrazových dat

Klasifikace zpracovaná v ENVI byla uložena do formátu pix a její přesnost byla určena v software Geomatica 10.1 (*Post Classification Analysis – Accuracy Assessment*). Pro relevantní výsledek bylo použito 500 náhodně vygenerovaných bodů, které operátor ručně přiřadil do tříd. Toto ruční přiřazení bylo poté porovnáno s výsledkem klasifikace. Celkové přesnosti klasifikací pro jednotlivé algoritmy jsou obsaženy v tabulce 5.

<i>Použitý algoritmus</i>		<i>Celková přesnost klasifikace</i>
Neural net	1. kolo	69,75 %
	2. kolo	77,20 %
Spectral Angle Mapper		60,60 %
Minimum Distance		49,00 %
Maximum Likelihood		57,90 %
Mahalanobis Distance		58,20 %
Linear Spectral Unmixing (subpixelová analýza)		68,00 %

Tab. 5 Přehled celkových přesností klasifikací

Zdroj: autorka, Geomatica

Celková přesnost klasifikací se pohybuje v rozmezí 49,00 % až 77,20 %. Nejlepšího výsledku bylo dosaženo za použití algoritmu neuronových sítí, kdy výsledek byl zpřesněn druhým kolem klasifikace. Již po první vizuální kontrole nejlepší výsledky poskytl

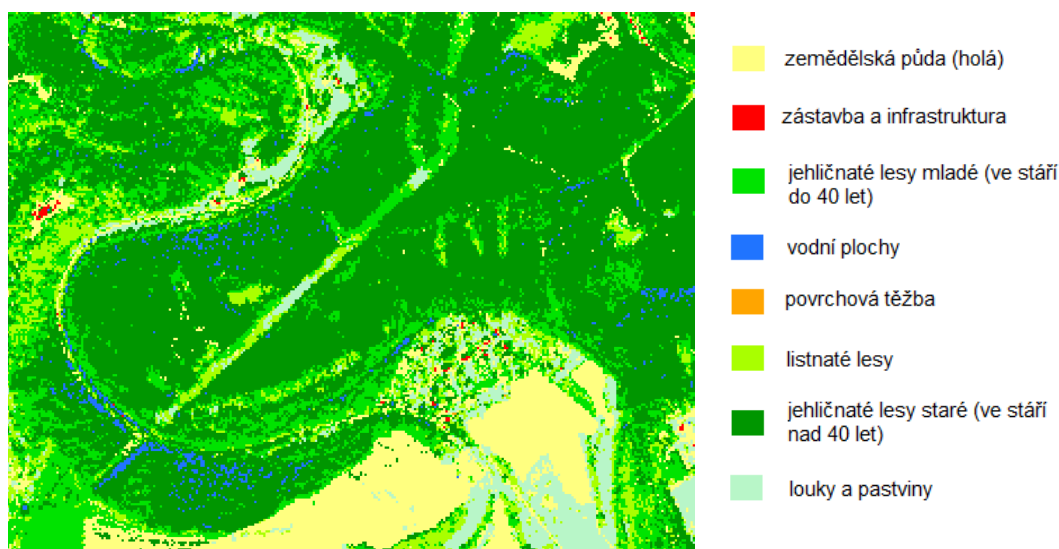
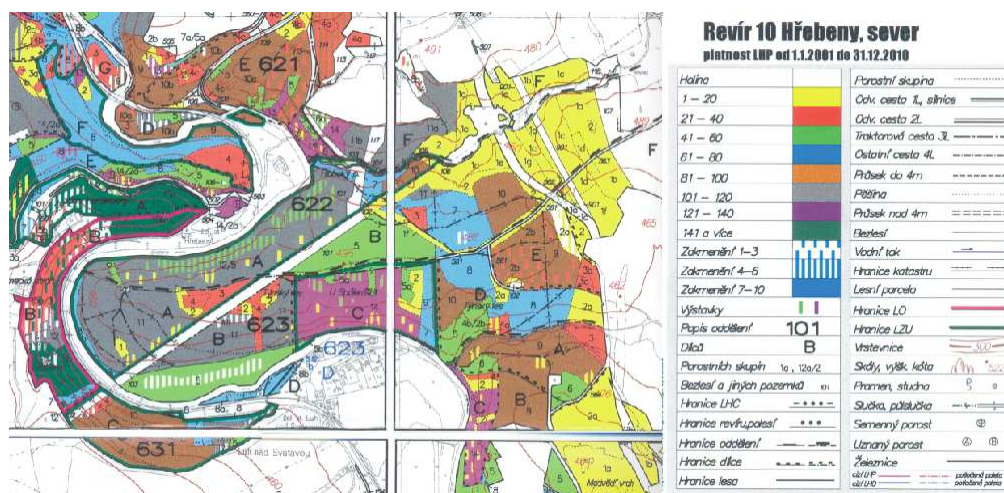
algoritmus neuronových sítí, který dokázal dobře rozlišit i povrchy, u kterých měly ostatní algoritmy problém (louky x jehličnaté stromy ve stáří do 40 let x jehličnaté stromy ve stáří nad 40 let). Dle předpokladu se však nepodařilo bližší určení jednotlivých druhů stromů (dub x buk x bříza). Listnaté a jehličnaté lesy (staré i mladé) byly odděleny úspěšně. Největší komplikace byly původně přepokládány při rozlišení mladých (stáří do 40 let) a starých (stáří nad 40 let) jehličnatých lesů a dále ze strany zástavby a povrchů s těžební činností. Tento předpoklad se potvrdil jen částečně, kdy byly zaznamenány problémy při rozlišení antropogenních umělých povrchů (těžební činnost x zástavba). Naopak nově vzniklým nedostatkem u všech použitých algoritmů je rozlišení lesa a louky, častým případem bylo chybné zařazení luk a pastvin do třídy listnatých nebo mladých jehličnatých lesů. Další drobné nepřesnosti vznikly v případě třídy starých jehličnatých lesů nad 40 let, kdy některé zastíněné části lesa byly přiřazeny do třídy vodních ploch. V případě klasifikátoru neurálních sítí byly oba tyto jevy částečně odstraněny aplikací druhého kola klasifikace.

6.2 Porovnání relativního zastoupení tříd v klasifikaci

Relativní zastoupení tříd je dáno poměrem plochy, která byla přiřazena k určité třídě, k celkové ploše obrazu. Porovnání tohoto faktoru pro použité algoritmy ukazuje nepřesnosti a odlišnosti mezi klasifikacemi. Jelikož nejlepší výsledek poskytuje algoritmus neuronových sítí po druhém kole klasifikace, toto relativní zastoupení jednotlivých tříd je považováno za „optimální“. V obraze jsou nejvíce zastoupeny staré jehličnaté lesy a zemědělsky obdělávaná půda, naopak nejmenší plochy zabírají vodní plochy a stíny.

6.2.1 Hodnocení klasifikace algoritmem neurálních sítí

Jak bylo již výše uvedeno, algoritmus neurálních sítí poskytuje nejlepší výsledky, co se týče v přesnosti a relevantnosti výsledku klasifikace. Algoritmus oddělil již v prvním kole jehličnaté porosty starší a mladší 40 let, výsledek byl ověřen a verifikován pomocí lesnických map, které uvádějí stáří lesa.



Obr. 18 Verifikace klasifikace algoritmem neurálních sítí podle lesnické mapy

Zdroj: autorka, ENVI, Lesy ČR

Drobné nejasnosti naopak vznikly v odlišení luk, listnatých lesů a mladých jehličnatých lesů, kdy některé malé části louky byly klasifikovány jako listnaté stromy nebo mladé jehličnaté stromy. Dalším drobným nedostatkem bylo vyklasifikování zastíněných ploch v lese i v zástavbě jako vodní plochy. Nepřesnosti se projevily také v klasifikaci lomu a zástavby. Aby byly tyto nepřesnosti odstraněny, bylo přistoupeno k druhému kolu klasifikace, tímto krokem se přesnost klasifikace zlepšila o téměř 7,5 %. Došlo tím i ke změně procentuálního zastoupení tříd v obraze, vzrostlo zastoupení zemědělské půdy, luk a pastvin, naopak kleslo zastoupení třídy listnatých stromů a stromů jehličnatých mladých i starých.

zemědělská půda	21,68 %
lom a holá půda (povrchová těžba)	3,99 %
zástavba a infrastruktura	5,43 %
listnaté stromy	9,97 %
jehličnaté stromy ve stáří do 40 let	17,02 %
jehličnaté stromy ve stáří nad 40 let	25,23 %
vodní plochy	2,06 %
louky a pastviny	14,63 %

Tab. 6 Relativní zastoupení tříd v klasifikaci algoritmem neurálních sítí v 1. kole

Zdroj: autorka, ENVI

zemědělská půda	23,18 %
lom a holá půda (povrchová těžba)	6,05 %
zástavba a infrastruktura	3,85 %
listnaté stromy	9,06 %
jehličnaté stromy ve stáří do 40 let	16,42 %
jehličnaté stromy ve stáří nad 40 let	22,48 %
vodní plochy	1,34 %
louky a pastviny	16,93 %
stíny (domů a stromů)	0,69 %

Tab. 7 Relativní zastoupení tříd v klasifikaci algoritmem neurálních sítí v 2. kole

Zdroj: autorka, ENVI

6.2.2 Hodnocení klasifikace algoritmem spektrálních úhlů

Výsledek klasifikace algoritmem spektrálních úhlů je značně odlišný od výsledků klasifikace zpracovanou klasifikátorem neurálních sítí. Největší rozdíl je patrný v zastoupení mladých jehličnatých stromů, které zde tvoří přes 40 %, naopak podíl starých jehličnatých stromů je výrazně nižší. Z velké části také chybí louky a pastviny, které byly vyklasifikovány jako mladé jehličnaté stromy.

Naopak dobré výsledky poskytl algoritmus v případě rozlišení lomů a zástavby, ačkoli v oblasti zástavby některé drobné plochy byly vyklasifikovány jako lom.

zemědělská půda	14,79 %
lom a holá půda (povrchová těžba)	4,56 %
zástavba a infrastruktura	5,91 %
listnaté stromy	12,86 %
jehličnaté stromy ve stáří do 40 let	40,11 %
jehličnaté stromy ve stáří nad 40 let	13,47 %
vodní plochy	1,22 %
louky a pastviny	7,08 %

Tab. 8 Relativní zastoupení tříd v klasifikaci algoritmem spektrálních úhlů

Zdroj: autorka, ENVI

6.2.3 Hodnocení klasifikace algoritmem minimální vzdálenosti

Výsledek klasifikace algoritmem minimální vzdálenosti se vyznačuje velkým podílem ploch přiřazených do třídy mladých jehličnatých lesů do 40 let, tento fakt však znamená nižší podíl luk a pastvin, které byly klasifikovány právě jako mladé jehličnaté lesy.

Dalším podstatným nedostatkem je chybné rozlišení těžebních ploch a infrastruktury, především proto, že tyto dva druhy ploch (střechy x lomy) mají podobné spektrální vlastnosti. Velké množství těžebních ploch bylo vyklasifikováno jako zástavba a infrastruktura.

Stejně jako v případě klasifikace algoritmem neurálních sítí i zde nastává problém s klasifikací stínů, které byly vyklasifikovány jako vodní plochy.

zemědělská půda	10,93 %
lom a holá půda (povrchová těžba)	3,04 %
zástavba a infrastruktura	6,59 %
listnaté stromy	18,42 %
jehličnaté stromy ve stáří do 40 let	31,72 %
jehličnaté stromy ve stáří nad 40 let	21,18 %
vodní plochy	3,29 %
louky a pastviny	4,84 %

Tab. 9 Relativní zastoupení tříd v klasifikaci algoritmem minimální vzdálenosti

Zdroj: autorka, ENVI

6.2.4 Hodnocení klasifikace algoritmem maximální věrohodnosti

Výsledky klasifikace algoritmem maximální věrohodnosti se vyznačují vysokým podílem listnatých lesů, naopak úplně chybí mladé jehličnaté stromy do 40 let a podíl starých jehličnatých lesů nad 40 let je také velmi malý. Z tohoto pohledu je použití tohoto klasifikátoru nevhodné. Relativně dobré výsledky poskytuje klasifikátor pro třídu povrchové těžby. Zajímavým rysem klasifikace je vznik „bufferových zón“ okolo silničních tahů, algoritmus tedy zachytil úzký pás holé půdy, který se vyskytuje podél silnic.

zemědělská půda	22,16 %
lom a holá půda (povrchová těžba)	6,39 %
zástavba a infrastruktura	1,54 %
listnaté stromy	34,28 %
jehličnaté stromy ve stáří do 40 let	0,36 %
jehličnaté stromy ve stáří nad 40 let	7,52 %
vodní plochy	2,35 %
louky a pastviny	25,39 %

Tab. 10 Relativní zastoupení tříd v klasifikaci algoritmem maximální věrohodnosti

Zdroj: autorka, ENVI

6.2.5 Hodnocení klasifikace algoritmem Mahalanobisovy vzdálenosti

Výsledek klasifikace algoritmem Mahalanobisova vzdálenost se vyznačuje vysokým zastoupením mladých jehličnatých lesů na úkor ploch luk a pastvin (luční a zatravněné plochy byly často přiřazeny do třídy mladých jehličnatých lesů). Další často vyskytující se chybou je klasifikace stínu do třídy vody, proto má tato třída relativně vysoký podíl zastoupení, tento nedostatek lze odstranit pomocí druhého kola klasifikace. Naopak velkým pozitivem klasifikace je relativně přesné vymezení ploch s povrchovou těžbou a holou půdou, nejsou zde ve větší míře chybně určené zastavěné plochy.

zemědělská půda	9,71 %
lom a holá půda (povrchová těžba)	6,41 %
zástavba a infrastruktura	4,60 %
listnaté stromy	8,49 %
jehličnaté stromy ve stáří do 40 let	33,11 %
jehličnaté stromy ve stáří nad 40 let	24,09 %
vodní plochy	4,50 %
louky a pastviny	9,11 %

Tab. 11 Relativní zastoupení tříd v klasifikaci algoritmem Mahalanobisovy vzdálenosti

Zdroj: autorka, ENVI

6.2.6 Hodnocení subpixelové analýzy Linear Spectral Unmixing

Subpixelová analýza zpracovala data v rámci pixelů, výsledek se proto jeví více nejednotný a nekompaktní, pixely jsou určeny podrobněji a detailněji. Přesto celková přesnost je menší než u výsledku klasifikace algoritmem neurálních sítí. Pro relevantní výsledek, který je možné porovnat s klasifikacemi, bylo použito i pro tuto analýzu stejných trénovacích souborů.

Relativní zastoupení jednotlivých tříd je značně nerovnoměrné, oproti klasifikaci algoritmem neurálních sítí je zastoupení zemědělské půdy o 10 % vyšší na úkor listnatých stromů a oblastí s povrchovou těžbou. Zastoupení luk a pastvin je dokonce o 15 % vyšší, naopak zastoupení jehličnatých lesů je menší než v případě klasifikátoru neurálních sítí.

Plocha zástavby a infrastruktury získaná z obrazu je velmi malá, městská zástavba je částečně přiřazena do holé půdy a povrchové těžby. Taktéž zastoupení listnatých lesů je velmi malé, především na úkor luk a pastvin. Celkově nelze považovat výsledek subpixelové analýzy za optimální, vyhovující je pouze v určitých menších místech (vodní plochy, staré jehličnaté lesy a zemědělská půda).

zemědělská půda	33,24 %
lom a holá půda (povrchová těžba)	3,56 %
zástavba a infrastruktura	0,22 %
listnaté stromy	1,97 %
jehličnaté stromy ve stáří do 40 let	13,45 %
jehličnaté stromy ve stáří nad 40 let	15,46 %
vodní plochy	1,76 %
louky a pastviny	30,34 %

Tab. 12 Relativní zastoupení tříd po aplikaci subpixelové analýzy

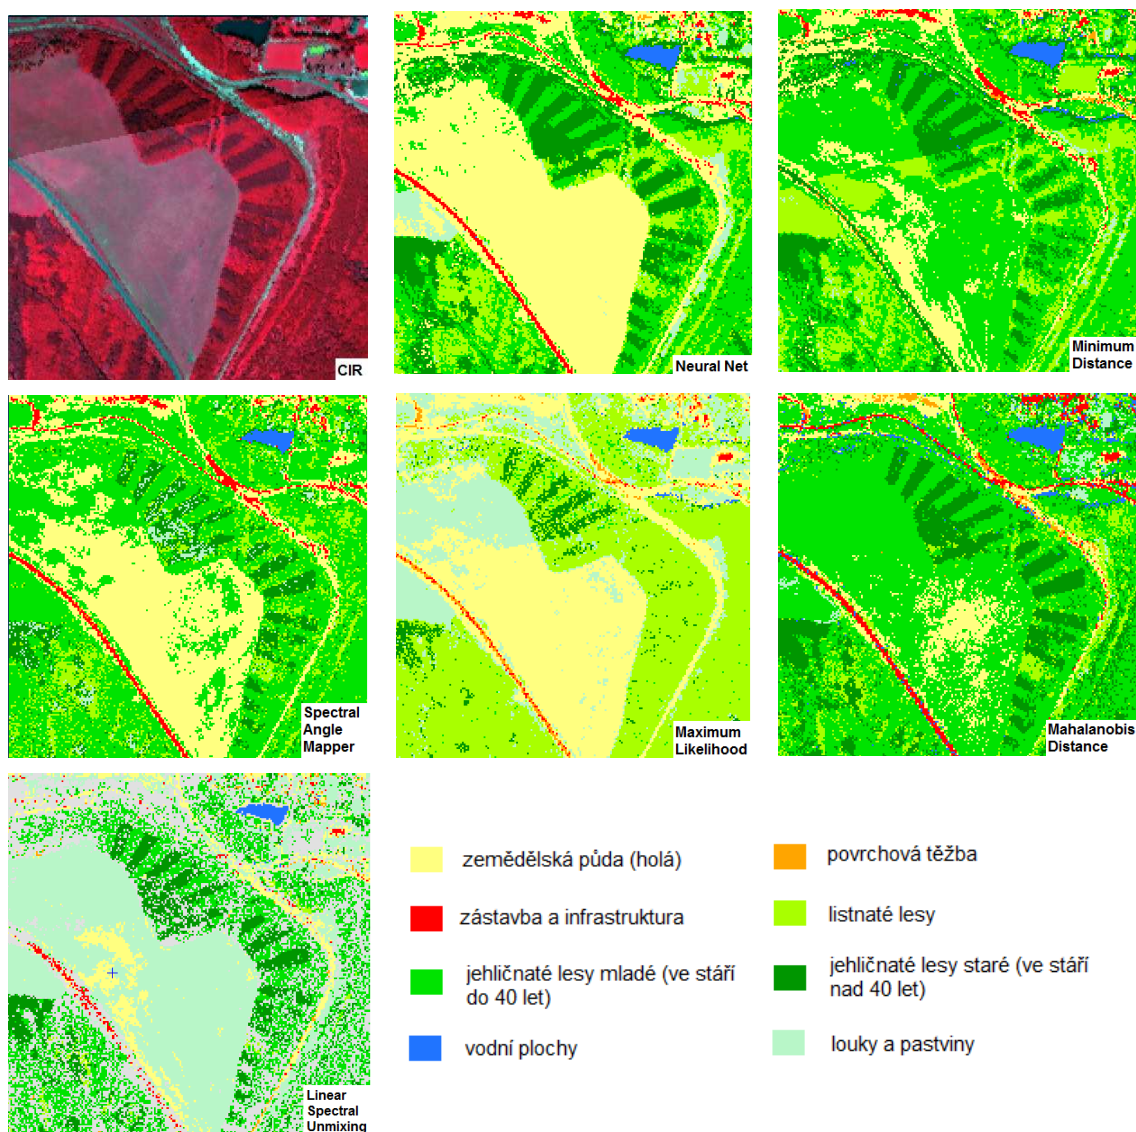
Zdroj: autorka, ENVI

6.3 Porovnání vybraných modelových území

V této části budou porovnány modelové výřezy území, které jsou specifické svým povrchem a použité klasifikační algoritmy vyhodnotily tato území různým způsobem. Na těchto vybraných územích jsou nejlépe zachyceny rozdíly ve výsledcích klasifikací. Pro porovnání byla vybrána odlišná území s různými typy povrchů, přičemž komparace proběhla mezi všemi použitými klasifikátory a subpixelovou analýzou, reálný snímek území je zastoupen výřezem zobrazeným v modu CIR.

Prvním příkladem je oblast, kde dochází ke střídání starých a mladých jehličnatých lesů *severně od Sokolova*, ale i zemědělská plocha JZ od pásu střídajícího se stáří lesa (viz obr. 19). Tmavé pásy lesa v zobrazení barev CIR patří jehličnatým lesům ve stáří nad

40 let, světlejší plochy znázorňují mladé jehličnaté lesy, šedomodrá barva na ploše JZ od lesů představuje lehce zatravněnou zemědělskou půdu.



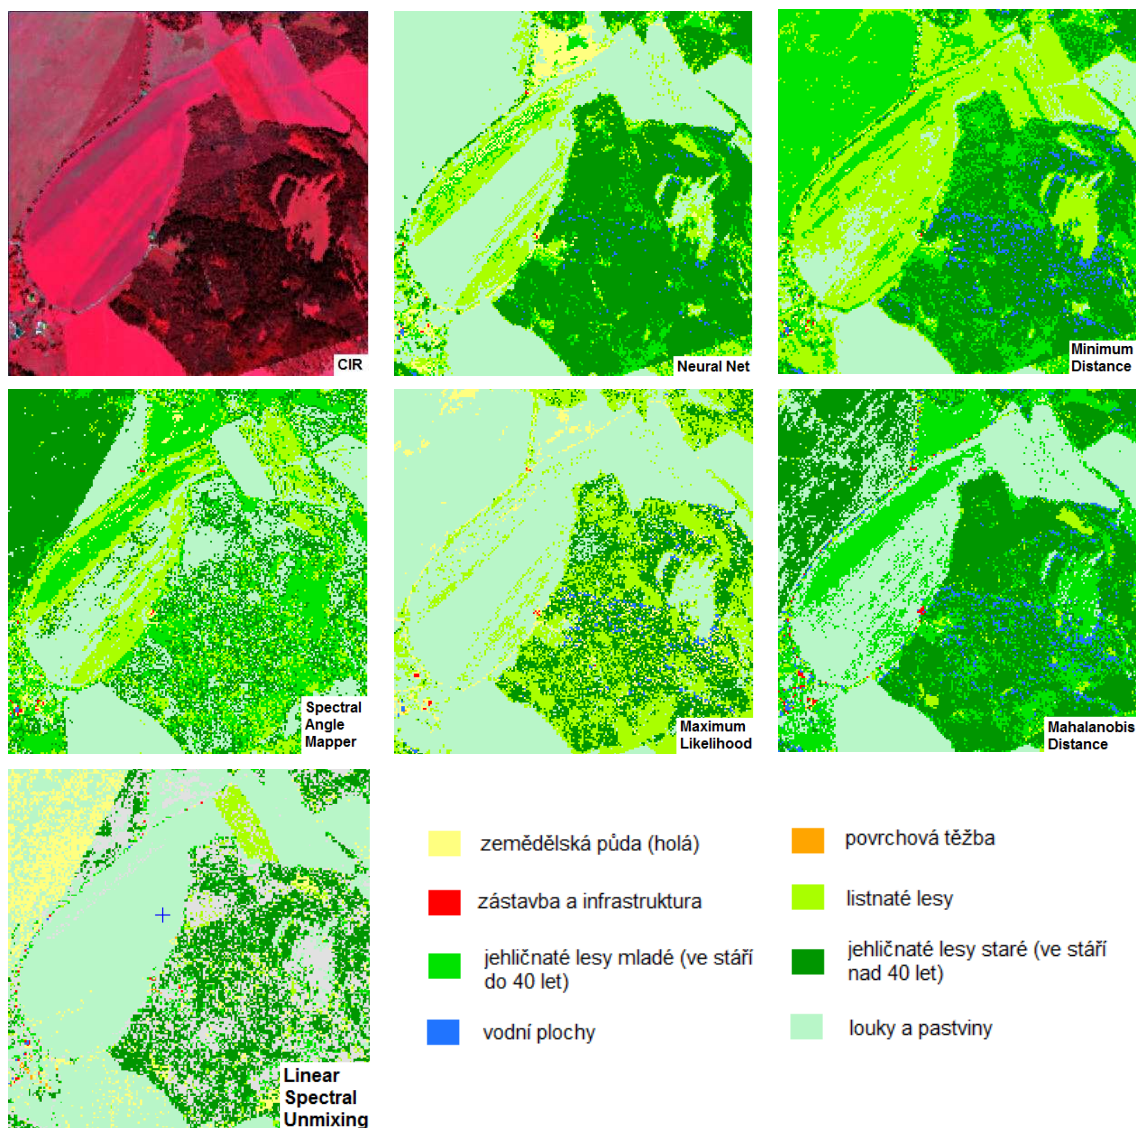
Obr. 19 Porovnání klasifikace první modelové oblasti severně od Sokolova

Zdroj: autorka, ENVI

Klasifikátory tuto oblast vyklasifikovaly různě, ačkoli náznak střídání pásů starého a mladého jehličnatého lesa je u všech použitých algoritmů. Pouze klasifikátor maximální věrohodnosti určil chybně mladý jehličnatý les do 40 let, který zaměnil za listnatý les. Větší rozdíl je na ploše, která je částečně zatravněna. Klasifikátor neurálních sítí určil plochu jako zemědělskou půdu, podobné řešení poskytl i klasifikátor maximální věrohodnosti (kombinace zemědělské půdy a louky) a klasifikátor spektrálních úhlů (zemědělská půda a špatně vyklasifikovaný mladý jehličnatý les). Algoritmus minimální vzdálenosti a Mahalanobisovy vzdálenosti vyklasifikoval většinu plochy jako mladý jehličnatý les do

40 let. Za nejsprávnější řešení je považován výsledek klasifikace algoritmem neurálních sítí a výsledek subpixelové analýzy, ačkoli se nejeví tolik kompaktně a jednotně.

Další modelová oblast se nachází východně od obce Háj (viz obr. 20). Jedná se o výsek lesa, který je obklopen loukami a pastvinami. Většina plochy lesního výseku je tvořena především starými jehličnatými lesy ve stáří nad 40 let. Nejlépe tuto oblast vyklasifikoval algoritmus neurálních sítí, minimální vzdálenosti a Mahalanobisovy vzdálenosti.



Obr. 20 Porovnání klasifikace druhé modelové oblasti východně od obce Háj

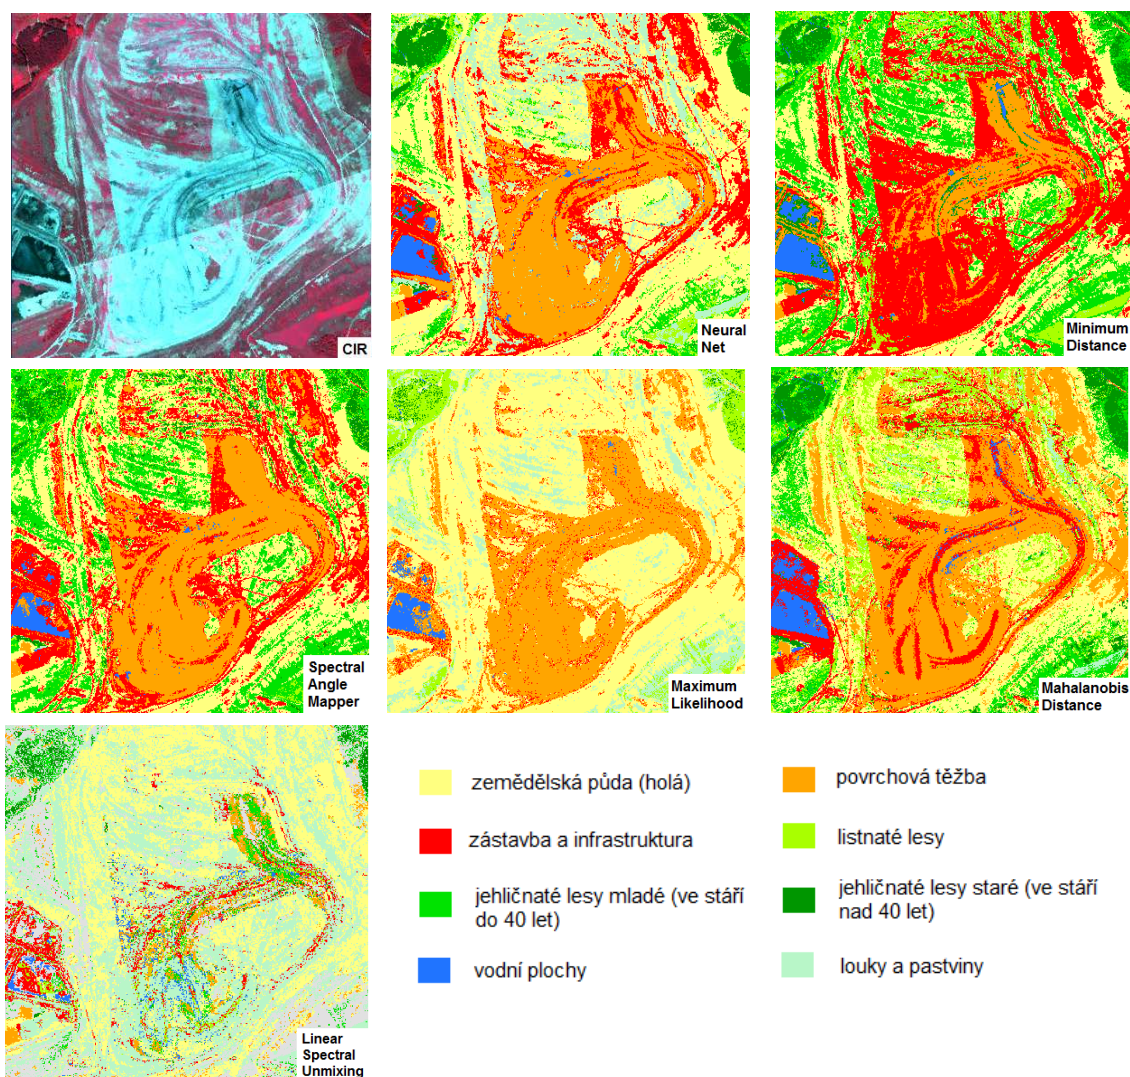
Zdroj: autorka, ENVI

Ovšem jsou zde patrné špatně vyklasifikované pixely stínu stromů, které byly určeny jako vodní plochy, tyto drobné nedostatky byly odstraněny druhým kolem klasifikace. Větší nepřesnosti v klasifikaci lesního výseku jsou patrné u klasifikace algoritmem maximální věrohodnosti a klasifikátoru spektrálních úhlů (výsledek spíše napovídá smíšenému lesu). Taktéž subpixelová analýza určila lesní výsek s drobnými nepřesnostmi –

větší plochy mýtin, než je v reálu. Různorodě byly také vyklasifikovány okolní louky a pastviny. Zatímco klasifikátor neurálních sítí a maximální věrohodnosti vyklasifikoval okolí správně jako louku, ostatní klasifikátory zde určily tyto plochy jako zalesněné.

Společným chybným rysem všech klasifikací jsou dva úzké pruhy SZ od lesního porostu, které byly klasifikovány jako listnaté lesy, ačkoli se jedná o louku. Tento fakt je způsoben velkou podobností spektrálních křivek louky a listnatého lesa, a bohužel ani při využití druhého kola klasifikace nedošlo k odstranění těchto chybně určených pixelů. Luční plocha v horním levém rohu výřezu byla ve většině případů klasifikována také chybně jako stromová vegetace. Nejlépe určila okolí lesního výseku subpixelová analýza, která oklasifikovala území jako louku bez výše zmíněných úzkých pruhů.

Třetí modelová oblast se nachází východně od obce Vřesová (viz obr. 21). Jedná se o území, které zachycuje povrchovou těžbu.



Obr. 21 Porovnání klasifikace třetí modelové oblasti východně od obce Vřesová

Zdroj: autorka, ENVI

Problémem při rozlišení holé půdy, na které probíhá těžba, je podobnost se zastavěným územím, spektrální křivky vyznačují určité společné rysy, a proto v některých případech dochází k chybnému vyklasifikování.

Území současné povrchové těžby se vyznačuje také velkým množstvím odkryté zeminy, která na okrajových místech již zarůstá travinami. V případě zobrazení území modem CIR je tato oblast téměř bez chlorofylu a zobrazuje se jako tyrkysově modrá, částečně růžové plochy zachycují chlorofyl nacházející se ve vegetaci.

Nejlépe tuto oblast vystihl algoritmus Maximum Likelihood, který ovšem neuspěl v jiných třídách a místech obrazu. Naopak nejméně přesně vyklasifikoval oblast algoritmus Minimum Distance, který vyhodnotil téměř celou oblast jako zastavěnou a zalesněnou mladými jehličnatými stromy. Výsledek subpixelové analýzy přiřadil většinu vybraného území k holé půdě a částečně také k loukám. Naopak zde úplně chybí třída povrchové těžby. Současně je zde vyklasifikována i zástavba, naopak vodní plocha, která se nachází v levé spodní části výřezu, zde úplně chybí.

Klasifikátor neuronových sítí, který poskytl komplexně nejlepší výsledky, zde přiřadil území povrchové těžby částečně i do třídy zástavby, zatrávnění v oblasti je zde vyjádřeno třídou luk a pastvin.

6.4 Shrnutí dosažených výsledků

Primárním předpokladem práce bylo dosažení nejvyšší přesnosti klasifikace při použití algoritmu neuronálních sítí. Tento předpoklad se potvrdil, klasifikace algoritmem neuronálních sítí dosáhla celkové přesnosti 77,20 %. Přesnost klasifikace přímo souvisí s prostorovým rozlišením dat, v tomto případě 5 m/pixel. Při lepším prostorovém rozlišení je pravděpodobné, že dosažená přesnost klasifikace by byla vyšší. Vyšší přesnosti klasifikace lze taktéž dosáhnout při použití spektrálních knihoven, které jsou k dispozici pro některé hyperspektrální senzory. Naopak nejmenší přesnost vykazuje použití klasifikátoru minimální vzdálenosti (49,00 %).

Veškeré výsledky klasifikací dokazují rozdílnost algoritmů a jejich postupů při výpočtu, ačkoli byl pro všechny klasifikace použit stejný soubor trénovacích ploch. Rozdílností algoritmů a principů, na kterých klasifikují a přiřazují data, definuje také rozdílnost a relevantnost výsledků.

Jak bylo výše uvedeno, největší nepřesnosti v klasifikaci jsou patrné u rozlišení lesa a louky, které byly v některých případech zařazeny do jednoho z typů lesa. Další nepřesnosti vznikly při klasifikaci zástavby a ploch ovlivněných těžebními činnostmi, protože oba povrchy mají podobné odrazivé vlastnosti.

Cílem práce je určení míry podrobnosti klasifikace land cover, které lze dosáhnout s daty s daným rozlišením. Již výše bylo uvedeno, že se s daty s rozlišením 5 m/pixel, se nepodařilo bližší druhové určení vegetace (bukové x dubové x březové lesy). Pro potřeby

dalšího výzkumu vlivu těžby v oblasti Sokolovska, se však podařilo odlišit jehličnaté porosty ve stáří do 40 let i nad 40 let. Rozdílnost obou typů stromů je patrná na snímku v modu CIR, kde je dobře patrný rozdíl obsahu chlorofylu v jehličích.

Zvláštním případem klasifikace je subpixelová analýza, jejíž celková přesnost dosáhla 68 %. Již výše bylo zmíněno, že výsledek analýzy působí rozdrobeně, oproti ostatním použitým klasifikátorům. Základní charakteristické rysy v obraze však byly zachyceny velmi dobře, a proto je použití této analýzy vhodné zvláště pro menší území, která se vyznačují výraznými rysy. Ačkoli ani v tomto případě nebylo docíleno větší podrobnosti a nebyly blíže určeny konkrétní druhy dřevin.

KAPITOLA 7

Diskuze postupu zpracování a výsledků

Ačkoli jsou hyperspektrální obrazová data moderním a progresivně rozvíjejícím se zdrojem dat v dálkovém průzkumu Země, stále ještě není jejich použití v analýzách land cover běžné a častěji jsou využívána multispektrální obrazová data. Jejich použitím je možné seznámit se s novými metodami ve zpracování dat.

Použití hyperspektrálních obrazových dat je výhodné především z hlediska množství a šířky spektrálních pásem. Spektrální křivky jsou detailnější než u dat multispektrálních. V některých případech je však nutné dimenzionalitu dat redukovat z důvodu zašumění okrajových pásem. Počet spektrálních pásem v obraze Sokolovské hnědouhelné pánve byl redukován pomocí transformace, podobně jako v případě Madery et al., (2006). V této práci byla zpracovávána taktéž hyperspektrální data ze senzoru HyMap, přičemž výzkum mapuje zemědělské plochy v jižním Německu. Dimenzionalitu dat autoři redukovali již použitím atmosférické korekce (FLAASH – Fast Line of Sight Atmospheric Analysis of Spectral Hypercubes – v ENVI), z dalšího zpracování bylo vyloučeno osm pásem, která byla silně zašuměna. Další redukce počtu spektrálních pásem proběhla využitím PCA transformace (Principal Component Analysis), do samotné klasifikace bylo použito 67 spektrálních pásem z celkových 126 kanálů, které senzor HyMap nabízí. Obdobný postup redukce dimenzionality dat byl použit i na data, která zpracovává předkládaná diplomová práce, atmosférická korekce ATCOR 4 určila pásma s chybovými hodnotami a výrazným zašuměním (pásma 31-38 a 45-52), další pásma byla vyloučena pomocí transformace MNF. Konečný počet použitých pásem v klasifikaci v rámci diplomové práce byl 78.

Zajímavým aspektem studie zabývající se zemědělskými plochami v jižním Německu je také tvorba legendy. Autoři rozlišili celkem šest druhů zemědělských plodin – zatravněné plochy, kukuřičné pole, obilné pole ozim, obilné pole jař, řepku a brambory. Struktura legendy je obdobná jako u této diplomové práce, která obsahuje celkem 9 typů povrchu, přičemž ale navíc rozlišuje stáří lesa. Požadavek na bližší určení stáří lesa není ve studiích zpracovávajících hyperspektrální data příliš častý, naopak se ve většině případů zabývá pouze samotnými typy povrchu a vegetace.

Mader et al., (2006) použili klasifikační algoritmus Maximum Likelihood, s nímž dosáhli celkové přesnosti klasifikace 83,30 %. O možnosti využití klasifikátoru neurálních sítí se studie nezmiňuje, ačkoli v případě zpracování dat Sokolovska jsou jeho výsledky

nejlepší. Přesnost klasifikace dat jižního Německa je vysoká především z důvodu méně členité a rovinné krajiny s pravidelnými tvary polí. Celková přesnost zpracování dat hnědouhelné pánve Sokolovska je nižší o 5 %, ovšem zpracovávané území je výrazně větší (cca 9krát) a členitější.

Mader et al. (2006) dále zmiňují důležitost dostatečného množství pixelů v jednotlivých trénovacích souborech tříd vzhledem k dimenzionalitě dat. Bohužel studie nepopisuje blíže postup sběru trénovacích souborů, nejspíše z důvodu, že rozlišení jednotlivých povrchů bylo patrné pouhým okem. V případě předkládané diplomové práce toto možné nebylo, proto bylo využito infračerveného pásma k rozlišení typu a stáří lesa.

Důležitým poznatkem při zpracování dat jsou možnosti zobrazení obrazových dat pro sběr trénovacích souborů pro klasifikaci. Z existujících možností zobrazení dat - v pravých barvách, v barevné syntéze nebo v modu CIR - je nejvhodnější právě poslední možnost. Využívá blízkého infračerveného pásma, v kterém je zaznamenán nárůst odrazivosti u vegetace díky obsahu chlorofylu. Tento fakt umožňuje zefektivnit výběr trénovacích ploch. Podobný postup při využití infračerveného pásma byl použit i ve studii Hirany et al., (2003), kteří metodu rozvinuli ještě použitím spektrálních knihoven AVIRIS ke klasifikaci dat. Studie se zaměřuje na výzkum mokřadů v národním parku Everglades na Floridě. Autoři zpracovávali hyperspektrální obrazová data ze senzoru AVIRIS se spektrálním rozlišením 20 m/pixel. Podobně jako při zpracování dat Sokolovska, byla i zde použita MNF transformace pro určení množství šumu v obraze, posléze bylo 12 pásem obsahujících šum vyloučeno z klasifikace. Tento postup redukce dimenzionality dat je společný pro většinu studií zpracovávajících hyperspektrální data, autoři zmiňují důležitost tohoto kroku především z důvodu kvalitnějšího a relevantnějšího výsledku.

Studie Hirany et al., (2003) rozšířila zpracování hyperspektrálních obrazových dat o použití spektrální knihovny, která je k dispozici pro data ze senzoru AVIRIS. Knihovna byla rozšířena o spektrálně čisté pixely jednotlivých povrchů, které byly získány pomocí analýzy PPI. V samotné klasifikaci bylo vyklasifikováno 14 tříd mokřadní vegetace, rozsah a hloubka legendy je podobná s legendou, která byla vytvořena pro data Sokolovska. Na zpracování samotné klasifikace bylo využito klasifikačního algoritmu spektrálních úhlů (Spectral Angle Mapper – SAM), přičemž Tutorial ENVI (2009) uvádí jako nejvhodnější použití tohoto klasifikátoru pro analýzy horninového složení povrchu. I přesto je algoritmus SAM často využíván pro analýzy vegetace. Data HyMap pro oblast Sokolovska byla taktéž zpracována za použití klasifikátoru SAM, výsledek prokazuje třetí nejvyšší celkovou přesnost, avšak při chybné klasifikaci mladých jehličnatých lesů.

Ověření přesnosti klasifikace bylo vypočítáno pomocí 537 náhodně vygenerovaných bodů, při obdobné velikosti zájmového území jako je zpracovávaná část hnědouhelné Sokolovské pánve, u které byla celková přesnost klasifikace ověřena pomocí 500 náhodně vygenerovaných kontrolních bodů. Přesnost klasifikace mokřadních oblastí byla s klasifikátorem SAM 65,7 %.

Celkový výsledek klasifikace je ovlivněn nejen výběrem pásem, která do klasifikace vstupují ale i kvalitou trénovacích ploch pro jednotlivé třídy. Literatura bohužel nenabízí podrobnější popis metodiky výběru trénovacích ploch, variant jak kvalitně vybrat trénovací pixely je více. Jednou z možností je využití analýzy Pixel Purity Index (PPI), která určí spektrálně čisté pixely v obraze, které lze následně využít pro trénovací množiny. Problémem je ovšem, že takovýchto spektrálně čistých pixelů bývá v obraze jen velmi malý počet (v závislosti na hodnotě prostorového rozlišení), který by nemusel dostačovat pro jednotlivé třídy a stejně by tedy byl potřeba zásahu operátora, který doplní počet trénovacích pixelů na optimum vzhledem k dimenzionalitě dat. Tento postup byl využit např. ve studii Hirany et al., (2003) nebo Lummeho (2004). Další možností je využití již zmíněného modu CIR, který zobrazí vlastnosti povrchu z hlediska obsahu chlorofylu nebo využití již hotových spektrálních knihoven, které ovšem nejsou dostupné pro všechny senzory. V tomto případě je nutná kvalitní atmosférická korekce, aby následné porovnání spekter bylo možné.

Další fakt, který literatura opomíjí, je určení kvality trénovacích souborů, proto v této diplomové práci byl zvolen vlastní postup – tedy výpočet podobnosti a oddělitelnosti (Signature Separability) jednotlivých trénovacích množin. Aby bylo dosaženo co nejlepšího výsledku, klasifikace proběhla pouze v případě, že hodnota Signature Separability neklesla pod 1,98 (přičemž 2 znamená úplnou oddělitelnost a rozdílnost).

Důležitým krokem ve zpracování dat Sokolovské hnědouhelné pánve bylo sloučení jednotlivých letových linií do jednoho obrazu pomocí metody mozaikování. Bohužel podobné práce zabývající se hyperspektrálními daty neobsahují metodiku sloučení jednotlivých pásů. Cílem mozaikování, které bylo aplikováno na data HyMap, bylo nejen sloučení devíti letových linií, ale také odstranění okrajových částí pásu, jelikož ty se jeví nejvíce zdeformované. Jako optimálním řešením bylo oříznutí překrývajících se částí pásu uprostřed tak, aby na sebe vedlejší letové linie plynule navazovaly. Snímky se tak nepřekrývají a v obraze nejsou dále zpracovávány okrajové zdeformované pixely.

Předkládaná diplomová práce zpracovala hyperspektrální data v dvoukolové klasifikaci, která není popisována v jiné podobné studii, proto byl na data aplikován vlastní zvolený postup. Na nejpřesnější výsledek klasifikace z prvního kola, tj. klasifikace algoritmem neurálních sítí, bylo aplikováno druhé kolo klasifikace s cílem zpřesnit výsledek. Jelikož v prvním kole klasifikace vznikly nepřesnosti především v rozlišení mladých jehličnatých lesů a listnatých lesů a také v rozlišení ploch s povrchovou těžbou a zastavěného území s infrastrukturou, bylo druhé kolo klasifikace zaměřeno především na tyto třídy. Pro každou třídu jsou určeny správně a chybně vyklasifikované pixely z prvního kola a tyto chyby zohledněny ve sběru nových trénovacích souborů. Dojde tak k efektivnímu odstranění chyb z prvního kola klasifikace. Nevýhodou je časově náročnější a relativně složitý postup při následném spojení všech upravených tříd zpět do jednoho obrazu. Tutorial ENVI bohužel neposkytuje k problematice druhého kola klasifikace a následného zpětného sloučení

výsledků do jednoho souboru bližší informace, proto byl vhodný postup určen metodou „pokus – omyl“ a v konečné fázi nalezen nejlépe vyhovující postup sloučení jednotlivých souborů, které vzniknou po druhém kole klasifikace. Druhé kolo klasifikace zpřesnilo výsledek o 8 %, ačkoli se zcela jistě nepodařilo odstranit všechny chybně vyklasifikované pixely. Největší nepřesnosti stále zůstávají mezi třídou zástavba a infrastruktura a povrchová těžba, především díky podobnosti povrchů, které jsou značně antropogenně ovlivněny. Ze všech použitých klasifikátorů a subpixelové analýzy nejlepší výsledky poskytl algoritmus neurálních sítí. Ostatní klasifikátory poskytly výsledky, které byly vhodné jen pro určitou část obrazu, příp. pro vybranou třídu, nejlepší komplexní výsledky však poskytl algoritmus neurálních sítí.

Jedním z primárních úkolů práce bylo určit jaké míry podrobnosti klasifikace, lze s daty HyMap dosáhnout. Podobně jako v případě studie Madery et al., (2006), byly určeny třídy land cover, v případě Sokolovské hnědouhelné pánve bylo navíc rozlišeno stáří jehličnatých lesů, tj. bližší druhové složení vegetace se dle očekávání nezdařilo. Výsledek by bylo možné zlepšit použitím spektrální knihovny, která však pro data HyMap není dostupná. Podobnou hloubku a strukturu legendy uvádí i ve své studii Lumme (2004). S daty ze senzoru AISA s prostorovým rozlišením 1,1 m/pixel vytvořil celkem sedm tříd (jehličnaté lesy, listnaté lesy, sklizené kukuřičné pole, nesklizené kukuřičné pole, zástavba, infrastruktura a cukrová řepa), přičemž dosáhl celkové přesnosti klasifikace 90 % s použitím algoritmu maximální věrohodnosti.

Bolus et al., (1997) zpracovávají jehličnaté lesy na pobřeží oceánu ve státě Washington. Jejich studie je právě jednou z prací, kde by bylo možné přesnost klasifikace vylepšit použitím druhého kola klasifikace. Autoři využívají hyperspektrální data ze senzoru HYDICE s prostorovým rozlišením 3 m/pixel s cílem určit zdravotní stav jehličnaté vegetace. Autoři porovnali spektrální křivky zdravé a nemocné, stresované jehličnaté vegetace. Studie nezmiňuje ani případné použití metody na odstranění šumu, která mohou okrajová pásma nést. Na data byla aplikována klasifikace algoritmem SAM, přičemž autoři přiznávají, že klasifikace poskytuje spolehlivé výsledky v případě velkých, starých a osamocených stromů. V případě mladší, husté a bujné vegetace nebyly výsledky dostatečně přesné. V tomto případě by bylo vhodné zpřesnit výsledek právě aplikací druhého kola klasifikace.

Druhé kolo klasifikace je vhodnou možností, kterou lze zpřesnit nejen klasifikaci land cover, ale i studie zabývající se detailnějšími a podrobnějšími jevy v krajině (stáří lesa, zdravotní stav vegetace, určení konkrétních druhů vegetace atd.), je vhodné i k použití na data s velmi vysokým prostorovým rozlišením, kde lze dosáhnout výsledků s celkovou přesností i přes 95 %.

Současně s klasifikacemi byla na data aplikována i subpixelová analýza Linear Spectral Unmixing, jejíž použití je v podobných analýzách land cover časté. Samotná analýza zpracuje pro každou třídu trénovací množiny dat obraz, který vyjadřuje procentuální

zastoupení daného povrchu ve „spektrálně nečistém pixelu“. S touto analýzou bylo dosaženo na datech Sokolovské hnědouhelné pánve celkové přesnosti 68 %, tedy o 1 % méně než v prvním kole klasifikace algoritmem neurálních sítí. Nejlepší výsledky použitím subpixelové analýzy byly pro třídu mladých a starých jehličnatých lesů, avšak komplexního a přesnějšího výsledku bylo dosaženo s algoritmem neurálních sítí. Subpixelovou analýzou bylo dosaženo relativně dobrých výsledků pro třídy zástavba a infrastruktura v případě studie Lummeho (2004), který porovnává metodu s klasifikací, při které bylo použito více klasifikačních algoritmů. Naopak Zeng et al., (2007) ukazují na efektní využití subpixelové analýzy především u dat se střední hodnotou prostorového rozlišení, kdy je možné vyřešit touto metodou problém spektrálně mixovaných pixelů. Autoři uvádějí, že v případě dat s vysokým rozlišením nemá tato analýza příliš smysl a efektivní výsledky poskytne klasifikace.

KAPITOLA 8

Závěr

Cílem diplomové práce bylo vytvořit metodiku klasifikace vegetačního pokryvu z hyperspektrálních dat za účelem vytvoření podkladové mapy pro studium vlivu těžby v oblasti Sokolovska na zdravotní stav vegetace. Výsledky práce budou součástí projektu Grantové agentury Akademie věd „Assessment of Mining Related Impacts Based on Utilization of ARES Airborne Hyperspectral Sensor“. Projekt se zabývá vlivy a dopadem dlouhodobé těžební činnosti na vegetaci v blízkosti povrchových lomů hnědouhelné Sokolovské pánve.

Hlavním úkolem práce pro její další využití v projektu bylo potřeba primárně rozlišit jehličnaté lesy staré (ve stáří nad 40 let) a jehličnaté lesy mladé (ve stáří do 40 let), vzniklé výsledky byly zaneseny do podkladových map, s nimiž bude nadále pracováno v projektu. V klasifikaci land cover však nebyly určeny pouze tyto dvě třídy, ale celé území o rozloze cca 200 km² bylo rozřazeno do celkem deseti tříd, které dobře popisují zkoumané území.

Pro zpracování klasifikace bylo využito hyperspektrálních dat HyMap vzniklých při letecké kampani v červenci 2009. Nezpochybnitelnou výhodou hyperspektrálních dat je množství a šířka spektrálních pásem, která data obsahují. Pro každý povrch (pixel) je tedy možné zobrazit téměř hladkou a spojitou spektrální křivku, která dobře charakterizuje vlastnosti povrchu. Zobrazit spektrální křivky lze i pro multispektrální data, ovšem výsledek bude v podobě lomené čáry. V některých případech je ovšem potřeba dimenzionalitu dat upravit, především z důvodu, že okrajové kanály mohou obsahovat značné množství šumu, který je vhodné odstranit. Spolu s atmosférickou korekcí bylo odstranění šumu důležitou součástí předzpracování hyperspektrálních dat HyMap. Vzhledem příznivým atmosférickým podmínkám mohla být data sloučena, z celkem devíti letových linií tak vznikl jeden obraz, na který byla následně aplikována klasifikace.

K dosažení cíle bylo potřeba překonat několik problémů při zpracování. Důležitým momentem práce byl výběr trénovacích souborů, které do značné míry ovlivnily výsledek klasifikace, proto bylo důležité ověřit před samotnou klasifikací kvalitu trénovacích souborů.

Na hyperspektrální data bylo aplikováno pět klasifikačních algoritmů, přičemž vstupní trénovací soubor dat byl ve všech případech stejný pro následné relevantní porovnání a hodnocení klasifikací. Hodnocení výsledků proběhlo nejen z hlediska dosažené přesnosti klasifikace, ale i z hlediska vnitřního zastoupení tříd v jednotlivých klasifikacích a také

vzájemné porovnání výsledů na vybraných modelových územích. Nejpřesnější výsledek klasifikace poskytl algoritmus neurových sítí, přičemž aplikace druhého kola klasifikace zajistila celkovou přesnost 77,20 %. Naopak nejméně přesně vyklasifikoval území algoritmus minimální vzdálenosti, který dosáhl celkové přesnosti pouze 49,00 %. Metoda porovnání vybraných modelových území dobře odhalila, který výsledek nejlépe odpovídá skutečnosti a zohledňuje nejen spektrální vlastnosti povrchu, ale i reálné charakteristiky území. Nejlépe bylo zpracovávané území vyklasifikováno algoritmem neurálních sítí, nejen z hlediska přesnosti, ale i reálnosti a kompaktnosti výsledku, který byl také srovnán s verifikačními daty (Lesnické mapy). Jelikož se data ze senzoru HyMap vyznačují prostorovým rozlišením 5 m/pixel bylo přistoupeno i k subpixelové analýze, která však nepotvrdila výraznější zpřesnění výsledů.

Mezi pozitiva dosažených výsledků lze počítat přesné rozlišení mladých a starých jehličnatých lesů, jež bylo primárním úkolem, a dále velmi přesné zachycení zemědělských a lučních ploch a v neposlední řadě také rozlišení vodních ploch, které má charakteristickou křivku odrazivosti.

Předpokladem klasifikace byl vznik nepřesností především při rozlišení mladých a starých jehličnatých lesů, který se však nepotvrdil. Vhodnějším prostředkem pro rozlišení vegetace se zde ukázalo zobrazení v modu CIR než v pravých barvách. Naopak nedostatky v klasifikaci vznikly především díky podobnosti spektrálních vlastností luk a listnatých lesů, a také v případě infrastruktury a povrchové těžby. Ačkoli bylo pro zlepšení výsledku aplikováno druhé kolo klasifikace, bohužel nedošlo k odstranění všech chybně vyklasifikovaných pixelů, které tak snižují celkovou přesnost klasifikace.

Návrhem na další zpřesnění výsledku je odstranění zaměněných pixelů louky za listnatý les a naopak a také zpřesnění tříd zástavby a povrchových lomů. V obou případech lze chybně vyklasifikované pixely vysvětlit spektrálně podobnými vlastnostmi a také prostorovým rozlišením dat. S vyšším prostorovým rozlišením dat lze předpokládat i větší přesnost a podrobnost klasifikace. S daným rozlišením hyperspektrálních dat lze tedy rozlišit typ lesa (jehličnatý x listnatý), ovšem přesné zastoupení druhů stromů se nezdařilo (bud x dub atd.). Jisté možnosti do budoucna by mohly představovat i spektrální knihovny, které jsou v současnosti k dispozici jen pro určité senzory. Pomocí spektrálních knihoven bude klasifikace jednodušší, jelikož nebude potřeba sbírat trénovací soubory dat, naopak bude náročnější proces předzpracování dat, kdy bude nezbytné přesné provedení atmosférické korekce, které umožní relevantní porovnání spektrální knihovny a určovaných dat.

Hyperspektrální obrazová data jsou progresivně rozvíjejícím se zdrojem dat v dálkovém průzkumu Země a již dnes hrají ve vědeckých studiích nezastupitelnou roli.

SEZNAM POUŽITÝCH ZDROJŮ

- AJITH, A. 2005. *Artificial Neural Networks* [online]. In Handbook of Measuring System Design. Oklahoma, 2005. s. 901-908. [cit. 2010-5-12]. Dostupný z WWW: <http://www.softcomputing.net/ann_chapter.pdf>.
- ALEMIE, B. K. 2005. *Spectral unmixing of hyperspectral and multispectral images for predictive mapping of surface soil organic matter* [online]. Netherlands, 2005. 94 s. [cit. 2010-5-18]. Dostupný z WWW: <http://www.itc.nl/library/papers_2005/msc/gfm/berhanu.pdf>.
- ARCDATA PRAHA. 2010. Webové stránky: *Arcdata Praha – Senzor Hyperion EO – 1* [online]. 2010. [cit. 2010-4-8]. Dostupný z WWW: <<http://www.arcdata.cz/produkty-a-sluzby/geograficka-data/druzicova-data/druzice-a-skenery/eo-1-a-senzor-hyperion/>>.
- BAJCSY, P., GROVES, P. 2004. *Methodology for hyperspectral band selection*. In Photogrammetric Engineering and Remote Sensing journal, University of Illinois, USA, 2004. Vol. 70, num. 7, p. 793-802.
- BOLUS, R. ...[et al.]. 1997. *Classification of Sitka Spruce Using HYDICE Data Acquired from Forests Near Willapa Bay, Washington*. International Symposium on Spectral Sensing Research, San Diego, California, 1997. 7 s.
- COCKS, T. ...[et al.]. 1998. *The HyMapTM airborne hyperspectral sensor: The system, calibration and performance* [online]. EARSEL Workshop on Imaging Spectroscopy, Zurich, 1998. 6 s. [cit. 2010-5-10]. Dostupný z WWW: <http://www.neodc.rl.ac.uk/docs/Hymap_specs.pdf>.
- CONGALTON, R. G., GREEN, K. 1999. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. Boca Raton: Lewis Publishers, 1999. 137 s. ISBN 0-87371-986-7

- ČAPER, R., LACKOVÁ, D. 1979. *Reliéf Československa I-IV*. In: Přírodní vědy ve škole, č. 1-4, roč. XXXV. 1979, 15 s.
- DEUTSCHES ZENTRUM FÜR LUFT- UND RAUMFAHRT. 2007. Webové stránky: *ARES* [online]. 2007. [cit. 2010-4-3]. Dostupný z WWW: <http://www.ares.caf.dlr.de/systemspecs_en.html>.
- ENCYKLOPEDIÉ WIKIPEDIA. 2010. [online], [cit. 2010-5-20]. Dostupný z WWW: <http://en.wikipedia.org/wiki/Main_Page>.
- ENVI. 1997. *ENVI Tutorial: Vegetation Hyperspectral Analysis* [online]. 1997. 14 s. [cit. 2010-2-5]. Dostupný z WWW: <http://www.itvis.com/portals/0/tutorials/envi/Vegetation_Analysis.pdf>.
- ENVI. 2009. *ENVI Tutorial: Advanced Hyperspectral Analysis* [online]. 2009. 28 s. [cit. 2010-2-5]. Dostupný z WWW: <http://www.itvis.com/portals/0/tutorials/envi/Adv_Hyperspectral_Analysis.pdf>.
- ESA. 2010. Webové stránky: *ESA – Senzor CHRIS* [online]. 2010. [cit. 2010-4-7]. Dostupný z WWW: <http://www.esa.int/esaMI/Proba_web_site/SEMFVBIK97G_0.html>.
- GALKA, T. 2009. Webové stránky: *Methoden der Fernerkundung: Multi-und hyperspektrale Klassifikation von Feuchtgebieten mittels Ableitungsanalysen und spektralem Entmischen* [online]. 2009. [cit. 2010-5-9]. Dostupný z WWW: <http://remote-sensing.carto-media.eu/thesis/1_beschreibung.htm>.
- GURNEY, K., GURNEY, K. N. 1997. *An introduction to neural networks*. UCL Press, 1997. 234 s. ISBN 1857285034.
- HANUŠ, J. 2010. *Data processing report for pre-processing of hyperspectral HyMap data acquired during HypSo 2009 flight campaign*. Akademie věd ČR: Ústav systémové biologie a ekologie, 2010. 8 s.
- HIRANO, A. ...[et al.]. 2003. *Hyperspectral image data for mapping wetland vegetation* [online]. In *Wetlands*. Japan, 2003, roč. 23, č. 2, s. 436-448. [cit. 2010-5-12]. Dostupný z WWW: <<http://www.crms.uga.edu/pubs/hirano%20wetlands%202003.pdf>>.

- HSIEH, P., LANDGREBE, D. 1998. *Lowpass Foilter For Icreasing Class Separability* [online]. International Geoscience and Sensing Symposium, Seattle, Washington, 1998. 4 s. [cit. 2010-7-09]. Dostupný z WWW: <<http://cobweb.ecn.purdue.edu/~landgreb/Hsieh.LowPass.pdf>>.
- CHAN, J. CH., CANTERS, F. 2007. *Esemble Classifiers for Hyperspectral Classification* [online]. Vrije Universiteit Brussel, Department of Geography, Brussels, Belgium, 2007. 11 s. [cit. 2010-6-02]. Dostupný z WWW: <http://5thearselsigis.vgt.vito.be/CD/Fullpapers/Chan_final.pdf>.
- CHANG, CHEIN-I. 2003. *Hyperspectral Imaging: texgniques for spectral detection and classification*. Kluwer Academic/Plenum Publishers, New York, USA, 2003. 374 s. ISBN 0-306-47483-2.
- KAYITAKIRE, F., DEFOURNEY, P. 2004. *Forest type descrimination using multi-angle hyperspectral data* [online]. Belgium, Université Catholique de Louvain: Department of Environmental Sciences and Land Use Planning, 2004. 13 s. [cit. 2010-5-20]. Dostupný z WWW: <http://earth.esa.int/workshops/chris_proba_04/papers/18_Kayit.pdf>.
- KOLÁŘ, J. ...[et al.]. 1997. *Dálkový průzkum Země 10*. Praha: Vydavatelství ČVUT, 1997. 164 s. ISBN 80-01-01567-X.
- KOPAČKOVÁ, V. 2009. *Webové stránky: Assessment of Mining Related Impacts Based on Utilization of (ARES) Airborne Hyperspectral Sensor* [online]. 2009. [cit. 2010-5-9]. Dostupný z WWW: <<http://www.geology.cz/project619100/>>.
- LANTORA, J., VAŠKOVÁ, Z. 2006. *Neuronové sítě v DPZ* [online]. Fakulta životního prostředí, Univerzita J. E. Purkyně, Ústí nad Labem. 2006. 8 s. [cit. 2010-5-8]. Dostupný z WWW: <http://gis.fzp.ujep.cz/files/0608_NeuronoveSite.pdf>.
- LESY ČESKÉ REUBLIKY. 2001. *Mapa porostní 1:10 00 – LČR-LS KRASLICE-LHC KRASLICE, Revír 09 Háje*. Brno, LHProjekt a.s., 2001.
- LESY ČESKÉ REUBLIKY. 2001. *Mapa porostní 1:10 00 – LČR-LS KRASLICE-LHC KRASLICE, Revír 10 Hřebeny, sever*. Brno, LHProjekt a.s., 2001.

- LUMME, J. H. 2004. *Classification of vegetation and soil using imaging spectrometer data* [online]. Helsinky, Finland, 2004. 5 s. [cit. 2010-5-1]. Dostupný z WWW: <<http://www.cartesia.org/geodoc/isprs2004/comm7/papers/16.pdf>>.
- MADER, S. ...[et al.]. 2006. *Crop classification with hyperspectral data of the HyMap sensor using different feature extraction techniques* [online]. 2nd Workshop of the EARSeL SIG on Land Use and Land Cover, Bonn, 2006. s. 96-101. [cit. 2010-5-12]. Dostupný z WWW: <http://www.univ-trier.de/fileadmin/fb6/prof/FER/dateien/Vohland/Vohland_Crop_class_96-101.pdf>.
- NASA. 2009. Webové stránky: *AVIRIS* [online]. 2009. [cit. 2010-4-5]. Dostupný z WWW: <<http://aviris.jpl.nasa.gov/>>.
- PLAZA, J. ...[et al.]. 2007. *Joint Linear/Nonlinear Spectral Unmixing of Hyperspectral Image Data* [online]. Spain: University of Extremadura, 2007. 4 s. [cit. 2010-5-25]. Dostupný z WWW: <http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=4423735>.
- POLÁČKOVÁ, J. 2008. *Podoba a struktura kvalifikačních prací na katedře* [online]. Praha, 2008 [cit. 2007-04-22]. Dostupné z WWW: <<http://www.natur.cuni.cz/gis/>>. Materiál vytvořený J. D. Bláhou pro studenty, kteří píšou svou kvalifikační práci na katedře aplikované geoinformatiky a kartografie na Přírodovědecké fakultě Univerzity Karlovy.
- PRŮMYSL U NÁS. 2005. Webové stránky: *Velmi stručná charakteristika severočeských hnědouhelných pánví*. [online]. 2005 [cit. 2007-04-28]. Dostupné z WWW: <<http://prumysl.unas.cz/texty/panve/SCHSHP.htm>>.
- ROTHBAUER, I. M. ...[et al.]. 2003. *Územní prognóza území dotčeného těžbou hnědého uhlí na Sokolovsku* [online]. Praha: Atelier T-plan, s.r.o, 2003. 188 s. [cit. 2010-5-9]. Dostupný z WWW: <http://www.kr-karlovarsky.cz/kraj_cz/karlov_kraj/dokumenty/koncepce/seznam/UPDK/upg_so.htm>.
- SOKOLOVSKÁ UHELNÁ, a. s. 2007. *Tvorba nové krajiny na Sokolovsku* [online]. Sokolov. 2007. 28 s. [cit. 2010-5-9]. Dostupný z WWW: <http://www.suas.cz/uploads/110170487247b2c8037de4b_07162_brozura_eko_su_mail.pdf>.

SPECTRAL IMAGING Ltd. 2009. *Aisa Dual hyperspectral sensor* [online]. Oulu, Finland, (2009). 2 s. [cit. 2010-5-10]. Dostupný z WWW: <<http://www.channelsystems.ca/documents/AISADualver1-07.pdf>>.

TONG, Q. ...[et al.]. 2002. *Forest Species Classification Based on Hyperspectral and Multitemporal CHRIS Images* [online]. Chinese Academy of Science, Beijing, 2002. 5 s. [cit. 2010-5-20]. Dostupný z WWW: <http://earth.esa.int/workshops/4th_chris_proba/session_3/paper13_Tong.pdf>.

TONG, Q. ...[et al.]. 2004. *Hyperspectral remote sensing technology and applications in China* [online]. CHRIS/Proba Workshop, Italy, 2004. 10 s.[cit. 2010-5-10]. Dostupný z WWW: <http://earth.esa.int/workshops/chris_proba_04/papers/39_tong.pdf>.

YANG, CH. ...[et al.]. 2007. *Airborne hyperspectral imagery and linear spectral unmixing for mapping variation in crop yield* [online]. In Precision Agric. Texas, USA, 2007, č. 8, s. 279-296. [cit. 2010-5-20]. Dostupný z WWW: <http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=5289022>.

ZENG, Y. ...[et al.]. 2007. *Using linear spectral unmixing of high spatial resolution and hyperspectral data for geometric-optical modeling* [online]. In Proceedings of 10th ISPMSRS, Davos, Switzerland, 2007. Vol. xxxvi (7/C50), pp. 304-309. [cit. 2010-5-10]. Dostupný z WWW: <http://www.isprs.org/proceedings/XXXVI/7-C50/P31_Zeng_GOMS.pdf>.

SEZNAM PŘÍLOH

- Příloha 1 CD s elektronickou verzí práce
- Příloha 2 Chybová matice klasifikace algoritmem neurálních sítí po 1. kole klasifikace
- Příloha 3 Chybová matice klasifikace algoritmem neurálních sítí po 2. kole klasifikace
- Příloha 4 Chybová matice klasifikace algoritmem maximální věrohodnosti
- Příloha 5 Chybová matice klasifikace algoritmem minimální vzdálenosti
- Příloha 6 Chybová matice klasifikace algoritmem Mahalanobisovy vzdálenosti
- Příloha 7 Chybová matice klasifikace algoritmem spektrálních úhlů
- Příloha 8 Chybová matice klasifikace algoritmem subpixelové analýzy

Příloha 2 Chybová matice klasifikace algoritmem neurálních sítí po 1. kole klasifikace

Accuracy Statistics

Overall Accuracy : 69.750% 95% Confidence Interval (65.123% 74.377%)
Overall Kappa Statistic: 0.640% overall Kappa Variance : 0.001%

Class Name	Producer's Accuracy	95% Confidence Interval	User's Accuracy	95% Confidence Interval	Kappa Statistic
hola puda	71.084%	(60.728% 81.440%)	71.951%	(61.618% 82.285%)	0.6461
tezba	65.625%	(47.606% 83.644%)	84.000%	(67.629% 100.371%)	0.8261
zastavba	35.000%	(11.596% 58.404%)	25.926%	(7.544% 44.308%)	0.2203
listnate	71.429%	(49.726% 93.131%)	36.585%	(20.622% 52.549%)	0.3307
jehlicnat	67.241%	(54.301% 80.182%)	72.222%	(59.350% 85.095%)	0.6751
jehlicnat	78.723%	(69.918% 87.529%)	80.435%	(71.785% 89.085%)	0.7442
vodni plo	85.000%	(66.851% 103.149%)	94.444%	(81.085% 107.804%)	0.9415
louky a p	65.278%	(53.586% 76.969%)	77.049%	(65.677% 88.422%)	0.7201

Zdroj: autorka, PCI Geomatica

Příloha 3 Chybová matice klasifikace algoritmem neurálních sítí po 2. kole klasifikace

Accuracy Statistics

Overall Accuracy : 77.200% 95% Confidence Interval (73.572% 81.028%)
Overall Kappa Statistic: 0.610% overall Kappa variance : 0.001%

Class Name	Producer's Accuracy	95% Confidence Interval	User's Accuracy	95% Confidence Interval	Kappa Statistic
lom	78.000%	(65.518% 90.482%)	86.667%	(75.623% 97.710%)	0.8519
stin	28.571%	(-12.038% 69.181%)	28.571%	(-12.038% 69.181%)	0.2756
zastavba	57.692%	(36.779% 78.606%)	53.571%	(33.313% 73.830%)	0.5102
smrky nad	80.000%	(72.070% 87.930%)	75.214%	(66.963% 83.465%)	0.6822
smrky do	50.649%	(38.833% 62.466%)	53.425%	(41.297% 65.553%)	0.4495
listi	45.098%	(30.461% 59.735%)	48.936%	(33.581% 64.292%)	0.4314
voda	84.000%	(67.629% 100.371%)	95.455%	(84.478% 106.432%)	0.9522
louka	69.863%	(58.652% 81.074%)	76.119%	(65.164% 87.075%)	0.7204
pole	69.136%	(58.459% 79.813%)	59.574%	(49.122% 70.027%)	0.5176

Zdroj: autorka, PCI Geomatica

Příloha 4 Chybová matice klasifikace algoritmem maximální věrohodnosti

Accuracy Statistics

Overall Accuracy : 57.900% 95% Confidence Interval (53.777% 62.623%)
Overall Kappa Statistic: 0.514% Overall Kappa Variance : 0.001%

Class Name	Producer's Accuracy	95% Confidence Interval	User's Accuracy	95% Confidence Interval	Kappa Statistic
poře	85.000%	(75.132% 94.868%)	53.125%	(42.622% 63.628%)	0.4673
lom	63.636%	(52.242% 75.030%)	94.231%	(86.932% 101.530%)	0.9318
zastavba	31.250%	(5.413% 57.087%)	45.455%	(11.483% 79.426%)	0.4365
listi	76.119%	(65.164% 87.075%)	31.481%	(24.021% 38.942%)	0.2088
jehlici d	0.000%	(0.000% 0.000%)	0.000%	(0.000% 0.000%)	0.0000
jehlici n	48.276%	(37.201% 59.351%)	82.353%	(70.910% 93.796%)	0.7864
voda	81.250%	(66.164% 96.336%)	81.250%	(66.164% 96.336%)	0.7997
louka	75.281%	(65.757% 84.805%)	69.792%	(60.086% 79.498%)	0.6325

Zdroj: autorka, PCI Geomatica

Příloha 5 Chybová matice klasifikace algoritmem minimální vzdálenosti

Accuracy Statistics

Overall Accuracy	: 49.000%	95% Confidence Interval (44.518%	53.482%)	
Overall Kappa Statistic:	0.413%	Overall Kappa Variance :	0.001%		
Class Name	Producer's Accuracy	95% Confidence Interval	User's Accuracy	95% Confidence Interval	Kappa Statistic
poře	63.333%	(50.306% 76.360%)	73.077%	(60.059% 86.095%)	0.6941
lom	29.688%	(17.713% 41.662%)	65.517%	(46.494% 84.541%)	0.6046
zastavba	62.500%	(35.653% 89.347%)	20.833%	(8.303% 33.364%)	0.1822
listnate	45.455%	(11.483% 79.426%)	5.952%	(0.297% 11.607%)	0.0384
jehlicnat	73.750%	(63.483% 84.017%)	43.066%	(34.409% 51.722%)	0.3222
jehlicnat	75.532%	(66.309% 84.755%)	72.449%	(63.093% 81.805%)	0.6607
voda	53.846%	(22.900% 84.792%)	43.750%	(16.317% 71.183%)	0.4225
louka	22.222%	(15.512% 28.933%)	100.000%	(98.611% 101.389%)	1.0000

Zdroj: autorka, PCI Geomatica

Příloha 6 Chybová matice klasifikace algoritmem Mahalanobisovy vzdálenosti

Accuracy Statistics

Overall Accuracy	: 58.200%	95% Confidence Interval (58.668%	67.332%)				
Overall Kappa Statistic:	0.556%	Overall Kappa Variance :	0.001%				
Class Name	Producer's Accuracy	95% Confidence Interval	User's Accuracy	95% Confidence Interval	Kappa Statistic		
-----	-----	-----	-----	-----	-----		
pole	67.778%	(54.520%	81.036%)	59.322%	(45.940%	72.704%)	0.5530
lom	59.016%	(45.855%	72.178%)	83.721%	(71.524%	95.918%)	0.8146
zastavba	55.882%	(37.722%	74.043%)	54.286%	(36.353%	72.218%)	0.5095
listi	40.000%	(23.568%	56.432%)	55.172%	(35.348%	74.997%)	0.5127
jehlici d	64.783%	(56.411%	73.154%)	54.088%	(46.028%	62.148%)	0.4037
jehlici n	67.757%	(58.882%	76.632%)	68.750%	(59.719%	77.781%)	0.6064
voda	71.429%	(44.193%	98.664%)	55.556%	(29.822%	81.289%)	0.5428
louka	40.909%	(30.068%	51.750%)	80.000%	(67.202%	92.798%)	0.7573

Zdroj: autorka, PCI Geomatica

Příloha 7 Chybová matice klasifikace algoritmem spektrálních úhlů

Accuracy Statistics

Overall Accuracy : 60.600% 95% Confidence Interval (58.259% 66.941%)
Overall Kappa Statistic: 0.556% Overall Kappa Variance : 0.001%

Class Name	Producer's Accuracy	95% Confidence Interval	User's Accuracy	95% Confidence Interval	Kappa Statistic
poře	68.919%	(57.698% 80.140%)	76.119%	(65.164% 87.075%)	0.7197
lom	74.286%	(58.377% 90.194%)	78.788%	(63.324% 94.251%)	0.7719
zastavba	60.976%	(44.824% 77.127%)	59.524%	(43.488% 75.559%)	0.5591
listi	38.889%	(21.575% 56.203%)	31.818%	(16.919% 46.717%)	0.2653
jehlici d	81.250%	(73.575% 88.925%)	51.124%	(43.499% 58.748%)	0.3701
jehlici n	47.778%	(36.902% 58.653%)	68.254%	(55.966% 80.542%)	0.6129
voda	94.444%	(85.573% 103.316%)	100.000%	(98.529% 101.471%)	1.0000
louka	38.158%	(26.578% 49.737%)	74.359%	(59.373% 89.345%)	0.6976

Zdroj: autorka, PCI Geomatica

Příloha 8 Chybová matice klasifikace algoritmem subpixelové analýzy

Accuracy Statistics

Overall Accuracy : 68.000% 95% Confidence Interval (63.763% 72.037%)
Overall Kappa Statistic: 0.487% overall Kappa variance : 0.001%

Class Name	Producer's Accuracy	95% Confidence Interval	User's Accuracy	95% Confidence Interval	Kappa Statistic
hořa	54.918%	(45.679% 64.157%)	51.145%	(42.203% 60.087%)	0.3538
lom	91.957%	(71.019% 102.894%)	58.824%	(40.810% 76.837%)	0.5684
zastavba	42.857%	(-0.946% 86.661%)	60.000%	(7.059% 112.941%)	0.5943
smrky nad	62.526%	(48.879% 72.174%)	52.874%	(41.810% 63.938%)	0.4443
smrky do	47.297%	(35.246% 59.349%)	59.322%	(45.940% 72.704%)	0.5226
listi	21.000%	(-1.149% 33.149%)	37.500%	(-2.298% 77.298%)	0.3490
voda	74.000%	(47.416% 92.584%)	77.778%	(55.794% 99.762%)	0.7685
louka	65.333%	(50.306% 76.360%)	63.333%	(50.306% 76.360%)	0.5833
poře	63.224%	(51.067% 71.382%)	61.224%	(51.067% 71.382%)	0.5177

Zdroj: autorka, PCI Geomatica