

UNIVERZITA KARLOVA V PRAZE

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Michaela POMAHAČOVÁ

**MOŽNOSTI VYUŽITÍ DPZ PŘI MONITORINGU LUČNÍ VEGETACE A
MANAGEMENTOVÝCH ZÁSAHŮ
V KRKONOŠÍCH**

Diplomová práce

Vedoucí diplomové práce: RNDr. Lucie Kupková, Ph.D.

Konzultant diplomové práce: Mgr. Stanislav Březina, Ph.D.

Praha 2012

Vysoká škola: Univerzita Karlova v Praze
Katedra: Aplikované geoinformatiky a kartografie

Fakulta: Přírodovědecká
Školní rok: 2011/2012

Zadání diplomové práce

pro Michaelu Pomahačovou
obor Kartografie a geoinformatika

Název tématu: Možnosti využití DPZ při monitoringu luční vegetace a managementových zásahů v Krkonoších

Zásady pro vypracování

Krkonošské tradičně obhospodařované louky jsou jednou z nejcennějších přírodních i krajinářských hodnot Krkonoš. Udržení těchto luk v příznivém stavu vyžaduje jejich pravidelné obhospodařování. Iniciativu při managementu luk přebírá v posledních letech správa Krkonošského národního parku. Nedílnou součástí pro rozhodování o provádění managementových zásahů je i tzv. managementový monitoring zásahů na dané lokalitě. Je nutné zjišťovat, jaký typ zásahu (mulčování, seč, pastva) byl ve zkoumaném časovém úseku proveden. Managementový monitoring vyžaduje také spolehlivé a opakovatelné mapování různých typů luční vegetace. Je třeba odlišit luční porosty s tenkostébelnými středně vzrůstnými travami, jež bývají často druhově bohaté a přírodovědně cenné, od intenzivně hnojených druhově chudých luk s převahou širokolistých travin či od nízkých smilkových trávníků.

Vizuální zjišťování uvedených skutečností mapovateli v terénu má své nevýhody, neboť je často zatíženo velkou subjektivní chybou, která znemožňuje spolehlivou interpretaci map vytvořených rozdílnými mapovateli v různých časových obdobích. Nevýhodou při monitoringu provedených či neprovedených hospodářských zásahů je bezesporu velká časová náročnost. Tyto nedostatky by teoreticky mohly být odstraněny při použití metod dálkového průzkumu Země (DPZ). Metody DPZ by mohly pomoci objektivně a opakovatelně vymapovat základní jednotky vegetace na lučních enklávách a s malou časovou náročností kontrolovat způsob managementu.

Hlavním cílem diplomové práce je zhodnocení možností využití družicových dat WorldView pro klasifikaci základních lučních společenstev modelového území v Krkonoších. Autorka bude při klasifikaci primárně vycházet z legendy navržené botanikem, případně ji upraví na základě možností družicových dat. Ověří také možnost využití dat WorldView 2 pro mapování biotopů Natura 2000 zastoupených v modelovém území.

Dalším cílem práce je ověřit, do jaké míry lze s využitím dat WorldView 2 monitorovat způsoby managementu luční vegetace.

Autorka dále porovná data WorldView 2 s daty Quickbird. Cílem je zjistit, zda spektrální pásma, která obsahují data WorldView-2 navíc oproti datům Quickbird, umožní lépe vyklasifikovat navržené kategorie lučních společenstev.

Hlavním výstupem diplomové práce bude návrh legendy klasifikace lučních společenstev z dat WorldView 2 a na základě této legendy vytvořená mapa luční vegetace modelového území. Výsledky klasifikace budou verifikovány na základě porovnání s výstupy terénního botanického mapování.

Rozsah grafických prací: 1 hlavní grafická příloha – mapa klasifikace lučních společenstev modelového území z dat WorldView 2.

Rozsah průvodní zprávy: 50 stran

Seznam odborné literatury:

CARLE, M. V.; SASSER, CH.; TWILLEY, R. *Mapping deltaic wetland vegetation at the species-level using WorldView-2 multispectral imagery*. Baton Rouge: Louisiana State University, 2011. 15 s.

CINGOLANI, A. M. et al. Mapping vegetation in a heterogeneous mountain rangeland using landsat data: an alternative method to define and classify land-cover units. *Remote Sensing of Environment*, 2004, 92, s. 84–97.

DOBROVOLNÝ, Petr. *Dálkový průzkum Země. Digitální zpracování obrazu*. Brno: Masarykova univerzita, 1998. 208 s.

DOBROWSKI, Solomon Z., et al. Mapping mountain vegetation using species distribution modeling, image-based texture analysis, and object-based classification. *Applied Vegetation Science*. 2008, 11, s. 499-508.

GOPAL, S.; WOODCOCK, C. Theory and Methods for Accuracy Assessment of Thematic Maps Using Fuzzy Sets. *Photogrammetric Engineering and Remote Sensing*. 1994, 60, s. 181-188.

KANNIAH, K. D. *Worldview-2 remote sensing data for tropical mangrove species classification*. Johor: University of Technology Malaysia, 2011. 17 s.

KRAHULEC, František, et al. Louky Krkonoš: Rostlinná společenstva a jejich dynamika. *Opera Corcontica*. 1996, 33, s. 1-252.

MCMAHAN, Ben; WEBER, Keith T.; SAUDER, Joel. Fuzzy Classification of Heterogeneous Vegetation in a Complex Arid Ecosystem. *African Journal of Range and Forage Science*. 2003, 20(2).

PRICE, Kevin P.; GUO, Xulin; STILES, James M. Optimal Landsat TM band combinations and vegetation indices for discrimination of six grassland types in eastern Kansas. *International Journal of Remote Sensing*. 2002, 23, s. 5031–5042.

SHA, Z., et al. Using a hybrid fuzzy classifier (HFC) to map typical grassland vegetation in Xilin River Basin, Inner Mongolia, China. *International Journal of Remote Sensing*. 2008, 8, s. 2317–2337.

Vedoucí diplomové práce: RNDr. Lucie Kupková, Ph.D.

Konzultant diplomové práce: Mgr. Stanislav Březina, Ph.D.

Datum zadání diplomové práce: 30. listopad 2011

Termín odevzdání diplomové práce: srpen 2012

Platnost tohoto zadání je po dobu jednoho akademického roku.

.....

Vedoucí diplomové práce

.....

Vedoucí katedry

V Praze dne

Prohlášení

Prohlašuji, že jsem závěrečnou práci zpracovala samostatně a že jsem uvedla všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze dne 29. 8. 2012

.....

podpis

Poděkování

Na tomto místě bych ráda poděkovala RNDr. Lucii Kupkové, Ph.D. za odborné vedení diplomové práce, za cenné rady a připomínky. Dále bych chtěla poděkovat pracovníkům Správy KRNAP, jmenovitě Mgr. Stanislavu Březinovi, Ph.D., a Mgr. Janu Šturmovi za věnovaný čas při zpracování diplomové práce.

Možnosti využití DPZ při monitoringu luční vegetace a managementových zásahů v Krkonoších

Abstrakt

Cílem diplomové práce bylo zhodnotit možnosti využití družicových dat WorldView-2 pro klasifikaci základních lučních společenstev na modelovém území v Krkonoších. Klasifikace byla založena jednak na legendě sestavené botanikem, jednak na legendě sestavené z biotopů Natura 2000. Z důvodu odstranění vlivu ostatních druhů povrchů na přesnost klasifikace, byla vytvořena maska lučních porostů. S využitím diskriminační analýzy byl zhodnocen význam spektrálních pásem WorldView-2, vybraných vegetačních indexů a komponent analýzy hlavních komponent (PCA) pro rozlišení tříd luční vegetace. Na základě výsledků diskriminační analýzy byly provedeny v softwaru ENVI verzi 4.7 klasifikace metodou neuronových sítí a metodou maximální věrohodnosti. Výsledky obou metod byly porovnány.

Klíčová slova: dálkový průzkum Země, luční společenstva, klasifikace, Krkonoše, WorldView 2

Possibilities of remote sensing in grassland vegetation and management interventions monitoring in the Giant Mountains

Abstract

The aim of this thesis was to evaluate suitability of WorldView-2 imagery for grassland associations classification in the model area of Giant Mountains. The classification was based both on the legend compiled by a botanist, and on the legend of Natura 2000. In order to eliminate the effects of other types of land cover on the classification accuracy, a mask of grasslands was created. Using discriminant analysis, the significance of spectral bands of WorldView-2, as well as significance of selected vegetation indices and components from Principal Component Analysis (PCA) – to distinguish particular classes of grassland vegetation were evaluated. Based on the results of discriminant analysis, classifications using neural networks method and also maximum likelihood method were performed in ENVI 4.7 version software. The results of the both method were compared

Key words: remote sensing, meadows association, classification, Giant mountains, WorldView 2

Obsah

Seznam obrázků a tabulek	10
1 Úvod a cíle práce.....	11
2 Literární rešerše	13
3 Charakteristika zájmového území	20
3.1 Zájmové území	20
3.2 Hlavní typy krkonošských lučních stanovišť	22
4 Data a metodika	27
4.1 Použitá data.....	27
4.1.1 Družicová data WorldView-2	27
4.1.2 Družicová data Quickbird	29
4.1.3 Terénní data.....	29
4.1.4 Ostatní zdroje dat	30
4.2 Předzpracování družicových dat.....	30
4.2.1 Ortorektifikace	30
4.2.2 Maska travních porostů	34
4.3 Legenda luční vegetace.....	36
4.3.1 Legenda stanovená botanikem	36
4.3.2 Legenda dle Nature 2000	38
4.4 Vegetační indexy.....	39
4.5 Diskriminační analýza	41
4.5.1 Využití diskriminační analýzy při klasifikaci lučních společenstev.....	41
4.6 Klasifikace luční vegetace	46
4.6.1 Klasifikátor neuronových sítí	46
4.6.2 Klasifikace v softwaru ENVI	48
5 Výsledky	51
5.1 Výstupy klasifikace.....	51
5.2 Zhodnocení přesnosti klasifikace.....	54
6 Diskuse.....	56
7 Závěr	60
8 Použité zdroje.....	62
Seznam příloh	65

Seznam obrázků a tabulek

Obr. 1 Zájmové území diplomové práce	20
Obr. 2 Horská trojštětová louka v srpnu 2011 na lokalitě Výsluní	22
Obr. 3 Druhově bohatá smilková louka v srpnu 2011 na lokalitě Výsluní.....	24
Obr. 4 Výřez snímku před ortorektifikací	33
Obr. 5 Výřez ortorektifikovaného snímku	33
Obr. 6 Výsledná maska lučních porostů pro zářijový snímek	35
Obr. 7 Diskriminační analýza v prostředí SPSS Statistics	43
Obr. 8 Statistics box	43
Obr. 9 Classification box.....	44
Obr. 10 Save box.....	44
Tab. 1 Fisherova diskriminační funkce pro data WorldView-2	45
Tab. 2 Fisherova diskriminační funkce pro simulovaná data Quickbird	46
Obr. 11 Schéma neuronové sítě.....	47
Obr. 12 Parametry nastavené při použití klasifikátoru neuronových sítí	50
Obr. 13 Klasifikace luční vegetace z dat WorldView-2 algoritmem neuronových sítí v Krkonoších v září 2011....	52
.....	52
Obr. 14 Klasifikace luční vegetace na základě simulovaných dat Quickbird algoritmem neuronových sítí v Krkonoších v září 2011.....	53

1 Úvod a cíle práce

Krkonošské tradičně obhospodařované louky jsou jednou z nejcennějších přírodních i krajinářských hodnot Krkonoš. Mozaika lesů a luk tvoří typický ráz krkonošské krajiny. Nachází se zde téměř třetina druhového bohatství původní krkonošské květeny včetně místního endemitu zvonku českého. Na jedné luční lokalitě lze zjistit více než 160 druhů brouků. Díky výrazné výškové členitosti pohoří a četnosti způsobů obhospodařování se rostliny v Krkonoších nacházejí z ekologického hlediska v rozmanitých kombinacích. Na jediné horské knotovkové louce se tak mohou vyskytovat rostliny typické pro karové hrany s běžnými lučními druhy z Podkrkonoší či se zástupci podmáčených luk.

Udržení těchto luk v příznivém stavu s jejich původní vysokou druhovou rozmanitostí vyžaduje pravidelné obhospodařování. Přirozený management luk však z velké části skončil s odsunem sudetských Němců po druhé světové válce. V posledních letech přebírá iniciativu při managementu správa Krkonošského národního parku (KRNAP). Snahou je obnovit obhospodařování alespoň na části opuštěných luk. Děje se tak přímými zásahy, motivováním k těmto zásahům prostřednictvím dotací Ministerstva životního prostředí či kontrolou dotací od Ministerstva zemědělství.

Nedílnou součástí pro rozhodování o provádění managementových zásahů je i tzv. managementový monitoring zásahů na dané lokalitě od minulosti do současnosti. Je nutné zjišťovat jaký typ zásahu (mulčování, seč, pastva) byl ve zkoumaném časovém úseku proveden či nikoliv. Managementový monitoring vyžaduje spolehlivé a opakovatelné mapování různých typů luční vegetace. Je třeba odlišit luční porosty s tenkostébelnými středně vzrůstnými travami, jež bývají často druhově bohaté a přírodovědně cenné, od intenzivně hnojených druhově chudých luk s převahou širokolistých travin či od nízkých smilkových trávníků. Dále je důležité spolehlivě rozeznat, jakým způsobem byl luční porost v daném roce obhospodařován.

Vizuální zjišťování uvedených skutečností mapovateli v terénu má své nevýhody. Mapování různých typů luční vegetace je často zatíženo velkou subjektivní chybou, která znemožňuje spolehlivou interpretaci map vytvořených rozdílnými mapovateli v různých časových obdobích. Otázkou totiž zůstává, zda lze zjištěné změny přičíst změnám reálným nebo zda byly způsobeny odlišnými mapovacími přístupy různých mapovatelů. Naopak nevýhodou při monitoringu provedených či neprovedených hospodářských zásahů je bezesporu velká časová náročnost.

Všechny tyto nedostatky terénního monitoringu by teoreticky mohly být odstraněny při použití metod dálkového průzkumu Země (DPZ). Metody DPZ by mohly pomoci objektivně a opakovatelně vymapovat základní jednotky vegetace na lučních enklávách a s malou časovou náročností kontrolovat způsob managementu. Zásadním problémem ztěžujícím aplikaci těchto metod pro naznačené účely jsou však pochybnosti o schopnosti rozpoznat a klasifikovat smysluplné jednotky v rámci lučních porostů z družicových snímků.

Hlavním cílem diplomové práce je zhodnocení možností využití družicových dat WorldView 2 pro klasifikaci základních lučních společenstev modelového území v Krkonoších. Klasifikace bude primárně vycházet z legendy navržené botanikem, případně bude upravena na základě možností družicových dat. Ověří se také možnost využití dat WorldView 2 pro mapování biotopů Natura 2000 zastoupených v modelovém území. Dalším cílem práce je ověřit, do jaké míry lze s využitím dat WorldView 2 monitorovat způsoby managementu luční vegetace. Dále budou porovnána data WorldView 2 s daty Quickbird. Cílem je zjistit, zda spektrální pásma, která obsahují data WorldView-2 navíc oproti datům Quickbird, umožní lépe vyklasifikovat navržené kategorie lučních společenstev.

Hlavním výstupem diplomové práce bude návrh legendy klasifikace lučních společenstev z dat WorldView 2 a na základě této legendy vytvořená mapa luční vegetace modelového území. Výsledky klasifikace budou verifikovány porovnáním s výstupy terénního botanického mapování.

2 Literární rešerše

Klasifikace přirozené heterogenní vegetace, jakou představují také krkonošská luční společenstva, je poměrně náročným úkolem. Stejný typ luční vegetace může mít na družicových snímcích odlišné spektrální vlastnosti a naopak (Cingolani et al. 2004, Stuart et al. 2006). Je tedy zřejmé, že klasifikace pouze z hlediska botanického či pouze z hlediska spektrálního nemůže vést k uspokojivým výsledkům. Avšak klasifikační systém vytvořený kombinací obou hledisek nemusí vyhovovat botanikům, kteří preferují především rostlinná společenstva (Sha et al. 2008).

Dalším problémem může být stanovení odpovídající hierarchické úrovně pro mapování (Cingolani et al. 2004), která závisí především na prostorovém rozlišení družicových dat. Nejčastěji se v odborné literatuře vyskytují studie používající ke klasifikaci přirozené vegetace data Landsat se středním prostorovým rozlišením, která však neumožňují vytvořit klasifikační třídy, které by byly více homogenní (McMahan et al. 2003). Jak uvádí Cingolani et al. (2004) mapování přirozené vegetace z družicových dat se středním rozlišením pomocí konvenčních klasifikačních technik čelí třem hlavním problémům - stanovení odpovídající hierarchické úrovně pro mapování, definování jednotlivých tříd pokryvu Země rozpoznatelných z dat DPZ a výběru reprezentativních trénovacích ploch.

Další otázkou při klasifikaci vegetace zůstává výběr klasifikační techniky. Obecně platí, že pro heterogenní společenstva, kde může existovat vysoká variabilita uvnitř pixelu, je vhodnější měkká a statisticky založená klasifikace jako fuzzy klasifikace, zatímco konvenční tvrdé klasifikátory mohou dosahovat dobrých výsledků u homogenní vegetace (Sha et al. 2008). Tradiční metody klasifikace dat DPZ tak nemusí přesně vystihovat složitost ekosystémů, které se vyznačují různorodou a variabilní strukturou vegetace (McMahan et al. 2003). Proto vzniká řada alternativních přístupů k vegetační klasifikaci.

Jeden z alternativních přístupů představuje studie zabývající se mapováním horské vegetace z družicového snímku Landsat ETM+ s prostorovým rozlišením 30 m založená na objektově orientované klasifikaci, kterou provedl Dobrowski et al. (2008) v povodí vodního toku American River na území západního svahu pohoří Sierra Nevada v Kalifornii. Zájmové území o velikosti 24 tis. ha zahrnovalo nadmořské výšky od 320 do 2190 m. Obrazové objekty vymezené na základě automatické obrazové segmentace byly klasifikovány pomocí metody rozhodovacího stromu s využitím údajů získaných z jednotlivých modelů rozšíření vegetačních druhů a odhadů pokrytí forem vegetace odvozených z texturní analýzy

leteckého snímku. Modelem rozšíření vegetace se rozumí rastrový obraz charakterizující pravděpodobnost výskytu daného druhu. Tyto modely byly vytvořeny na základě topografických a bioklimatických dat a dat získaných terénním průzkumem a představují jakýsi ekologický model, který předpokládá, že vegetační společenstva se skládají z druhů seskupených podle biofyzikálních parametrů. Na základě texturní analýzy leteckého snímku byly identifikovány čtyři formy vegetace zahrnující listnatý a jehličnatý les, keře a bylinnou vegetaci. Pro každou třídu bylo digitalizováno minimálně sto polygonů, které sloužily jako tréninková a validační data. Celkem bylo klasifikováno 12 rostlinných společenstev s celkovou přesností 75 % a hodnotou kappa 0,69. Využití modelů rozšíření druhů zlepšilo klasifikační přesnost asi o 15 %, zatímco zahrnutí pokrytí forem vegetace z leteckého snímku v klasifikátoru výslednou přesnost příliš nezvýšilo. Dosažené výsledky poukazují na význam topografických, půdních a bioklimatických proměnných, obsažených v jednotlivých modelech rozšíření vegetace, při mapování rostlinných společenstev v členitém terénu, který představuje také území Krkonoš. Metoda rozhodovacího stromu je vhodná pro uvedený typ problému, neboť umožňuje účinně optimalizovat velké množství vážených kombinací (Benediktsson and Sveinsson 2003) a je schopná zvládnout i nelineární interakce (De'Ath and Fabricius 2000).

Odlisný přístup ke klasifikaci horské vegetace nabízí Cingolani et al. (2004) ve studii provedené na heterogenních horských pastvinách v horní části Córdobského pohoří v centrální oblasti Argentiny. Území o rozloze 124,7 tis. ha zahrnuje nadmořské výšky od 1700 do 2800 m n. m. Zájmové území se skládá z mozaiky travnatých porostů, pasených travníků, lesů s *Polylepis australis*, žulových výchozů a erodovaných oblastí s obnaženým horninovým podkladem. Ve studii byl použit družicový snímek Landsat 5 TM z první části vegetačního období roku 1997 (14. 11. 1997) a 251 terénních vzorků o velikosti minimálně 4 x 4 pixely. Celkem bylo definováno osm tříd land cover na základě ekologických kritérií a především jejich vztahu k spektrálním datům, který byl pro stanovení výsledných mapových jednotek rozhodující. Tímto způsobem se zvýšila pravděpodobnost dosažení přesnější klasifikace oproti případu, kdy je uvažován pouze jeden z těchto přístupů. Daný klasifikační systém však nemusí vyhovovat biologům, kteří preferují rostlinná společenstva a nikoliv kombinace strukturních typů. To způsobuje problémy v klasifikaci vegetace pomocí dat DPZ, jelikož spektrální data nasbíraných terénních vzorků nemusí dostatečně odrážet rozdíly rostlinných společenstev (Sha et al. 2008). Klasifikace scény Landsat byla provedena pomocí Fisherovy lineární klasifikační funkce odvozené z diskriminační analýzy, jejímž cílem je minimalizovat rozptyl v rámci dané třídy a maximalizovat rozdíly mezi jednotlivými třídami.

Pro srovnání byl snímek klasifikován také tradiční metodou maximální věrohodnosti, neboť každý nový přístup by měl být konfrontován s běžně používanou metodou kvůli zjištění určitého zlepšení v konečném výsledku (Sha et al. 2008). Fisherova klasifikační funkce zahrnovala všechna spektrální pásma jako proměnné. Pro každou třídu land cover byla vytvořena lineární kombinace vstupních proměnných (pásem), celkem tak bylo vygenerováno osm lineárních kombinací. Každý pixel byl následně podroben osmi lineárním transformacím. Nakonec bylo porovnáno osm výsledných hodnot pro každý pixel a daný pixel byl pak přiřazen k třídě s nejvyšší hodnotou. Celková přesnost klasifikačního přístupu založeného na diskriminační funkci dosáhla 86 % v porovnání s metodou maximální věrohodnosti, jejíž přesnost byla 78 %.

Alternativním přístupem pro klasifikaci heterogenních vegetačních oblastí s vysokou variací uvnitř pixelu může být fuzzy logic (Cingolani et al. 2004). „*Fuzzy logic označuje skupinu algoritmů a rozhodovacích pravidel, které nejsou pevné, v každém kroku jednoznačně definované, ale umožňují pracovat s určitou mírou nejistoty*“ (Dobrovolný 1998). Fuzzy klasifikace umožňuje na rozdíl od tvrdých klasifikátorů zařadit každý pixel do více tříd (Zhang a kol. 1998). Pro každý pixel je vypočtena pravděpodobnost příslušnosti k dané třídě na základě sestavení tzv. funkce příslušnosti = membership function (Dobrovolný 1998). Příslušnost obrazového prvku k určité kategorii se pohybuje od úplné příslušnosti - 100 % až k nulové příslušnosti - 0 % (Gopal and Woodcock 1994).

Fuzzy klasifikaci s tradiční metodou řízené klasifikace maximální věrohodnosti srovnává McMahan et al. (2003) ve studii zaměřené na stepní vegetaci náhorní plošiny Snake River na jihovýchodě státu Idaho, USA. Většinu vegetace náhorní plošiny tvoří stepní ekosystém s dominantním pelyňkem a různé druhy trav. Dále jsou zde zastoupeny také holá půda a lávové proudy různého stáří. Vegetační klasifikace byla provedena na základě snímku Landsat 7 ETM+, který byl pořízen 7. 8. 2002. Byly definovány dvě varianty výsledných mapových jednotek, první varianta obsahovala dvě kategorie land cover – pelyněk a travní porosty, druhá varianta pak obsahovala tři třídy – pelyněk, travní porosty a smíšenou kategorii. Za účelem získání tréninkových ploch pro uvedené kategorie land cover byla rovněž v létě 2002 nasbírána terénní data. Každý z daných klasifikačních systémů zahrnoval spektrální pásmo 5 (SWIR), druhou hlavní komponentu analýzy PCA (PC2) a následující vegetační indexy – PVI (perpendicular vegetation index), NDVI (normalized difference vegetation index), SAVI (soil-adjusted vegetation index), tasseled cap greenness a tasseled cap moistness. Celková přesnost řízené klasifikace dosahovala 33,7 % a 47,5 % pro klasifikační model se dvěma resp. třemi třídami land cover, zatímco fuzzy klasifikace byla provedena

s přesností 39,5 % resp. 50,5 %. Zlepšení přesnosti pomocí fuzzy klasifikace ukazuje užitečnost fuzzy logic systémů pro klasifikaci heterogenní vegetace v komplexních ekosystémech. Výsledná klasifikační přesnost je však omezena hrubým prostorovým rozlišením použitých družicových dat, která způsobují vysokou různorodost trénovacích ploch. Multispektrální data s vyšším prostorovým rozlišením by tak měla umožnit sběr trénovacích ploch, které by byly více homogenní a měly by přinést lepší výsledky.

Samotná klasifikace luční vegetace je náročným úkolem, neboť potenciál úspěchu klasifikace satelitního snímku ovlivňuje řada faktorů (Salovaara et al. 2005). Jak již bylo uvedeno v úvodu, stejný typ luční vegetace může mít na družicových snímcích odlišné spektrální vlastnosti a naopak odlišné typy vegetace mohou mít podobné spektrum. Je tedy zřejmé, že existuje mozaika luční vegetace (Cingolani et al. 2004, Stuart et al. 2006). Rozpor nastává vždy, když je klasifikace travních porostů vytvořena pouze z botanického hlediska nebo pouze z hlediska spektrálního. Vzhledem ke složitosti tohoto problému byly vyvinuty různé metody klasifikace lučních porostů z dat DPZ (Langley et al. 2001). Zásadním krokem, který má velký vliv na výsledek a přesnost klasifikace vegetace je rovněž sběr terénních vzorků z různých tříd jako tréninkových a validačních dat. Jedná se o zásadní krok při provádění klasifikace pomocí dat DPZ (Debba et al. 2005). V ideálním případě by se měl sběr terénních dat uskutečnit současně s pořízením snímku z důvodu minimalizace časových rozdílů (Carle et al. 2011).

Rozporem mezi klasifikací z hlediska botanického a spektrálního byla inspirována studie Sha et al. (2008) zaměřená na klasifikaci travních porostů v povodí vodního toku Xilin v oblasti Vnitřního Mongolska v Číně. Povodí řeky Xilin je jednou z nejreprezentativnějších stepních oblastí v Číně. V této studii byly použity dva snímky Landsat ETM+ z 14. 8. 2004 pokrývající zájmové území. Ze snímku byly odstraněny komunikace, obydlená území a oblasti silně postižené desertifikací z důvodu možného vlivu na výsledky klasifikace. Dodatečně byly odstraněny také člověkem obhospodařované oblasti, které nevykazují pro přirozenou vegetaci typické spektrální chování, a mohly by tak rovněž ovlivnit přesnost klasifikace. Speciálně pro klasifikaci travních porostů pomocí snímku Landsat se střední prostorovou rozlišovací schopností byl vyvinut hybridní fuzzy klasifikátor. Na základě různých hledisek byly vytvořeny tři systémy klasifikace vegetace – botanický systém (Bio-třídy), kombinovaný botanický a spektrální systém (Bio-S třídy) a spektrální systém (Spec-třídy). K získání smysluplné vegetace a souboru dat pro zhodnocení přesnosti klasifikace byly nasbírány aktuální terénní vzorky rovnoměrně pokrývající zkoumané území. Z botanického hlediska bylo definováno celkem 11 Bio-tříd. Za předpokladu, že uvnitř každé Bio-třídy

pravděpodobně existuje spektrální variabilita, byla nad souborem Bio-tříd provedena dvoufázová hierarchická shluková analýza s prvními dvěma hlavními komponentami analýzy PCA jako proměnnými. V případě, že spektrální rozdíly uvnitř dané Bio-třídy byly větší než zvolený práh, byla tato Bio-třída rozdělena do několika podtříd. Tímto způsobem bylo vygenerováno 21 Bio-S tříd. S využitím neřízené klasifikace snímku Landsat pak bylo vytvořeno 36 Spec-tříd. Na základě definování fuzzy funkce příslušnosti bylo následně provedeno fuzzy přiřazení 36 Spec-tříd k 21 Bio-S třídám. Na závěr došlo k převedení zpět do Bio-tříd. Celková přesnost hybridní fuzzy klasifikace dosáhla 80,2 % a hodnoty kappa 0,77 v porovnání s konvenční metodou řízené klasifikace maximální věrohodnosti, jejíž přesnost byla 69 % a hodnota kappa 0,63.

Kromě klasifikace samotných lučních společenstev se řada studií zabývá také klasifikací managementových zásahů. Kontrola o provedení konkrétního managementu na lučních porostech totiž často souvisí například s přidělováním dotací. Price et al. (2002) hodnotí několik vegetačních indexů a kombinací spektrálních pásem družicových dat Landsat TM pro optimální rozlišení několika managementových opatření na travních porostech v Douglas County ve státě Kansas, USA. V této studii byly použity tři snímky Landsat 5 TM z 15. 5., 2. 7. a 4. 9. 1997. Travní porosty zájmového území byly rozděleny do 6 kategorií – chladnomilné a teplomilné louky pasené, kosené a chráněné. Pro účely rozlišení daných kategorií luční vegetace byly hodnoceny vegetační indexy – tasseled cap brightness, GVI (green vegetation index), WI (wetness index), první tři hlavní komponenty analýzy hlavních komponent (PCA), NDVI (normalized difference vegetation index), GR (green ratio) a MR (MIR ratio) a pásma TM1 (blue-green), TM2 (green), TM3 (red), TM4 (NIR), TM5 (MIR) a TM7 (MIR). Srovnání bylo provedeno pomocí jednoho, dvou a kombinace všech tří snímků s využitím diskriminační analýzy. Bez ohledu na použité kombinace snímků bylo zjištěno, že pásmo TM4 bylo vždy první nalezenou proměnou pro rozlišení lučních typů. V případě vegetačních indexů dominoval ve všech kombinacích index GVI. Během aktivní části vegetačního období (květen a zejména červenec) jsou pro rozlišení vhodnější vegetační indexy. Naopak kombinace spektrálních pásem a vegetačních indexů nepřináší žádné významné rozlišovací schopnosti. Snímek pořízený v září je nejméně vhodný pro rozlišení, neboť teplomilné a chladnomilné druhy trav vykazují v září podobné spektrální vlastnosti.

Diskriminační analýzu za účelem nalezení optimální kombinace jednotlivých pásem a jejich transformací pro rozlišení dvou lučních typů používají ve své studii také Lauer and Whistler (1993). Ve studii zaměřené na luční porosty v Anderson County ve státě Kansas, USA byl použit snímek Landsat TM ze 7. června 1988. Cílem této studie bylo odlišit kvalitní

kosené travnaté porosty s vysokou druhovou rozmanitostí od pasených travnatých porostů nízké kvality s nízkou druhovou rozmanitostí. Při terénním průzkumu byly zjištěny mezi uvedenými typy porostů rozdíly v pokryvnosti, druhové skladbě a množství rostlinné biomasy, které by mohly pomoci k rozlišení kvalitních trávníků a trávníků s nízkou kvalitou z dat Landsat. Za tímto účelem byly s využitím lineární diskriminační analýzy hodnoceny indexy transformace Tasseled Cap (brightness, greenness, wetness), index NDVI a pásma TM2, TM3, TM4, TM5 a TM7. Z výsledků diskriminační analýzy byly vybrány čtyři kombinace proměnných, ze kterých byly vytvořeny metodou řízené klasifikace maximální věrohodnosti mapy potenciální luční vegetace s přesností od 76,5 do 82,3 %. S cílem eliminovat malé skupiny pixelů s nízkou pravděpodobností zařazení do správné třídy byla následně aplikována technika prahování (threshold). K vytvoření finální mapy kvalitních trávníků byla vybrána kombinace zahrnující pásma TM2, TM4, TM5, TM7 a index NDVI. Přesnost klasifikace se po aplikaci prahování snížila ze 76,7 na 63,4 %, ale zároveň došlo také ke snížení odhadované plochy kvalitních lučních porostů z 16,6 % na požadovaných 8 % zjištěných při terénním průzkumu.

Výše uvedené studie používaly ke klasifikaci přirozené vegetace data Landsat se středním prostorovým rozlišením, která, jak již bylo uvedeno, neumožňují vytvořit klasifikační třídy, které by byly více homogenní (McMahan et al. 2003). Výzvu však přináší využití satelitních dat WorldView-2 s velmi vysokým prostorovým rozlišením. Přestože se jedná o poměrně mladý družicový systém, dosahuje poměrně dobrých výsledků při mapování vegetace na úrovni jednotlivých druhů. Družicová data WorldView-2 navíc disponují spektrálními pásmy, která zvyšují možnosti jejich využití při studiu vegetace (Kanniah 2011).

Možnosti využití družicových dat WorldView-2 pro mapování různých druhů tropických mangrovů v Malajsii zkoumala Kanniah (2011). Zájmové území se nachází v distriktu Kota Tinggi, Johor, Malajsie, kde mangrovový les chráněný od roku 1930 zaujímá plochu kolem 1606 ha. Družicový snímek WorldView-2 pokrývající studované území byl pořízen 14. 9. 2010. Před samotnou klasifikací multispektrálního snímku bylo provedeno jeho zaostření pomocí panchromatických dat s vyšším prostorovým rozlišením. Pro klasifikaci mangrovových lesů s různými druhy byla zvolena technika umělých neuronových sítí. „*Jde o algoritmy, které se snaží napodobit procesy probíhající v nervové soustavě. Jednotlivé neurony jsou vzájemně propojeny do sítě. Neuron jako uzel této sítě může mít obecně několik vstupů, avšak tyto vstupy mohou generovat pouze jeden výstup*“ (Dobrovolný 1998). Neuronové sítě jsou obvykle koncipovány tak, aby byly schopné zlepšit přesnost automatické

klasifikace díky své rozvrstvené struktuře a silné schopnosti řízení výpočtu. Jejich výhodou při klasifikaci různých druhů mangrovů je schopnost učit se jejich spektrální chování z multispektrálních pásem a prostorové změny z panchromatického pásma (Mohanty and Majumdar 1996). Dosažená přesnost klasifikace mangrovových druhů se lišila od různých neuronových modelů s různými nastaveními vnitřních parametrů. Bylo zjištěno, že největší vliv na přesnost klasifikace měly čtyři parametry – počet iterací, rychlost učení, počet skrytých vrstev a střední kvadratická chyba (RMS). V této studii bylo klasifikováno pět dominantních druhů mangrovů nacházejících se na zájmovém území s celkovou přesností 87,53 % a hodnotou kappa 0,85. Pro srovnání byla provedena řízená klasifikace maximální věrohodnosti s dosaženou přesností 84,09 % a hodnotou kappa 0,81. Mezi oběma metodami byl nalezen jen malý rozdíl v přesnosti klasifikace, který by se však mohl zvyšovat s vyšším počtem klasifikovaných tříd (Kanniah 2011).

Užitečnost družicových dat WorldView-2 pro mapování vegetace na úrovni jednotlivých druhů ukazuje také studie, kterou provedla v deltě Wax Lake ve státě Louisiana, USA Carle et al. (2011). Sladkovodní mokřadní vegetace v deltách představuje velmi rozmanitý, prostorově heterogenní a sezóně dynamický systém. Snímek použitý v této studii byl pořízen 15. 6. 2010. Z důvodu ovlivnění výsledků klasifikace byla ze snímku pomocí masky odstraněna silniční síť, zastavěná území a drobná oblačnost. Testována byla metoda řízené klasifikace maximální věrohodnosti a fuzzy klasifikace. Hodnocení přesnosti obou klasifikačních technik bylo provedeno porovnáním náhodného vzorku 742 bodů. Celková přesnost řízené klasifikace na úrovni jednotlivých druhů (13 tříd) byla 62 %, zatímco přesnost fuzzy klasifikace na úrovni druhů byla mnohem vyšší – 74 %. Přesnost klasifikace by se však ještě mohla výrazně zlepšit sběrem terénních referenčních dat současně s pořízením snímku z důvodu minimalizace časových rozdílů. To platí zejména v dynamickém prostředí.

3 Charakteristika zájmového území

3.1 Zájmové území

Krkonoše jsou nejvyšším pohořím České republiky a zároveň místem vzniku prvního národního parku u nás vyhlášeného v roce 1963. Navzdory malé rozloze a nízké nadmořské výšce oplývají mimořádnou pestrostí krajiny, flóry a fauny, která zdaleka převyšuje přírodní rozmanitost okolních evropských hor. Vděčí za to především výjimečné poloze uprostřed Evropy, kde se v minulosti odehrály události formující vývoj středoevropské krajiny (www.krnapp.cz).

Zájmové území se nachází severovýchodně od města Vrchlabí na území Krkonošského národního parku (KRNAP) – viz obrázek č. 1. Rozkládá se na ploše asi 80 km² a zahrnuje nadmořské výšky od 550 do 1420 m. Mezi hlavní typy zemského pokryvu na zájmovém území patří především lesní porosty a luční vegetace. Zájmové území bylo zvoleno tak, aby zahrnovalo cenná smilková společenstva na Zadních Rennerovkách a v okolí Velké Úpy a obhospodařované louky v okolí Dolního Dvora.



Obr. 1 Zájmové území diplomové práce

(Zdroj: <http://geoportal.gov.cz>, úpravy: vlastní, ArcGIS 9.3)

Krkonoše jsou geologicky velmi starým pohořím, avšak jejich geomorfologický vývoj začal až v období třetihor a čtvrtohor. Nejstaršími dochovanými zbytky někdejšího reliéfu jsou rozsáhlé náhorní plošiny v západních a východních Krkonoších. Vlivem alpinského vrásnění ve třetihorách došlo k mohutné říční erozi, vodní toky se začaly zahlubovat a rozčlenily povrch Krkonoš do podoby krkonošských rozsoch a členité sítě hlubokých říčních údolí. V období čtvrtohor došlo během střídání dob ledových a meziledových k přemodelování výše položených partií do podoby ledovcových karů, sněžníků, trogů a ledovcových údolí (www.krnap.cz).

Krkonošské podnebí má výrazně oceánský charakter. Pro počasí v Krkonoších je typické výrazné střídání ročních období a silná proměnlivost v krátkých časových úsecích. Průměrná roční teplota se pohybuje mezi +6 až 0 °C. Nejtepleji je v Krkonoších v červenci a nejméně v lednu. V Krkonoších ročně spadne 800 až 1400 mm srážek. Nejvyšší srážkové úhrny jsou na většině míst v srpnu vlivem západního proudění a četných bouřek (www.krnap.cz).

Nezanedbatelnou složku krkonošské přírody představují luční porosty, z nichž nejcennější jsou tzv. květnaté horské louky. Jedná se o druhově bohaté louky vyskytující se především v montánním a spodním alpinském stupni Krkonoš. Vznikly zejména během období budního hospodářství v 17. až 19. století, kdy docházelo k jejich pravidelnému kosení, pastvě nebo i přihnojování. Z početných archivních zdrojů vyplývá, že již v polovině 17. a na počátku 18. století byly po celých Krkonoších rozptýleny letní i celoročně využívané horské boudy se značným množstvím chovaného hovězího dobytka, koz i koní. Na přelomu 18. a 19. století údajně existovalo na maršovském panství 996 bud, 309 bud na vrchlabském panství a 316 na jilemnickém panství. Společně s územím Žacléřska a s boudami na slezské straně bylo na území Krkonoš rozptýleno téměř 2500 horských bud. Zbytky květnatých luk lze dnes nalézt například na enklávách Severky, Zadních Rennerovek, v Modrém a Obřím dole, na Rýchorách či ve Svatém Petru. Tyto polokulturní porosty jsou existenčně závislé na pravidelném odstraňování nadzemní biomasy. Pokud by k tomu nedocházelo po delší dobu, došlo by k poměrně rychlé přeměně v les. Luční společenstva však obvykle vykazují daleko větší biodiverzitu než většina lesních porostů. Jejich druhové složení závisí především na nadmořské výšce, množství živin a vlhkosti stanoviště (Krahulec et al. 1996, www.krnap.cz).

3.2 Hlavní typy krkonošských lučních stanovišť

Běžně po celých Krkonoších, zvláště pak v západních a jihozápadních Krkonoších, v nadmořských výškách od 450 do 1000 m na půdách s hlubokým humózním horizontem se vyskytují horské trojštětové louky s kakostem lesním (*Geranio sylvatici-Trisetetum flavescens*) patřící do svazu horských trojštětových luk (*Polygono bistortae-Trisetion flavescens*). Jedná se o středně vzrůstavé horské louky s dominantní kostřavou červenou, psinečkem obecným a v menší míře s trojštětem žlutavým, kakostem lesním a srhou říznačkou. Dále jsou přítomny také druhy horských luk (rdesno hadí kořen, škarda měkká, řeřišničník Hallerův a zvonečník klasnatý) a luční druhy (kontryhel, rozrazil rezekvítek, pryskyřník prudký nebo řebříček obecný). Ostatní rostlinný kryt je velice různorodý v závislosti na stanovišti a typu obhospodařování. V dolní části výškové distribuce (500-700 m n. m.) se trojštětové louky s kakostem lesním prolínají s kostřavovo-trojštětovými loukami, na horní hranici pak sousedí s horskými knotovkovými loukami nebo s horskými smilkovými trávníky. Vyžadují kosení jednou až dvakrát ročně a extenzivní přihnojování.



Obr. 2 Horská trojštětová louka v srpnu 2011 na lokalitě Výsluní

(Zdroj: vlastní)

Roztroušeně především ve východních Krkonoších lze nalézt horské knotovkové louky (*Melandrio rubri-Phleetum alpini*) patřící rovněž mezi horské trojštětové louky. Jedná se o endemické společenstvo, neboť se mimo Krkonoše nikde jinde nevyskytuje. Středně vzrůstavé, mezofilní, vlhké louky jsou rozšířeny v nadmořských výškách 850 až 1300 m na plochých či mírně ukloněných polohách nižších hřebenových partií a přilehlých svazích s hnědozemními až podzolovými půdami. Mezi dominantní druhy patří psineček obecný, kostřava červená, kontryhel lesní a mochna zlatá. Vyskytují se zde také luční druhy (jako řebříček obecný, třezalka skvrnitá a pryskyřník prudký), druhy horských luk (zvonek český, bojínka švýcarská, lipnice Chaixova, rdesno hadí kořen a silenka nadmutá), častá je vlhkomilná metlice trsnatá a produkční travina psárka luční. Na dolní hranici výškového rozšíření sousedí horské knotovkové louky s horskými trojštětovými loukami s kakostem lesním, na horní hranici výškového rozšíření pak sousedí se subalpínskými smilkovými trávníky. Často tvoří mozaiku s vlhkými loukami řádu *Molinietalia* a subalpínskými smilkovými trávníky. Ke kosení dochází jednou až dvakrát ročně. Kromě toho se provádí také vápnění, hnojení a odstraňuje se šťovík alpský. V západních Krkonoších se lze setkat s variantou horských knotovkových luk s koprníkem štětínolistým a svízelem hercynským označovaných jako horské koprníkové louky (*Meo athamantici-Festucetum*).

Další endemické společenstvo nacházející se pouze v Krkonoších představují druhově bohaté horské smilkové trávníky (*Sileno vulgaris-Nardetum*) ze svazu horských smilkových trávníků s alpínskými druhy (*Nardo strictae-Agrostion*). Dominantními travami bývají smilka tuhá, psineček obecný, kostřava červená, metlička křivolaká a tomka vonná. Hojně se vyskytují také mezofilní luční druhy jako řebříček obecný, jitrocel kopinatý, rozrazil rezevítka, kontryhel, pampeliška podzimní, bika ladní, pryskyřník prudký, dále oligotrofní druhy smilkových trávníků jako rozrazil lékařský, jestřábník hladký, ostřice kulkonosná, mochna nátržník a druhy horských luk jako kakost lesní, zvonečník klasnatý, řeřišníkovec Hallerův, rdesno hadí kořen a škarďa měkká. Nepatrně pak bývají zastoupeny produkční traviny srha říznačka a ovsík vyvýšený. Druhově bohaté smilkové trávníky se vyskytují roztroušeně po celém území Krkonoš s těžištěm ve východní části v nadmořských výškách 700 až 1100 m. Typické jsou pro ně horní části svahů nebo konvexní tvary reliéfu. Na dolní hranici vertikální distribuce sousedí s horskými trojštětovými loukami s kakostem lesním, na horní hranici se subalpínskými smilkovými trávníky. Tvoří mozaiku s horskými knotovkovými loukami i se subalpínskými smilkovými trávníky. Kosení se provádí jednou, výjimečně dvakrát ročně, případně dochází k letnímu nebo podzimnímu přepásání. Jde o společenstvo velmi náchylné ke změnám.



Obr. 3 Druhově bohatá smilková louka v srpnu 2011 na lokalitě Výsluní

(Zdroj: vlastní)

Na živinami obohacovaných částech lučních enkláv v oblasti kolem horní hranice lesa nebo na mělkých terénních sníženinách v nadmořských výškách 1000 až 1300 m se vyskytují druhově bohaté subalpínské smilkové trávníky (*Thesio alpini-Nardetum strictae*) patřící do svazu subalpínských smilkových trávníků (*Nardion*). Jsou rozšířeny především na lokalitách Zadní Rennerovky, Richterovy Boudy, Modrý Důl a Liščí louka u Pece pod Sněžkou, Dvoračky a Hájenka u Rokytnice nad Jizerou. Druhově bohatým porostům nízkých trav dominuje smilka tuhá nebo metlička křivolaká. Lze nalézt i další nízkostébelné trávy psineček obecný, kostřava obecná a tomka alpská. Hojně jsou také druhy horských luk, jako zvonečník klasnatý, mochna zlatá, zvonek český, violka sudetská, lipnice Chaixova, škarda velkoúborná a rdesno hadí kořen. Druhově bohaté subalpínské smilkové trávníky tvoří obvykle mozaiku s druhově chudými subalpínskými smilkovými trávníky a horskými knotovkovými loukami. Vyžadují kosení jednou ročně a extenzivní přihnojování.

Kromě druhově bohatých subalpínských smilkových trávníků jsou ze svazu *Nardion* v Krkonoších rozšířeny také druhově chudé subalpínské smilkové trávníky (*Solidagini-Nardetum*). Vyskytují se na živiny chudých stanovištích při horní hranici lesa v nadmořských

výškách 950 až 1400 m. Lze je nalézt v oblasti Zadních Rennerovek, Richterových Bud, Liščí louky, Rýchor, Dvořáček a Hájenky u Rokytnice nad Jizerou. Jedná se o druhově chudé porosty nízkých trav s dominantní smilkou tuhou nebo metličkou křivolakou s konstantní přítomností tomky alpské. Běžné jsou dále druhy nejvyšších obhospodařovaných poloh jako podbělice alpská, bika sudetská nebo hořec tolitovitý. Na dolní hranici výškové distribuce sousedí společenstva chudých subalpínských smilkových trávníků s horskými knotovkovými a kakostovými loukami a s druhově bohatými horskými smilkovými trávníky, na horní hranici výškové distribuce pak sousedí se zapojenými alpínskými trávníky se smilkou tuhou. Porosty jsou obvykle extenzivně koseny nebo paseny.

Na stanovištích s nedostatečným zásobením živinami a malou produktivitou v nadmořských výškách 600 až 800 m se vyskytují mezofilní a suché podhorské a horské smilkové trávníky (*Festuco capillatae-Nardetum strictae* a *Campanulo rotundifoliae-Dianthetum deltoidis*) patřící do svazu podhorských a horských smilkových trávníků (*Violion caninae*). Těžiště výskytu tohoto společenstva v Krkonoších se nachází v oblasti Horního Maršova. Krátkostébelným oligotrofním porostům dominuje smilka tuhá nebo kostřava červená. Přítomny bývají trávy psineček obecný a tomka vonná. Běžné jsou také oligotrofní druhy jako mochna nátržník, ostřice kulkonosná, rozrazil lékařský, jestřábník chlupáček a některé druhy mezofilních luk jako bika ladní, třezalka skvrnitá, pryskyřník prudký, jitrocel kopinatý nebo třeslice prostřední. Z managementu se provádí pastva či kosení a extenzivní přihnojování.

Na území Krkonoš se nacházejí také společenstva svazu mezofilních ovsíkových a kostřavových luk (*Arrhenatherion elatioris*), avšak jen roztroušeně. První z nich, suché ovsíkové louky (*Ranunculo bulbosi-Arrhenatheretum elatioris*), lze nalézt pouze v okolí Poniklé a Horních Albeřic, zbytky porostů pak u Horního Maršova a Hřiběcích Bud. Typická jsou pro ně slunná stanoviště a půda bohatá na báze s krystalickým podložím vápenců v nadmořských výškách 700 až 800 m. Dominantními druhy bývají u těchto mezofilních až xerofilních luk srha říznačka a středně vysoké trávy kostřava červená, lipnice luční, tomka vonná, ovsík vyvýšený a trojštět žlutavý. Často jsou zastoupeny i luční byliny štírovník růžkatý, tollice dětelová, svízel povázka a rožec rolní. Jde o nejvíce teplomilné společenstvo zastoupené v Krkonoších. Mimo vápencové podloží přechází v podhorské kostřavové nebo horské trojštětové louky s kakostem lesním. Kosí se jednou do roka a extenzivně přihnojují.

Další společenstvo svazu *Arrhenatherion elatioris*, produkční podhorské kostřavovo-trojštětové louky (*Poo-Trisetetum*), představuje hlavní typ produkčních květnatých luk v Krkonoších. Nacházejí se roztroušeně převážně na jihozápadě Krkonoš, maloplošně pak

převážně v západních Krkonoších. Vyskytují se v nadmořských výškách od 600 do 700 m na hlinité až jílovito-hlinité hnědozemi s nepříliš humózním horizontem. Společenstvu dominují středně vysoké trávy (kostřava červená, ovsík vyvýšený, psineček obecný) a druhy náročnější na živiny (jako srha říznačka a psárka luční, lipnice obecná a trojštět žlutavý). Častými druhy jsou také luční byliny jako jetel plazivý, kopretina luční, pryskyřník prudký, řebříček obecný a pampeliška podzimní. Vyžadují kosení dvakrát ročně a přihnojování minerálními i organickými hnojivy.

V západních Krkonoších se lze setkat také s neprodukčními podhorskými kostřavovo-trojštětovými loukami (*Trifolio-Festucetum rubrae*) svazu *Arrhenatherion elatioris*. Vyskytují se na slunných stanovištích na půdách se svorovým podložím v nadmořských výškách 550 až 800 m. Dominantními druhy jsou vysoké trávy jako kostřava červená, psineček obecný a tomka vonná. Časté jsou také luční byliny (jako třezalka skvrnitá, rozrazil rezevíték a řebříček obecný), oligotrofní druhy (jako smilka tuhá, jestřábník chlupáček nebo violka psí) a méně náročné xerofyty teplomilných širokolistých trávníků (pupava bezlodyžná, mateřídouška vejčitá a hvozdík kropenatý). Kosení se provádí obvykle jednou ročně a místo druhé sklizně jsou louky často přepásány. (Chytrý et al. 2007)

4 Data a metodika

4.1 Použitá data

4.1.1 Družicová data WorldView-2

V diplomové práci byly využity družicové snímky WorldView-2 pořízené 22. 8. 2011 a 24. 9. 2011 pokrývající zájmové území stanovené botanikem KRNAP s ohledem na rozšíření cenných lučních ekosystémů. Snímek ze srpnového termínu byl ze značné části pokrytý oparem, proto dodavatel poskytl ještě snímek ze září téhož roku, který již nebyl tímto jevem postižen. Při klasifikaci lučních společenstev se vycházelo především ze zářijového snímku, kde mohlo být využito celé zájmové území. Avšak pozemní data pořízená v srpnu již úplně neodpovídala situaci na lučních enklávách v září, kdy řada luk již byla posekána, spasena či mulčována.

Družice WorldView-2, kterou provozuje americká společnost DigitalGlobe (družice QuickBird), byla vypuštěna 8. 10. 2009 a je první komerční družicí poskytující multispektrální snímky s velmi vysokým prostorovým rozlišením (1,84 m) pořízené v osmi spektrálních pásmech a panchromatické snímky s prostorovým rozlišením 0,5 m. Kromě čtyř tradičních pásem (blue, green, red a near-infrared) nabízí čtyři nová pásma (coastal blue, yellow, red-edge a near-infrared 2) výrazně zvyšující informační obsah a možnosti využití těchto dat především pro potřeby vegetačních analýz, batymetrických měření a objektově orientované klasifikace:

Coastal Blue (400 – 450 nm)

- Nové pásmo
- Absorbováno chlorofylem ve zdravých rostlinách, pomáhá při provádění vegetačních analýz
- Nejméně absorbováno vodou, velmi užitečné při batymetrických studiích
- Značně ovlivněno rozptylem v atmosféře, má potenciál ke zlepšení techniky atmosférické korekce

Blue (450 – 510 nm)

- Totožné s pásmem družice QuickBird
- Absorbováno chlorofylem v rostlinách
- Ve srovnání s pásmem Coastal Blue méně ovlivněno rozptylem a absorpcí v atmosféře

Green (510 – 580 nm)

- Užší než zelené pásmo družice QuickBird
- Ve spojení se žlutým pásmem velmi užitečné při rozlišování mezi rostlinnými typy

Yellow (585 – 625 nm)

- Nové pásmo
- Důležité pro objektově orientovanou klasifikaci
- Vhodné k identifikaci charakteristiky „yellowness“ u vegetace, a to jak na zemi, tak i ve vodě

Red (630 – 690 nm)

- Užší než červené pásmo družice QuickBird, přesunuto na delší vlnové délky
- Lépe zaměřené na absorpci červeného světla chlorofylem u zdravých rostlin
- Jedno z nejdůležitějších pásem pro rozlišení vegetace
- Velmi užitečné pro klasifikaci holé půdy, silnic a geologických prvků

Red-Edge (705 – 745 nm)

- Nové pásmo
- Velmi užitečné pro analýzu zdravotního stavu rostlin, pomáhá při klasifikaci vegetace

NIR1 (770 – 895 nm)

- Užší než pásmo NIR1 družice QuickBird z důvodu lepšího oddělení od senzoru Red-Edge
- Velmi efektivní pro stanovení obsahu vlhkosti a rostlinné biomasy
- Efektivně odděluje vodní plochy od vegetace, identifikuje typy vegetace a rozlišuje mezi půdními typy

NIR2 (860 – 1040 nm)

- Nové pásmo
- Překrývá se s pásmem NIR1, ale je méně ovlivňován atmosférou
- Umožňuje vegetační analýzy a studie biomasy (www.digitalglobe.com, www.gisat.cz).

WorldView-2 je prvním multispektrálním satelitem s velmi vysokým rozlišením obsahujícím Red-Edge senzor pro provádění vegetačních analýz, které mohou odhalit typ, stáří, zdravotní stav a rozmanitost vegetace v neočekávaných detailech. Pásmo Red-Edge poskytuje dostatečnou citlivost k rozlišení mladé vs. zralé, jehličnaté vs. listnaté vegetace a dokonce detekuje nepatrné změny ve zdravotním stavu rostlin ještě předtím, než jsou viditelné. Oblast Red-Edge byla objevena právě s rozvojem hyperspektrálních senzorů, které mohou měřit

desítky až stovky spektrálních pásem. Jedná se o část spektra mezi 680 až 750 nm, kde dochází k prudkému nárůstu odrazivosti vegetace (www.digitalglobe.com).

4.1.2 Družicová data Quickbird

Jedním z cílů diplomové práce byla také klasifikace lučních společenstev z dat Quickbird za účelem zjištění, zda nová pásma přidaná v datech WorldView-2 přispějí ke zvýšení přesnosti klasifikace. Dostupná data Quickbird nebylo možné ortorektifikovat s takovou přesností, aby mohla být využita nasbíraná terénní data k natrénování jednotlivých tříd. Proto byla provedena klasifikace luční vegetace alespoň na základě simulace dat Quickbird pomocí dat WorldView-2. Simulovaná data Quickbird byla vytvořena na základě pásem shodných s pásmy dat WorldView-2 (blue, green, red, NIR1). Rozsah a vlnové délky daných pásem dat Quickbird a WorldView-2 nejsou zcela totožné, ale rozdíly mezi nimi jsou malé. Prostorové rozlišení také není zcela stejné, ale je velmi podobné (rozdíl 0,1 m u zaostřených dat).

4.1.3 Terénní data

Pro klasifikaci lučních společenstev je velmi důležitý sběr terénních vzorků z jednotlivých tříd, které slouží jako trénovací data. Jedná se o zásadní krok při provádění klasifikace pomocí dat DPZ (Debba et al. 2005). V ideálním případě by se měl sběr terénních dat uskutečnit současně s pořízením snímku z důvodu minimalizace časových rozdílů (Carle et al. 2011).

Družicový snímek WorldView-2 pro účely této diplomové práce byl pořízen 22. 8. 2011. Sběr terénních dat se uskutečnil za účasti botanika s minimálním odstupem od pořízení snímku ve dnech 26. a 27. 8. 2011. Celkem bylo nasbíráno 65 terénních vzorků reprezentujících jednotlivá luční společenstva (seznam viz příloha č. 1). U každého vzorku byly určeny jeho souřadnice pomocí přístroje GPS Trimble Geoexplorer 3000 Geo XT (měřeny uprostřed polygonu daného lučního společenstva, přesnost do 1 m). Dále botanik stanovil druhové zastoupení, pokryvnost, průměrnou výšku společenstva a případně typ managementu (pastva, kosení, mulč).

Družicový snímek ze srpna je však v západní části zájmového území značně pokryt oparem (haze). Právě na postiženém území se nachází cenná luční společenstva v oblasti Rennerovek a Klínových bud. Proto dodavatel poskytl ještě snímek pořízený 24. 9. 2011.

Pro účely klasifikace lučních porostů byla použita terénní data ze srpna jak pro srpnový snímek, tak i pro zářijový. Stav lučních porostů v období mezi pořízením obou snímků se do určité míry změnil, zejména v tom, že byla část lučních porostů pokosena. Tím byly ovlivněny i výsledky klasifikace. V rámci diplomové práce nebylo provedeno odstranění haze, to přesahovalo její cíle a možnosti.

4.1.4 Ostatní zdroje dat

V diplomové práci byla dále použita data ZABAGED zapůjčená Zeměměřickým úřadem (ZÚ). Výškopisná složka dat byla využita pro vytvoření digitálního elevačního modelu (DEM) pro potřeby ortorektifikace družicových snímků WorldView-2. Polohopisná složka dat ZABAGED, zejména vektorové vrstvy cest a budov, sloužila k posouzení přesnosti ortorektifikace. Data ZABAGED byla použita také k vytvoření topografického podkladu výsledných map klasifikace lučních společenstev.

Za účelem porovnání vhodnosti legendy stanovené botanikem KRNAP a legendy Natura 2000 pro klasifikaci lučních společenstev v Krkonoších byla použita Vrstva mapování biotopů poskytnutá Agenturou ochrany přírody a krajiny České republiky (AOPK ČR). Jedná se o výstup z mapování biotopů České republiky pro potřeby vymezení soustavy chráněných území Natura 2000.

4.2 Předzpracování družicových dat

4.2.1 Ortorektifikace

Při pořizování obrazových záznamů zemského povrchu vzniká řada nepřesností, které ovlivňují jejich kvalitu. Aby bylo možné data dálkového průzkumu Země dále využívat je potřeba provést úpravy ve smyslu radiometrických a geometrických vlastností (Dobrovolný 1998).

Družicová data WorldView-2, použitá v této práci, byla dodána poskytovatelem v úrovni Ortho Ready Standard (OR2A), která jsou již radiometricky i geometricky upravena. Snímek je zasazen do systému UTM/WGS-84 s polohovou přesností 5 m. U produktu Ortho Ready Standard se však neprovádí korekce na topografický reliéf, data jsou vytvořena pouze projekcí na průměrnou výšku vypočítanou z DEM (www.digitalglobe.com). Proto je potřeba data před dalším zpracováním nejprve ortorektifikovat.

Dobrovolný (1998) definuje ortorektifikaci jako proces, během něhož jsou odstraněny nepřesnosti vznikající v důsledku relativní změny polohy objektů plynoucí z jejich rozdílné nadmořské výšky. K ortorektifikaci je potřeba digitální elevační model (DEM) a je nutné ji provádět zejména pro družicové snímky zachycující vertikálně členitý reliéf a dále pro mapy velkých měřítek. Ortorektifikaci pak vznikají ortofotomapy či družicové mapy.

V současnosti jsou nejvíce využívány dva odlišné přístupy k ortorektifikaci družicových dat. První přístup založený na orbitálním družicovém modelu vyžaduje znalost parametrů oběžné dráhy družice a technických parametrů družicového skeneru. Tyto údaje jsou obvykle dodávány společně s družicovými daty. K odladění přesnosti vlastního ortorektifikačního modelu je třeba následně použít také sestavu vlíčovacích bodů (GPC – Ground Control Points). S rozvojem družicových dat s velmi vysokým rozlišením vznikl druhý přístup založený na využití racionálních polynomických funkcí. Jedná se o metodu, kdy je orbitální družicový model aproximován pomocí vícerozměrných polynomických funkcí. Koeficienty racionálních funkcí (RPC – Rational Polynomial Coefficients) jsou opět dodávány společně s družicovým snímkem (www.gisat.cz). Tento přístup umožňuje ortorektifikovat družicový snímek i bez použití vlíčovacích bodů (www.pcigeomatics.com). K ortorektifikaci snímku WorldView-2 byl zvolen právě přístup využívající racionální polynomické funkce, neboť součástí získaných družicových dat byl také soubor s obsahující RPC koeficienty. V případě dat WorldView-2 se jedná o soubor ve formátu .rpb.

Oba snímky WorldView-2, panchromatický a multispektrální, v úrovni Ortho Ready Standard jsou převzorkovány přesně na sebe. Proto se doporučuje před samotnou ortorektifikací provést zaostření multispektrálního snímku s nižším prostorovým rozlišením snímkem panchromatickým s vyšším prostorovým rozlišením (www.pcigeomatics.com). Pokud se pansharpening provede až po té, kdy jsou oba snímky ortorektifikovány každý zvlášť, výsledný zaostřený snímek je rozastrovaný. Po zaostření multispektrálního snímku např. v modulu Focus softwaru PCI Geomatica se už ale nevygeneruje soubor obsahující RPC koeficienty potřebné k následné ortorektifikaci. Tento problém řeší funkce *Merge/Pansharp Multispectral Image* zabudovaná přímo v modulu Orthoengine v softwaru PCI Geomatica od verze 10.2, která současně se zaostřeným snímkem vygeneruje i soubor obsahující RPC koeficienty. Z tohoto důvodu byla pořízena 15-ti denní zkušební verze softwaru PCI Geomatica 2012, která rovněž zahrnuje uvedenou funkci. Po provedení zaostření multispektrálního snímku v modulu Orthoengine je již možné snímek ortorektifikovat s využitím racionální funkce. K tomuto účelu slouží v modulu Orthoengine nástroj Rational Function (Extract from image).

Digitální elevační model (DEM) potřebný k ortorektifikaci družicového snímku lze vygenerovat přímo v modulu Orthoengine, k čemuž slouží funkce Import DEM. Elevační model může být vytvořen z několika různých zdrojů. V tomto případě byl DEM vygenerován na základě vektorové vrstvy vrstevnic ZABAGED s intervalem 2 m ve formátu shapefile. Vytvořený DEM se však nepřekrýval se zaostřeným multispektrálním snímkem, přestože s původním multispektrálním a panchromatickým snímkem překryv vznikl. Ortorektifikaci tedy nebylo možné dokončit. Po načtení jednotlivých snímků do softwaru ArcGIS bylo zjištěno, že zatímco zaostřený snímek vytvořený v modulu Focus se překrýval s původním multispektrálním a panchromatickým snímkem, multispektrální snímek zaostřený v modulu Orthoengine nikoliv.


Ortorektifikaci prostřednictvím koeficientů racionální funkce lze provést rovněž v softwaru ENVI, kde je k dispozici ortorektifikace přímo pro senzor WorldView (*Map/Orthorectification/WorldView/Orthorectify WorldView*). Výhodou ortorektifikace v ENVI je, že soubor obsahující RPC koeficienty lze zvolit zvlášť, nemusí být tedy doprovodným souborem družicového snímku, jako je tomu v případě softwaru PCI Geomatica. Díky tomu mohl být k ortorektifikaci využit multispektrální snímek zaostřený v modulu Focus, který se překrýval s daným elevačním modelem. Jako soubor zahrnující RPC koeficienty pak byl zvolen soubor ve formátu .rpb vygenerovaný společně se zaostřeným snímkem v modulu Orthoengine.

Digitální elevační model pro potřeby ortorektifikace v softwaru ENVI musí být v rastrovém formátu. Z tohoto důvodu byl na základě vektorové vrstvy vrstevnic vytvořen DEM v softwaru ArcGIS prostřednictvím nástroje *Topo To Raster* a převeden do formátu TIFF. Dále bylo nutné zadat hodnotu Geoid offset, která představuje rozdíl mezi střední hladinou moře, používanou u většiny DEM, a povrchem geoidu. RPC koeficienty jsou totiž vytvořeny na základě výšky geoidu, takže hodnota Geoid offset musí být uvedena z důvodu přesné ortorektifikace. Tuto hodnotu lze vypočítat pomocí kalkulátorů poskytovaných řadou odborných institucí zabývajících se fotogrammetrickým výzkumem. Hodnota Geoid offset pro zájmové území této studie byla vypočítána pomocí Geoid Height Calculator poskytovaným organizací UNAVCO, zaměřenou na výzkum a vzdělávání v oblasti geodézie, na webové adrese http://www.unavco.org/community_science/science-support/geoid/geoid.html. Pro výpočet hodnoty Geoid offset je třeba zadat zeměpisnou šířku, zeměpisnou délku a výšku zvoleného bodu. Zvolen byl bod nacházející se zhruba ve středu zájmového území. Hodnota Geoid offset pak byla vypočtena na cca +43 m.

Následně byla zvolena mapová projekce. Jelikož mezi nabízenými projekcemi není S-JTSK, byla vybrána mapová projekce UTM/WGS-84 Zone 33N. Z tohoto důvodu bylo třeba transformovat elevační model ze souřadnicového systému S-JTSK do UTM/WGS-84. Transformace byla provedena v softwaru ArcGIS s využitím funkce *Project Raster*. Polohová chyba nepřesahuje polohovou přesnost dat ZABAGED (budovy, silnice, ulice do 5 m). Výsledek ortorektifikace a původní vstupní snímek v porovnání s vybranými daty ZABAGED jsou znázorněny níže.



Obr. 4 Výřez snímku před ortorektifikací
(Zdroj: vlastní, ArcGIS 9.3)



Obr. 5 Výřez ortorektifikovaného snímku
(Zdroj: vlastní, ArcGIS 9.3)

Software ENVI nabízí také možnost ortorektifikace pomocí RPC koeficientů a GCP bodů současně (*Map/Orthorectification/Generic RPC and RSM/Orthorectify using RPC or RSM with Ground Control*). Výsledek této ortorektifikace však při porovnání s daty ZABAGED dosahoval větší polohové chyby než v případě ortorektifikace založené pouze na racionální funkci, což je způsobeno nedostatkem vhodných vlíčovacích bodů. Jedná se o členité horské území a především ve vysokých nadmořských výškách se kromě průsečíků horských pěšin a cest nevyskytují jiné využitelné vlíčovací body.


4.2.2 Maska travních porostů

Před samotnou klasifikací jednotlivých lučních kategorií bylo třeba vytvořit masku travních porostů z důvodu vyloučení vlivu ostatních druhů povrchů na přesnost klasifikace. Bylo třeba odmaskovat především lesní porosty, budovy, silnice, oblačnost nebo stíny. Software ENVI umožňuje tvorbu masky pomocí funkce *Built Mask (Basic Tools/Masking/Built Mask)*. Masku lze vytvořit například na základě vektorové vrstvy (*Options/Import EVFs*) či zadáním hraničních hodnot pixelu u rastrových formátů (*Options/Import Data Range*). Výsledný rastr obsahuje pouze hodnoty 0 a 1, hodnoty 1 odpovídají masce vybraného území, hodnoty 0 pak jejímu okolí.

K vytvoření prvotní hrubé masky lučních společenstev byly použity vektorové vrstvy trvalých travních porostů a budov z databáze ZABAGED poskytnuté na základě žádosti ZÚ pro zvolené zájmové území. Vektorové vrstvy bylo třeba ještě před vytvořením masky transformovat ze souřadnicového systému S-JTSK do systému UTM/WGS-84 Zone 33N, ve kterém jsou družicové snímky WorldView-2. Transformace mezi souřadnicovými systémy byla provedena v softwaru ArcGIS pomocí funkce *Project*. V případě potřeby byly vektorové vrstvy ještě editovány (doplněny chybějící plochy s lučními porosty). Na základě takto upravených vrstev pak byly v softwaru ENVI vytvořeny dvě samostatné masky travních porostů a budov. V dalším kroku byla vytvořena inverzní maska budov tak, že budovám byla přiřazena hodnota 0 a okolí hodnota 1. Pomocí funkce *Band Math* byly obě masky vynásobeny a tím vznikla hrubá maska travních porostů, ze které byly odstraněny budovy často vykazující podobné vlastnosti jako luční porosty. Nad touto hrubou maskou byla následně provedena rovněž v softwaru ENVI neřízená klasifikace metodou K-Means (*Classification/Unsupervised/K-Means*). Počet tříd byl nastaven na hodnotu 10, ostatní parametry byly ponechány. Výsledná maska travních porostů pak vznikla pouze

z vyklasifikovaných tříd reprezentujících luční porosty. Třída zahrnující převážně stromy a stíny nebyla do masky zahrnuta. Tento postup byl zvolen proto, aby byla odstraněna zejména lesní půda v řídkých lesních porostech a také lesní porosty, které jinak byly často bez použití vrstvy trvalých travních porostů jako hrubé masky klasifikovány rovněž jako luční vegetace. Přesto se nepodařilo úplně odstranit všechny nežádoucí druhy povrchů, neboť zejména cesty a stromy často vykazovaly podobné spektrální vlastnosti jako travní porosty. Masky byla na závěr ještě částečně ručně upravena. Ideální by bylo vytvořit masku lučních porostů manuální vektorizací, což by bylo ovšem časově značně náročné.

Pro oba družicové snímky WorldView-2 použité v této diplomové práci nebylo možné využít jednu totožnou masku, neboť snímek ze září byl postižen jevem haze. Z hrubé masky travních porostů tak musely být odstraněny oparem pokryté oblasti. Rovněž neřízená klasifikace pro oba snímky byla provedena zvlášť, neboť také stíny a oblačnost jsou na obou snímcích odlišné.



Obr. 6 Výsledná maska lučních porostů pro zářijový snímek
(Zdroj: vlastní, ENVI 4.7)

4.3 Legenda luční vegetace

4.3.1 Legenda stanovená botanikem

Klasifikace lučních společenstev v této práci vychází primárně z legendy sestavené botanikem Krkonošského národního parku. Legenda by měla vystihovat variabilitu travních porostů v Krkonoších. Kromě zřejmě nejrozšířenějších smilkových trávníků a trojštětových luk jsou zastoupeny i další typy ne už tak častých společenstev. Zahrnuta jsou také managementová opatření nejčastěji prováděná na horských loukách. Legenda respektuje čistě botanické hledisko, protože práce chtěla reagovat zejména na praktické požadavky botaniků národního parku a cílem bylo zjistit, zda lze tyto kategorie z družicových dat vyklasifikovat. Zahrnuje celkem 8 hlavních kategorií lučních společenstev:

1. Posečené louky
 - jakékoliv čerstvě posečené porosty
2. Spasené louky
 - jakékoliv spasené porosty
3. Louky s dominantní smilkou tuhou (*Nardus stricta*)
 - 3.1 *Violion caninae* – nízké, chudší pastvou narušované extenzivní pastviny v podhorských polohách nebo porosty s přítomností druhů jako violka psí (*Viola canina*) nebo vítod obecný (*Polygala vulgaris*)
 - 3.2 *Sileno vulgaris-Nardetum* – majoritní typ luk vyššího montánního stupně; v typické formě květnaté a obsahující druhy vysokostébelných niv; často také obsahují jak submontánní, tak i subalpínské elementy; degradovanější porosty se projevují značnou pokryvností brusnice borůvky (*Vaccinium myrtillus*) a rdesna hadí kořen (*Bistorta major*)
 - 3.3 *Thesio alpini-Nardetum strictae* /*Solidagini-Nardetum* – společenstva primárně (sub)alpínského bezlesí; sekundárně rozšířená na nejvýše položené luční enklávy; nejvzácnější a ochránářsky nejcennější typ krkonošských luk; význačná je vysoká frekvence endemických nebo vzácných druhů jako kokrhel sličný (*Rhinanthus pulcher*) nebo violka sudetská (*Viola sudetica*)

4. Degradované louky

4.1 *Rumex alpinus* – velmi často monodominantní, husté porosty v nitrofilním okolí bud a při tocích odvodňovacích struh nebo potůčků; ochranný nejmeně žádaný a často likvidovaný typ vegetace

4.2 Porosty s dominantní kýchavicí bílou (*Veratrum album*) a starčkem Fuchsův (*Senecio ovatus*) – většinou jde o degradační stadia horských luk, převážně *Sileno vulgaris*-*Nardet*; expanzivní druhy pokrývají více jak polovinu plochy důsledkem dlouhodobého nesečení

4.3 Pasekovitá vegetace a iniciální sukcese lesa s dominantní třtinou chloupkatou (*Calamagrostis villosa*), brusnicí borůvkou (*Vaccinium myrtillus*) a metličkou křivolakou (*Avenella flexuosa*) – již velmi dlouho nesečené louky s počínající sukcesí lesa

4.4 *Deschampsion cespitosae* – dlouho nesečené vlhké louky s dominantní metlicí trsnatou (*Deschampsia cespitosa*) a nízkou druhovou diverzitou

5. Louky s dominantními brusnicovitými keříčky a vřesem

5.1 *Violion caninae* – submontánní, sekundární, rozvolněná vřesoviště s pastvinovým charakterem nebo sešlapávaná; často na extenzivních okrajích sjezdovek nebo lesních cestách; přítomny druhy jako vítod obecný (*Polygala vulgaris*) nebo trojzubec poléhavý (*Danthonia decumbens*)

5.2 *Arnico-Callunetum* – kamenitá kyselá stanoviště v montánních a alpinských polohách; převažují druhy brusnicovitých keříčků – brusnice brusinka (*Vaccinium vitis-idaea*), brusnice borůvka (*Vaccinium myrtillus*); místy spíše slabší populace arniky horské (*Arnica montana*)

6. Louky s dominantním trojštětem žlutavým (*Trisetum flavescens*), srhou říznačkou (*Dactylis glomerata*) nebo psárkou luční (*Alopecurus pratensis*)

6.1 Přejít trojštětových a ovsíkových luk – vysoké, travní porosty v submontánních polohách sečené několikrát ročně; zahrnují druhy submontánních a nížinných druhů; dominuje především trojštět žlutavý (*Trisetum flavescens*), srha říznačka (*Dactylis glomerata*), ovsík vyvýšený (*Arrhenatherum elatior*)

6.2 Trojštětové louky (*Polygono bistortae-Trisetion flavescens*) – vysoké, produkční louky v montánních a výjimečně subalpínských polohách s dominantním trojštětem žlutavým (*Trisetum flavescens*) a kostřavou

červenou (*Festuca rubra*); často s vysokým podílem širokolistých bylin jako kakost lesní (*Geranium sylvaticum*)

6.3 Travní kultury a zachovalé ovsíkové louky – převážně antropogenní porosty v nejnižších úsecích ochranného pásma KRNAP, často přecházející v ruderály

7. Podmáčené porosty

7.1 Rašeliniště a degradovaná rašeliniště – podmáčené deprese a svahová rašeliniště s dominantními mechy; v degradovaných variantách s vysokým podílem bezkolence modrého (*Molinia caerulea*)

7.2 Pcháčové a podmáčené louky – nivy potoků, zvodnělé deprese nebo prameništní louky; často jen pasené nebo ponechané ladem; s vysokým podílem pcháče zelinného (*Cirsium oleraceum*) nebo skřípiny lesní (*Scirpus sylvaticus*)

8. Cenná antropogenní společenstva

8.1 Horské knotovkové louky (*Melandrio rubri-Phleetum alpini*) – bohatá širokolistá společenstva v dusíkem dobře zásobeném okolí bud a chat; dominantními druhy jsou kontryhel (*Alchemilla* sp.) nebo rdesno hadí kořen (*Bistorta major*); často přítomny i subalpínské druhy jako bojínek švýcarský (*Phleum rhaeticum*)

8.2 Sešlapávané trávníky – v okolí cest a bud, zastoupeny druhy tolerantní k sešlapu jako úrazník položený (*Sagina procumbens*), jitrocel větší (*Plantago major*) nebo lipnice roční (*Poa annua*) a druhy dovozené se šterkem z nížiny.

Klasifikována byla pouze první úroveň legendy, celkem tedy 8 kategorií lučních společenstev. Nad rámec legendy stanovené botanikem byla navíc do klasifikace zahrnuta ještě třída mulčovaných luk, která se na snímku také poměrně často vyskytuje. Výsledná legenda využitá při klasifikaci tak zahrnovala 9 tříd.

4.3.2 Legenda dle Natury 2000

Cílem diplomové práce bylo ověřit také možnosti dat WorldView-2 pro mapování biotopů Natura 2000. Legenda vytvořená pro modelové území na základě Natury 2000 zahrnuje celkem 7 kategorií:

1. R2.3 Přejchodová rašeliniště
2. T1.1 Mezofilní ovsíkové louky
3. T1.2 Horské trojštětové louky
4. T1.5 Vlhké pcháčové louky
5. T2.2 Horské smilkové trávníky s alpinskými druhy
6. T8.2 Sekundární podhorská a horská vřesoviště
7. X7 Ruderální bylinná vegetace mimo sídla

Nasbírané terénní vzorky byly dle map Natura zařazeny do jednotlivých kategorií a poté využity jako trénovací plochy pro klasifikaci.

4.4 Vegetační indexy

Pro mapování vegetace se používají zejména tzv. vegetační indexy. Využívají se také např. k zjišťování kvantitativních ukazatelů, jako množství biomasy apod. Vegetační indexy jsou založeny na vztahu mezi odrazivostí červené viditelné části spektra (600 – 700 nm, RED) a blízké infračervené části spektra (700 – 900 nm, NIR). Lze je rozdělit do dvou velkých skupin na poměrové a ortogonální indexy. V diplomové práci byly pro mapování luční vegetace využity poměrové vegetační indexy, které jsou vyjádřeny poměrem odrazivosti povrchů v červené viditelné a blízké infračervené části spektra. Naproti tomu ortogonální indexy představují lineární kombinaci původních pásem multispektrálního obrazu (http://www.sci.muni.cz/~dobro/zemsky_povrch_vegetace.html).

Pomocí diskriminační analýzy byl hodnocen význam vegetačních indexů – RVI, SAVI a NDVI pro odlišení tříd luční vegetace.

Jednoduchý poměrový vegetační index RVI (Ratio Vegetation Index) poprvé použil Jordan (1969). Vyjadřuje poměr mezi odrazivostí v blízké infračervené (NIR) a červené viditelné (RED) části spektra a nabývá hodnot od 0 do více než 30. Pro zelenou vegetaci jsou nejčastější hodnoty v rozmezí od 2 do 8.

$$RVI = \frac{NIR}{RED}$$

Vegetační index SAVI (Soil-Adjusted Vegetation Index) minimalizuje rušivý vliv půdy. Poprvé index popsal Huete (1988). Nabývá hodnot od -1 do 1 a vypočte se na základě vzorce:

$$SAVI = \frac{(1 + L) \cdot (NIR - RED)}{NIR + RED + L},$$

kde proměnná L představuje korekci vlivu půdy – 0 pro velmi vysokou vegetaci a 1 pro velmi nízkou vegetaci, nejčastěji se však používá hodnota 0,5.

Normalizovaný vegetační index NDVI (Normalized Difference Vegetation Index) je jedním z nejpoužívanějších vegetačních indexů a poprvé byl popsán v Rouse et al. (1973). Nabývá hodnot od -1 do 1. Hodnoty typické pro zelenou vegetaci se pohybují na intervalu od 0,2 do 0,8.

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Dále bylo hodnoceno s využitím diskriminační analýzy 5 indexů založených na NDVI - $NDVI_{Coastal\ blue}$, $NDVI_{Blue}$, $NDVI_{Green}$, $NDVI_{Yellow}$ a $NDVI_{Red-edge}$. Zatímco klasické NDVI je citlivé především na množství zelené biomasy, naproti tomu $NDVI_{Green}$ vykazuje větší citlivost na obsah chlorofylu v rostlinách (Gitelson et al. 1996). Index je vypočten na základě vzorce pro NDVI s tím rozdílem, že odrazivost v červené viditelné části spektra je nahrazena odrazivostí v zelené viditelné části spektra:

$$NDVI_{Green} = \frac{NIR - GREEN}{NIR + GREEN}$$

$NDVI_{Red-edge}$ je další modifikací tradičního indexu NDVI. Je určený především pro data s velmi vysokým spektrální rozlišením, jako jsou hyperspektrální data. Využívá se zejména v oblasti precizního zemědělství, monitorování lesních porostů či detekce vegetačního stresu (Gitelson and Merzlyak, 1994).

$$NDVI_{Red-edge} = \frac{NIR - RED\ EDGE}{NIR + RED\ EDGE}$$

Obdobně jsou spočteny i další indexy založené na NDVI.

Mutanga et al. (2012) hodnotil ve své studii, zaměřené na zjištění množství biomasy u mokřadní vegetace, indexy založené na NDVI ze všech možných kombinací dvou pásem

družicových dat WorldView-2, celkem tedy 64 indexů založených na NDVI. Jako nejvýznamnější byl vyhodnocen index s použitím pásma red-edge. Uvedené indexy byly vybrány právě z důvodu předpokládaných rozdílů mezi množstvím biomasy u jednotlivých společenstev.

4.5 Diskriminační analýza

Diskriminační analýza patří mezi vícerozměrné statistické metody. Slouží jednak k nalezení optimálních proměnných významných pro diskriminaci mezi předem danými skupinami objektů (kanonická diskriminační analýza), jednak ke klasifikaci neznámých objektů do skupin (klasifikační diskriminační analýza). Objekty jsou odděleny ve vícerozměrném prostoru podél přímky, jedná se tedy o lineární diskriminační analýzu, obdobu lineární regrese. Existuje však také kvadratická diskriminační analýza. Princip diskriminační analýzy spočívá v nalezení kombinace několika proměnných odlišujících existující skupiny objektů, které nelze odlišit žádnou z proměnných samostatně. Výpočet diskriminační analýzy probíhá ve dvou krocích. Nejprve je testována významnost rozdílů v hodnocených proměnných mezi existujícími skupinami objektů. Následně je nalezena lineární kombinace proměnných, která nejlépe rozlišuje mezi danými skupinami objektů, tzv. diskriminační funkce (Jarkovský a Littnerová 2011).

Klasická diskriminační analýza byla popsána v roce 1936 Ronaldem A. Fisherem pod názvem canonical variate analysis (CVA). Rao ji později rozšířil pro více než dvě skupiny. Vychází z předem známých dvou a více skupin objektů, kdy je o každém objektu známo, do které skupiny patří. Každý zkoumaný objekt je charakterizován souborem proměnných, na základě kterých se pro každou skupinu vypočítá diskriminační funkce sloužící k co nejlepšímu odlišení daných skupin. Fisherova diskriminační analýza slouží zároveň k zařazování nových objektů do příslušných skupin, kdy je pravděpodobnost příslušnosti nezařazeného objektu vypočtena na základě diskriminační funkce. Nový objekt je pak zařazen do skupiny s nejvyšší pravděpodobností (Jarkovský a Littnerová 2012, Pešková 2009).

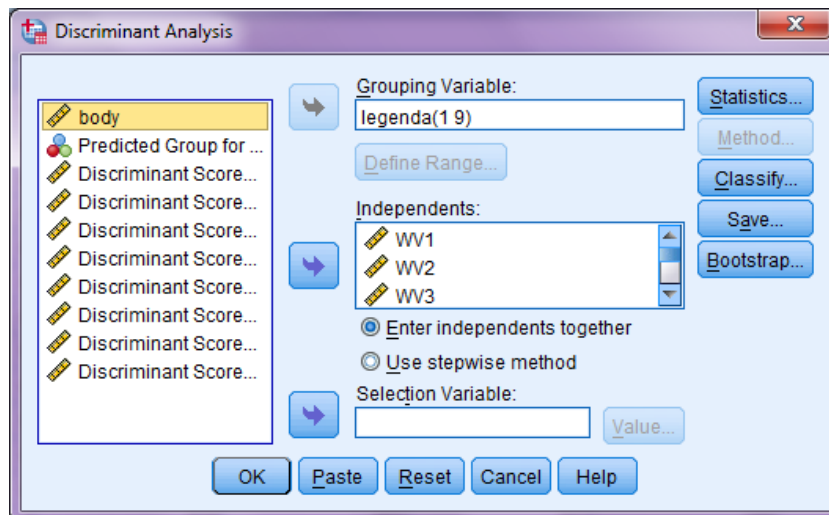
4.5.1 Využití diskriminační analýzy při klasifikaci lučních společenstev

Řada studií zabývajících se klasifikací travních porostů využívá diskriminační analýzu za účelem nalezení nejlepších identifikátorů pro odlišení jednotlivých lučních kategorií.

Cingolani et al. (2004) založil klasifikaci horských pastvin z dat Landsat TM na Fisherově diskriminační funkci a dosáhl celkové přesnosti 86 % v porovnání s klasifikací klasickou metodou maximální věrohodnosti bez využití diskriminační analýzy, jejíž přesnost byla 78 %. Diskriminační analýzu nad daty Landsat TM použili ve své studii také Lauver and Whistler (1993). Pro odlišení kvalitních kosených trávníků od pasených trávníků nízké kvality bylo nalezeno několik kombinací vstupních proměnných, ze kterých byly metodou maximálních věrohodnosti vytvořeny mapy potenciální luční vegetace s přesností pohybující se od 76,5 % do 82,3 %. Price et al. (2002) hodnotil pomocí diskriminační funkce několik vegetačních indexů a spektrálních pásem Landsat TM s cílem nalézt optimální kombinaci proměnných pro rozlišení několika managementových zásahů na travních porostech.

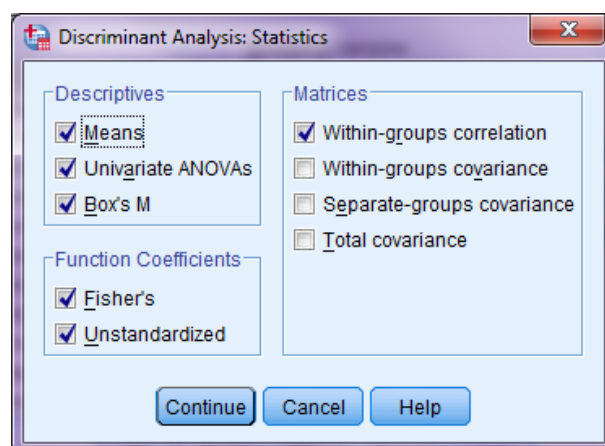
S cílem nalézt optimální kombinaci proměnných pro diskriminaci mezi danými třídami lučních společenstev (viz kapitola Legenda stanovená botanikem) a zlepšit tak přesnost klasifikace byla v této diplomové práci využita Fisherova diskriminační analýza. Celkem bylo testováno 24 proměnných – 8 pásem družicového snímku WorldView-2 (coastal blue, blue, green, yellow, red, red edge, NIR1, NIR2), 8 hlavních komponent analýzy PCA (principal component analysis) a vegetační indexy NDVI, RVI, SAVI, NDVI_{Coastal blue}, NDVI_{Blue}, NDVI_{Green}, NDVI_{Yellow}, NDVI_{Red-edge}. Vstupní soubor zahrnoval 327 pixelů (pixely v okolí bodů zaměřených v terénu) rozdělených do 9 tříd (počet tříd legendy stanovené botanikem). Pro každý pixel byly nasbírány hodnoty uvedených 24 proměnných.

Diskriminační analýza byla provedena v softwaru SPSS Statistics od společnosti IBM. Vstupní soubor obsahující hodnoty proměnných pro jednotlivé pixely byl uložen ve formátu MS Excel a následně načten do softwaru SPSS. Nástroj pro diskriminační analýzu se v softwaru SPSS nachází pod záložkou *Analyze – Classify – Discriminant analysis*. Před samotným provedením analýzy je třeba zvolit položku, která definuje rozdělení jednotlivých objektů, v tomto případě pixelů, do skupin (*Grouping Variable*) a dále položky, které obsahují hodnoty jednotlivých proměnných pro každý pixel (*Independents*).



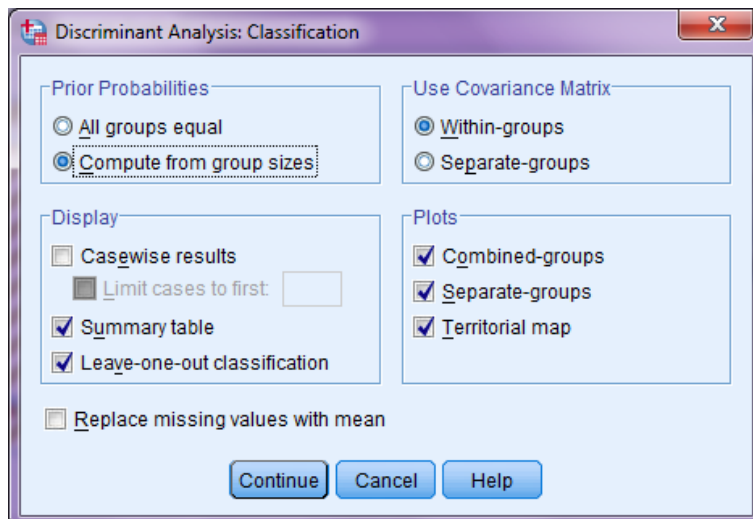
Obr. 7 Diskriminační analýza v prostředí SPSS Statistics
(Zdroj: IBM SPSS Statistics)

Pod záložkou *Statistics* lze následně vybrat jednak charakteristiky jednotlivých proměnných (*Descriptives*), jednak typ koeficientů diskriminační funkce (*Function Coefficients*) a jejich matic (*Matrices*), které mají být vygenerovány.



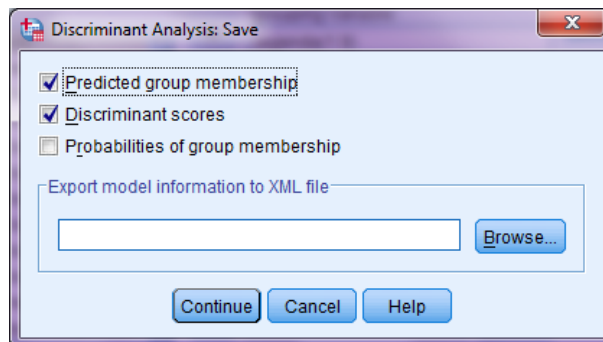
Obr. 8 Statistics box
(Zdroj: IBM SPSS Statistics)

Classification box umožňuje nastavit, zda budou klasifikační koeficienty upraveny na základě předem dané příslušnosti ke skupině či nikoliv (*Prior Probabilities*). Volba *All groups equal* nemá žádný vliv na výsledné koeficienty, zatímco u volby *Compute from group sizes* jsou koeficienty upraveny tak, aby se zvýšila pravděpodobnost příslušnosti k největší skupině. Dále lze zvolit možnosti zobrazení (*Display*), typ kovarianční matice použitý při klasifikaci (*Use Covariance Matrix*) a grafy, které budou vygenerovány (*Plots*).



Obr. 9 Classification box
(Zdroj: IBM SPSS Statistics)

Pomocí funkce *Save* pak lze nastavit přidání nových proměnných do vstupního souboru. Vybrat lze předpokládanou příslušnost k určité skupině (*Predicted group membership*), diskriminační skóre (*Discriminant scores*) nebo pravděpodobnost příslušnosti k dané skupině (*Probabilities of group membership*).



Obr. 10 Save box
(Zdroj: IBM SPSS Statistics)

Pro každou luční kategorii byla vygenerována příslušná Fisherova diskriminační funkce, celkem tedy 9 diskriminačních funkcí. Jako nejvýznamnější proměnné pro diskriminaci mezi danými kategoriemi byly zjištěny vegetační indexy NDVI, NDVI_{Green} a NDVI_{Blue}. Z výsledků diskriminační analýzy uvedených v tab. 1 bylo vybráno 14 proměnných – vegetační indexy NDVI_{Green}, NDVI_{Blue}, NDVI, NDVI_{Yellow}, SAVI, RVI a spektrální pásma WV1, WV2, WV3, WV4, WV5, WV6, WV7, WV8 které byly následně využity

při klasifikaci lučních společenstev. Zbylé dvě proměnné z diskriminační funkce, první a pátá komponenta analýzy PCA, nebyly ve výsledné klasifikaci použity, neboť přesnost klasifikace snižovaly. Vyzkoušena byla také klasifikace s menším počtem proměnných, avšak výsledná přesnost byla horší. V případě klasifikace luční vegetace provedené v této práci platí, že čím vyšší je počet zahrnutých proměnných (z výsledků diskriminační analýzy), tím je vyšší i přesnost klasifikace.

Classification Function Coefficients									
	legenda								
	1	2	3	4	5	6	7	8	9
WW1	10,748	10,648	11,097	11,360	11,034	11,279	11,729	10,825	10,777
WW2	35,240	34,279	34,426	33,869	33,520	34,520	33,046	34,848	33,571
WW3	-55,209	-54,581	-54,614	-53,597	-53,598	-54,239	-53,301	-54,413	-52,525
WW4	1,832	1,816	1,826	1,524	1,626	1,561	1,361	1,815	1,531
WW5	30,651	31,262	30,487	30,162	30,610	30,374	30,579	30,345	30,369
WW6	1,488	1,516	1,548	1,468	1,546	1,389	1,494	1,378	1,405
WW7	7,121	6,938	7,004	6,895	6,905	6,954	6,876	6,900	6,529
WW8	-,630	-,561	-,602	-,517	-,588	-,493	-,523	-,479	-,421
PCA1	,036	,036	,040	,035	,036	,038	,035	,040	,034
PCA5	,567	,696	,732	,595	,581	,643	,684	,599	,568
NDVI	15371,706	15469,467	15312,415	15133,158	15300,743	15258,429	15256,635	15244,288	15010,619
NDVI_GREEN	-36343,147	-36316,817	-36184,316	-35478,639	-35172,701	-36112,756	-35335,531	-36147,699	-35179,807
NDVI_BLUE	18149,738	18005,657	18007,530	17492,285	17109,904	17985,135	17233,857	18055,985	17428,257
SAVI	85,816	84,150	85,354	83,114	85,493	83,977	83,987	76,564	83,404
RVI	7,959	14,903	9,352	8,066	7,335	13,356	7,453	17,312	20,671
NDVI_YELLOW	266,357	259,622	266,282	255,771	263,427	227,226	272,221	257,787	235,905
(Constant)	-4527,095	-4535,949	-4503,828	-4460,372	-4433,910	-4551,574	-4480,111	-4532,371	-4478,903

Fisher's linear discriminant functions

Tab. 1 Fisherova diskriminační funkce pro data WorldView-2

(Zdroj: IBM SPSS Statistics)

Diskriminační analýze byla stejným způsobem podrobena také simulovaná data Quickbird. Testována byla pásma blue, green, red a NIR1, vegetační indexy NDVI, NDVI_{Blue}, NDVI_{Green}, SAVI, RVI a 4 hlavní komponenty analýzy PCA vypočtené ze 4 uvedených spektrálních pásem. Vstupní soubor hodnot proměnných byl nasbíráán na základě totožných pixelů jako u předchozího testu. Z výsledků diskriminační analýzy (viz tab. 2) bylo vybráno 9 proměnných ke klasifikaci luční vegetace pomocí simulovaných dat Quickbird. Do klasifikace nebyla z Fisherovy diskriminační funkce zahrnuta pouze třetí komponenta analýzy PCA, která stejně jako v prvním případě nepřinesla zlepšení výsledků klasifikace.

Classification Function Coefficients

	legenda								
	1	2	3	4	5	6	7	8	9
BLUE	70,896	71,092	70,586	69,772	69,103	71,490	69,767	71,017	69,504
GREEN	-76,714	-77,288	-76,534	-75,438	-75,102	-77,066	-75,788	-76,628	-74,813
RED	-8,302	-8,352	-8,270	-8,276	-8,220	-8,627	-8,221	-8,155	-8,041
NIR	13,064	13,184	13,044	12,909	12,905	13,104	12,987	12,969	12,676
NDVI	20419,552	20695,023	20413,552	20203,612	20358,137	20439,820	20416,588	20351,708	20120,304
NDVI_GREEN	-41744,491	-42120,995	-41714,375	-41028,552	-40573,285	-42024,189	-41116,513	-41821,301	-40911,386
NDVI_BLUE	18903,724	18967,263	18867,869	18388,152	17861,804	19083,715	18282,937	19029,977	18420,205
SAVI	94,083	93,886	94,419	92,620	94,112	94,349	94,618	86,248	93,499
RVI	37,559	42,500	38,202	37,525	37,007	41,957	37,558	44,881	47,639
PCA3	65,876	67,363	65,959	65,164	65,624	66,311	65,794	65,603	65,274
(Constant)	-4887,042	-4971,979	-4853,711	-4770,402	-4754,382	-4935,734	-4798,985	-4915,440	-4852,211

Fisher's linear discriminant functions

Tab. 2 Fisherova diskriminační funkce pro simulovaná data Quickbird

(Zdroj: IBM SPSS Statistics)

4.6 Klasifikace luční vegetace

Pro klasifikaci lučních společenstev z dat WorldView-2 byla zvolena metoda řízené klasifikace algoritmem neuronových sítí (Neural Net) v porovnání s klasickou metodou maximální věrohodnosti (Maximum Likelihood). Metoda klasifikace pomocí neuronových sítí byla vybrána na základě předpokladu, podle kterého by měla lépe vystihnout složitost a rozmanitost heterogenní luční vegetace než tradiční metody klasifikace jakou je např. metoda maximální věrohodnosti (McMahan et al. 2003).


4.6.1 Klasifikátor neuronových sítí

Neuronové sítě představují algoritmy, které se snaží napodobit procesy probíhající v nervové soustavě. Základním prvkem umělé neuronové sítě jsou neurony vzájemně propojené do sítě. Neurony jsou v síti propojeny tzv. váhovými koeficienty, které zesilují nebo zeslabují signál přicházející z předchozích neuronů. Neuron může přijímat několik vstupů z jiných neuronů, avšak generuje pouze jeden výstup. Výstup z neuronu je definován funkcí $F(x)$, která kombinuje hodnoty všech vstupních podnětů x :

$$F(x) = \sum_i w_i x_i$$

kde x_i je hodnota i -tého vstupu a w_i je váha i -tého vstupu. Každá funkce $F(x)$ je prahována pro určitou výstupní hodnotu. Výstup z neuronu je tedy realizován pouze v případě, kdy překračuje tuto prahovou hodnotou. Uspořádání neuronové sítě může mít řadu různých podob. Každá síť zahrnuje kromě vstupních a výstupních vrstev obvykle také několik vnitřních, skrytých vrstev (Dobrovolný 1998).

Klasifikace obrazu pomocí neuronových sítí může mít podobu řízené i neřízené klasifikace. Neuronová síť analogická k řízené klasifikaci využívá k natrénování učící algoritmus zpětného šíření (Back propagation). Proces učení se probíhá tak, že jsou sítí předkládána trénovací data, a na základě toho se mění váhové spojení mezi neurony. Cílem je dosáhnout nulové či minimální chyby. Příkladem neřízené neuronové sítě jsou tzv. samoorganizující se sítě (Self-organizing) jako Kohonenova síť (Kýnová 2010).



Obr. 11 Schéma neuronové sítě

(Zdroj: <http://lib.bioinfo.pl/courses/view/501>)

Klasifikace metodou neuronových sítí má svoje výhody i nevýhody. Mezi hlavní výhody patří možnost kombinovat data z různých zdrojů, např. optická data, radarová data apod. K výhodám také patří i to, že vstupní data nevyžadují normální rozdělení jako je tomu např. u klasifikátoru maximální věrohodnosti. Naopak nevýhodou neuronových sítí je fakt, že nepracují s žádným přesně definovaným matematickým modelem. K vytvoření neuronové sítě je navíc zapotřebí velkého množství dat (Dobrovolný 1998).

4.6.2 Klasifikace v softwaru ENVI

Klasifikace lučních společenstev pomocí klasifikátorů neuronových sítí a maximální věrohodnosti byla provedena v softwaru ENVI 4.7. Před samotnou klasifikací byly na základě pořízených terénních dat nasbírány trénovací množiny pro jednotlivé položky legendy. V softwaru ENVI slouží ke sběru trénovacích ploch nástroj *Region Of Interest (ROI)*. Trénovací plochy lze definovat jak polygonem, tak výběrem jednotlivých pixelů. V tomto případě byly trénovací plochy definovány polygonem kolem zaměřených bodů reprezentujících jednotlivé typy lučních společenstev, resp. kategorie legendy v terénu. Jelikož nebyly u terénních dat zaznamenány také rozměry příslušného společenstva, byla velikost trénovací plochy volena na základě vizuálního zhodnocení, zda se daná plocha jeví jako jedno společenstvo či nikoliv. Pro dané snímky WorldView-2, ze srpna a října 2011, byly nasbírány odlišné trénovací soubory jednak z důvodu výskytu jevu haze na srpnovém snímku, jednak z důvodu změny managementu na zářijovém snímku. Z trénovacího souboru pro srpnový snímek byly vyřazeny plochy, které se nacházely pod oparem. Naopak v případě zářijového snímku nebyly do trénovacího souboru zařazeny plochy, u kterých došlo k provedení managementového zásahu, případně byly tyto plochy přiřazeny k některé z managementových kategorií, pokud bylo evidentní, o jaký typ zásahu se jedná. Trénovací množiny pro kategorie legendy dle Nature 2000 byly definovány rovněž polygonem kolem zaměřených bodů na základě překryvu s vrstvou mapování biotopů. Zejména pro klasifikátor neuronových sítí platí, že čím více pixelů je obsaženo v trénovacích množinách, tím je klasifikace přesnější.

Po nasbírání trénovacích množin bylo přistoupeno k samotné klasifikaci luční vegetace. Při klasifikaci jak pomocí metody neuronových sítí, tak pomocí klasifikátoru maximální věrohodnosti se vycházelo z výsledků diskriminační analýzy. Finální klasifikace byla provedena na základě 14 vstupních pásem z Fisherovy diskriminační funkce – 8 spektrálních pásem družicového snímku WorldView-2 a 6 vegetačních indexů $NDVI_{Green}$, $NDVI_{Blue}$, $NDVI$, $NDVI_{Yellow}$, $SAVI$, RVI . Fisherova diskriminační funkce obsahovala také první a pátou komponentu analýzy PCA, avšak zahrnutí těchto dvou proměnných do klasifikace snižovalo její přesnost, proto ve výsledné klasifikaci nebyly použity. Dále byla provedena klasifikace algoritmem neuronových sítí pomocí simulovaných dat Quickbird s cílem zjistit, zda nová pásma přidaná v datech WorldView-2 přispějí ke zlepšení přesnosti klasifikace. Klasifikace vycházela rovněž z výsledků diskriminační analýzy a zahrnovala

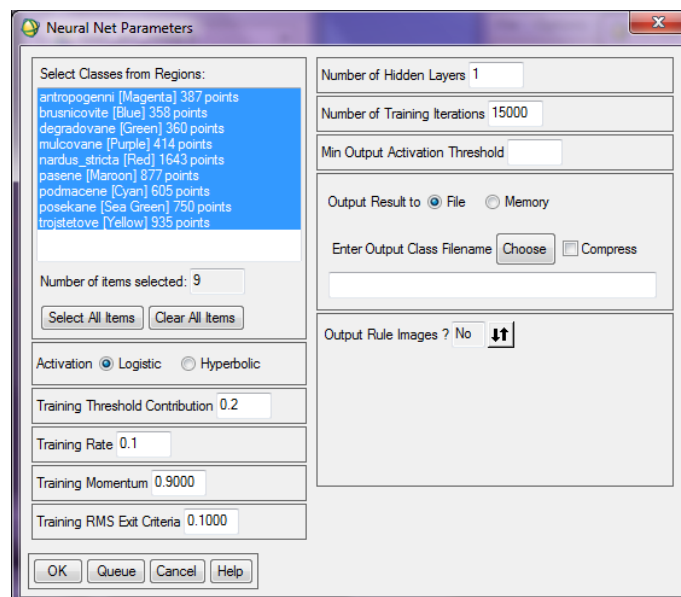
pásma blue, green, red a NIR1 z dat WorldView-2 a indexy NDVI, NDVI_{Green}, NDVI_{Blue}, SAVI a RVI.

Vegetační indexy byly spočteny v softwaru ENVI pomocí funkce *Band Math* a uloženy jako samostatná pásma. Aby bylo možné využít při klasifikaci jak pásma družicového snímku, tak i vegetační indexy, bylo nutné spojit všechna pásma do jednoho souboru. K tomuto účelu slouží v softwaru ENVI funkce *Layer Stacking*.

Klasifikátor neuronových sítí v softwaru ENVI (*Classification/Supervised/Neural Net*) představuje typ vícevrstvé dopředné (feedforward) sítě a používá k učení se s učitelem tradiční algoritmus zpětného šíření (backpropagation). Zahrnuje několik nastavitelných parametrů. Lze zvolit počet skrytých vrstev (*Number of Hidden Layers*) a vybrat mezi logistickou a hyperbolickou aktivační funkcí. Dále lze nastavit počet iterací (*Number of Training Iterations*) a hodnotu směrodatné odchylky (*Training RMS Exit Criteria*). Fáze trénování pak probíhá tak dlouho, dokud není dosažen zvolený počet iterací nebo hodnota směrodatné odchylky neklesne pod nastavený práh. Parametr *Training Threshold Contribution* se používá k úpravě změn vnitřních vah uzlu. Lze nastavit hodnotu od 0 do 1, přičemž hodnota 0 neumožňuje úpravu vnitřních vah uzlu. Parametr *Training Rate* slouží k nastavení rychlosti trénování zadáním hodnoty od 0 do 1. Vyšší hodnota umožňuje rychlejší trénování, avšak zvyšuje riziko vzniku oscilací. Parametr *Training Momentum* vyžaduje rovněž zadání hodnoty od 0 do 1. Zvolením hodnoty větší než 0 lze dosáhnout vyšší rychlosti trénování bez oscilací. Na závěr lze nastavit ještě aktivační hodnotu pixelu (*Min Output Activation Threshold*). Pokud hodnota klasifikovaného pixelu bude nižší než zvolený práh, pak daný pixel nebude klasifikován. Testováním klasifikátoru neuronových sítí bylo zjištěno, že největší vliv na přesnost klasifikace luční vegetace má počet iterací (*Number of Training Iterations*) a parametry *Training Rate* a *Training Threshold Contribution*. Nejvyšší úspěšnost klasifikace byla dosažena nastavením počtu iterací na 15000 a parametrů *Training Rate* na hodnotu 0,1 a *Training Threshold Contribution* na hodnotu 0,2. Ostatní parametry byly ponechány podle původního nastavení.

Klasifikátor maximální věrohodnosti (Maximum Likelihood) patří mezi tradiční metody klasifikace a je založen na výpočtu pravděpodobnosti, že daný pixel patří do určité třídy. Každý pixel je pak přiřazen do třídy s nejvyšší pravděpodobností. U klasifikátoru maximální věrohodnosti v softwaru ENVI lze nastavit práh pravděpodobnosti (*Set Probability Threshold*) zvolením hodnoty od 0 do 1. Parametr *Probability Threshold* lze nastavit buď pro všechny třídy jednotně, nebo pro každou třídu zvlášť. Pixel, jehož hodnota

pravděpodobnosti příslušnosti k třídě klesne pod nastavený práh, nebude klasifikován. Hodnota *Probability Threshold* nebyla nastavena, tudíž všechny pixely byly klasifikovány.



Obr. 12 Parametry nastavené při použití klasifikátoru neuronových sítí
(Zdroj: ENVI 4.7)

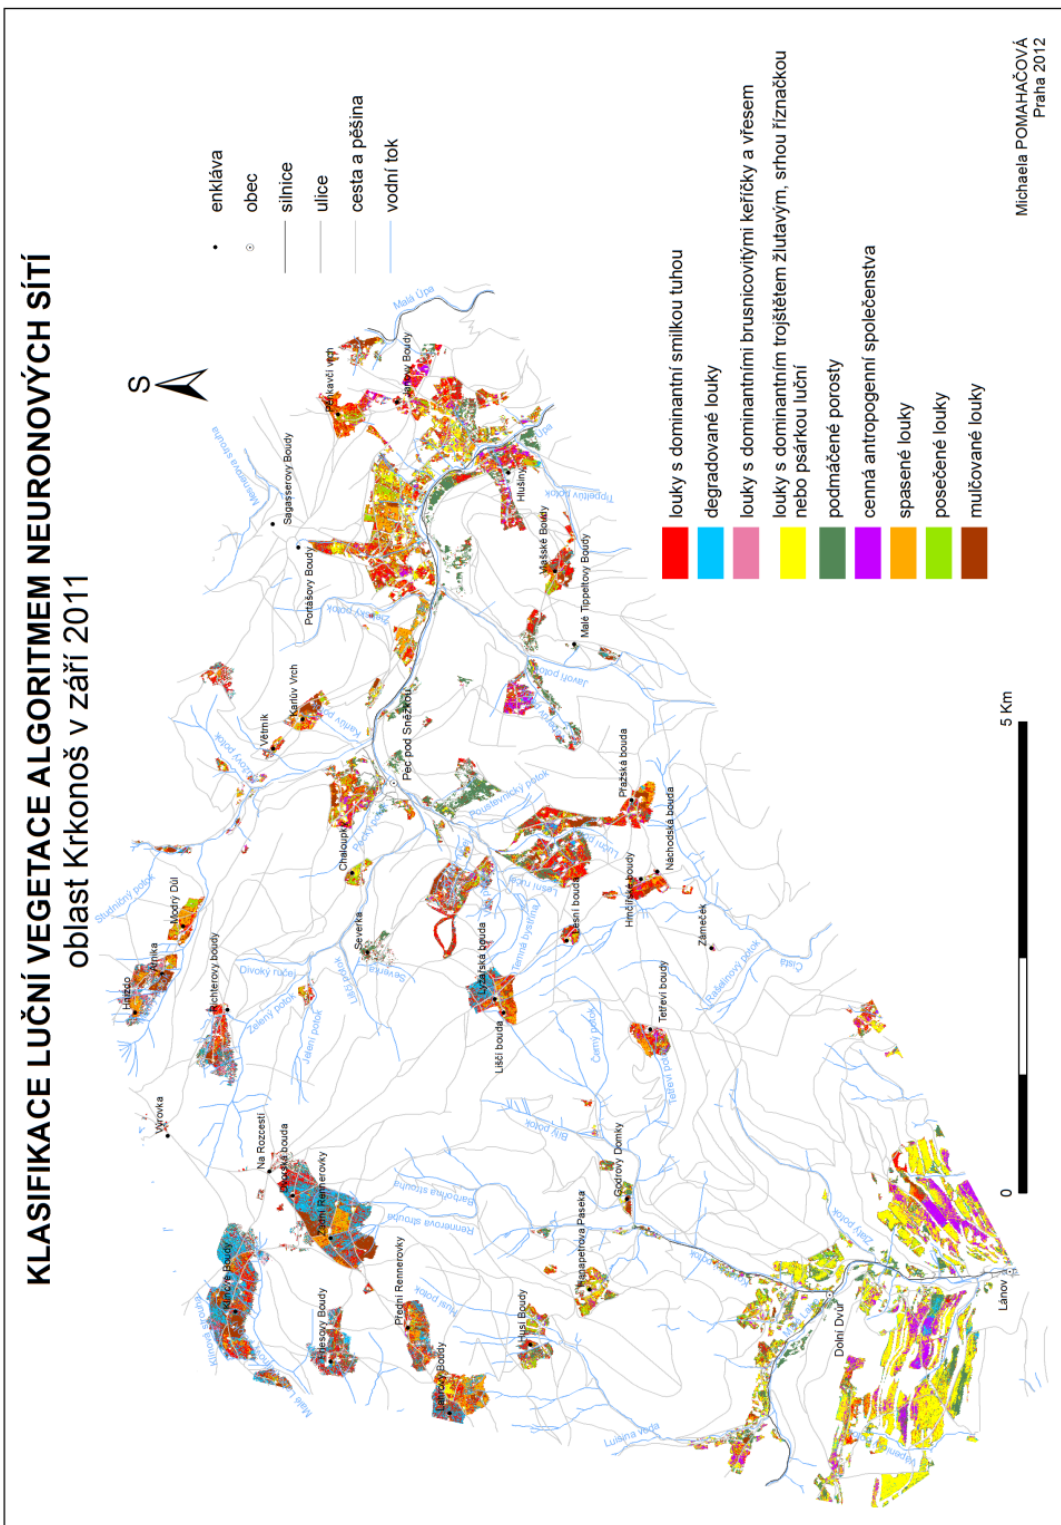
Za účelem odstranění izolovaných pixelů byly výsledky klasifikace upraveny pomocí nízkofrekvenčního mediánového filtru o velikosti 5x5 pixelů (*Filter/Convolutions and Morphology/Convolutions/Median*). Na závěr byly výsledné rastry převedeny na vektorové vrstvy (*Classification/Post Classification/Classification to Vector*).

5 Výsledky

5.1 Výstupy klasifikace

Z výstupů klasifikací převedených na vektorové vrstvy byly vytvořeny v softwaru ArcGIS 9.3 mapy luční vegetace. Z důvodu lepší orientace na zájmovém území byly mapy doplněny topografickým podkladem vytvořeným z dat ZABAGED zapůjčených Zeměměřickým úřadem. Na obrázku č. 13 je znázorněna klasifikace luční vegetace z dat WorldView-2 v září algoritmem neuronových sítí, která zahrnuje celé zájmové území, a u níž byla dosažena nejvyšší přesnost (91,1 %) a pro srovnání klasifikace na základě simulace dat Quickbird (viz obrázek č. 14), jejíž přesnost byla 76,5 %. Ostatní výstupy jsou zařazeny v přílohách (viz přílohy č. 5 až 10).

KLASIFIKACE LUČNÍ VEGETACE ALGORITMEM NEURONOVÝCH SÍTÍ oblast Krkonoš v září 2011



Obr. 13 Klasifikace luční vegetace z dat WorldView-2 algoritmem neuronových sítí v Krkonoších v září 2011
(Zdroj: vlastní, ArcGIS 9.3)

5.2 Zhodnocení přesnosti klasifikace

Přesnost výsledků klasifikace po aplikaci mediánového filtru byla určena v softwaru ENVI 4.7 (*Classification/Post Classification/Confusion Matrix*). Jistou nevýhodou při stanovení přesnosti klasifikace představuje fakt, že pro klasifikaci podle legendy stanovené botanikem nebyl k dispozici žádný mapový podklad, na základě kterého by se dala přesnost zhodnotit. Vrstva mapování biotopů nemohla být využita z důvodu odlišností mezi třídami definovanými botanikem a kategoriemi Natura 2000. Ke stanovení přesnosti klasifikace tak byly použity původní trénovací množiny. Ideální by samozřejmě bylo ověřit přesnost klasifikace přímo v terénu, což ale z časových důvodů již nebylo možné. Navíc přesnost klasifikace u managementových kategorií by se stejně již ověřit nedala.

Nejvyšší přesnost klasifikace byla dle očekávání dosažena metodou neuronových sítí. Celková přesnost klasifikace zářijového snímku pomocí umělých neuronových sítí byla 91,1414 % (Kappa Coefficient = 0,8957) v porovnání s metodou maximální věrohodnosti, jejíž přesnost byla 83,6422 % (Kappa Coefficient = 0,8085). Přesnost klasifikace srpnového snímku klasifikátorem neuronových sítí dosáhla 90,7410 % (Kappa Coefficient = 0,8914) v porovnání s klasifikátorem maximální věrohodnosti, jehož přesnost dosáhla 90,6529 % (Kappa Coefficient = 0,8913).

Přesnost klasifikace na základě simulovaného snímku Quickbird, tedy bez nových pásem přidaných v datech WorldView-2 a indexů vytvořených z těchto nových pásem, byla výrazně nižší. V případě zářijového snímku byla přesnost klasifikace pomocí neuronových sítí 76,5119 % (Kappa Coefficient = 0,7203), u srpnového snímku pak klasifikace dosáhla přesnosti jen 74,7195 % (Kappa Coefficient = 0,7032). Porovnáním přesností klasifikací dosažených s použitím nových pásem WorldView-2 a bez nich je tedy evidentní, že nová pásma přidaná v datech WorldView-2 výrazně zvyšují přesnost klasifikace luční vegetace.

Ke stanovení přesnosti klasifikace dle legendy Natura 2000 byla použito 500 náhodně vygenerovaných bodů (*Classification/Post Classification/Generate Random Sample*) na základě vrstvy mapování biotopů. Přesnost klasifikace podle Natury 2000 byla výrazně nižší než v případě legendy stanovené botanikem. To může být do určité míry způsobeno odlišným postupem při hodnocení přesnosti. Přesnost klasifikace zářijového snímku algoritmem neuronových sítí byla pouze 40,2105 % (Kappa Coefficient = 0,1274), zatímco klasifikace srpnového snímku dosáhla 47,4000 % (Kappa Coefficient = 0,1170).

Výsledky hodnocení přesnosti klasifikace jsou zařazeny v přílohách (přílohy č. 11 až 14). Podrobněji jsou komentovány v kapitole Diskuse.

6 Diskuse

Klasifikace luční vegetace je poměrně náročným úkolem. Tradiční metody klasifikace dat DPZ tak nemusí přesně vystihovat složitost ekosystémů, které se vyznačují různorodou a variabilní strukturou vegetace (McMahan et al. 2003). Na základě výsledků dosavadních studií týkajících se dané problematiky byla v předkládané diplomové práci ke klasifikaci lučních společenstev z dat WorldView-2 zvolena metoda umělých neuronových sítí (Neural Net) v porovnání s tradiční metodou maximální věrohodnosti (Maximum Likelihood) v kombinaci s diskriminační analýzou. Klasifikace luční vegetace vycházela z legendy sestavené botanikem z čistě ekologického hlediska, aby respektovala praktické požadavky botaniků Krkonošského národního parku. Legenda zahrnuje kromě samotných lučních společenstev také managementové třídy (posekané/spasené/mulčované).

Dle očekávání dosáhla nejvyšší přesnosti klasifikace pomocí neuronových sítí. Přesnost klasifikace metodou neuronových sítí zářijového a srpnového snímku byla 91,14 % resp. 90,74 %, zatímco přesnost klasifikátoru maximální věrohodnosti dosáhla 83,64 % resp. 90,65 %. Cingolani et al. (2004) klasifikoval horské pastviny z dat Landsat TM s využitím Fisherovy diskriminační funkce s celkovou přesností 86 %. Diskriminační analýzu nad daty Landsat TM použili ve své studii také Lauer and Whistler (1993). Pro odlišení kvalitních kosených trávníků od pasených trávníků nízké kvality bylo nalezeno několik kombinací vstupních proměnných, ze kterých byly metodou maximální věrohodnosti vytvořeny mapy potenciální luční vegetace s přesností pohybující se od 76,5 % do 82,3 %. Přesnost klasifikací luční vegetace z dat WorldView-2, vytvořených v této diplomové práci, se pohybuje od 83,6 % do 91,1 %. Bylo tedy dosaženo vyšší přesnosti klasifikace než v předchozích studiích, které také založily klasifikaci travní vegetace na diskriminační analýze. Avšak předchozí studie pracovaly s daty Landsat TM se zcela odlišným prostorovým rozlišením.

Na zářijovém snímku byla s nejnižší přesností (Producer's Accuracy = 70,13 %) metodou neuronových sítí klasifikována antropogenní společenstva. Nejvíce chybně klasifikovaných pixelů bylo zařazeno do třídy trojštětových luk. Právě sešlapávané trávníky patřící do antropogenních společenstev vykazují podobné druhové složení jako trojštětové louky. Naopak nejvyšší přesnosti klasifikace dosahují trojštětové louky (98,68 %) a porosty s dominantní *nardus stricta* (97,16 %). Při použití klasifikátoru maximální věrohodnosti se vyznačují nejnižší přesností degradované porosty (50,95 %). Degradované porosty mají

nejnižší přesnost klasifikace (77,50 %) také na srpnovém snímku při použití klasifikátoru umělých neuronových sítí. Chybně klasifikované pixely degradovaných luk jsou nejčastěji řazeny mezi kategorie podmáčených a trojštětových luk, dále pak ke kategoriím brusnicových porostů a smilkových luk. Třída degradovaných porostů definovaná botanikem zahrnuje mimo jiné právě degradované smilkové porosty, degradované vlhké louky i pasekovitou vegetaci s brusnicovými keříčky. Tyto porosty tak budou s největší pravděpodobností chybně zařazeny mezi uvedené kategorie. Některá společenstva z třídy degradovaných porostů by tak bylo možná vhodněji zařadit do jiné kategorie. Naopak pomocí metody maximální věrohodnosti vykazují nejnižší přesnost klasifikace smilkové porosty (82,29 %), přičemž nejvíce chybně klasifikovaných pixelů je zařazeno do třídy degradovaných porostů. Tento fakt tedy také potvrzuje, že by měly být obě třídy lépe odděleny.

Ačkoliv přesnost klasifikace s využitím neuronových sítí byla u zářijového snímku o něco vyšší než v případě srpnového snímku, z botanického hlediska se však jeví jako zdařilejší klasifikace srpnového snímku. Na zářijovém snímku byla totiž řada luk již posekána, spasena či mulčována. U luk, na které byl aplikován nějaký druh managementu, již není možné určit, o jaké společenstvo se jedná, neboť nelze rozlišit jednotlivé dominantní druhy, které jsou rozhodující pro odlišení společenstev. Otázkou tedy zůstává, zda by nebylo vhodnější, klasifikovat luční společenstva a druhy managementu odděleně. Pro klasifikaci samotných lučních společenstev se jeví jako ideální snímek z období počátku vegetačního období, kdy ještě nejsou louky posekány, spaseny či mulčovány. Naopak pro klasifikace lučních managementů by bylo dobré využít sérii snímků z jednoho roku, na kterých by byla patrná změna např. mezi posekanou a neposekanou loukou apod. Pořízení série snímků by však bylo poměrně nákladné, což nemusí být v možnostech Krkonošského národního parku.

Jedním z cílů diplomové práce byla také klasifikace lučních společenstev z dat Quickbird za účelem zjištění, zda nová pásma přidaná v datech WorldView-2 přispějí ke zvýšení přesnosti klasifikace. Dostupná data Quickbird však nebylo možné ortorektifikovat s takovou přesností, aby mohla být využita nasbíraná terénní data k natrénování jednotlivých tříd. Proto byla provedena klasifikace luční vegetace alespoň na základě simulace dat Quickbird pomocí dat WorldView-2. Rozdíly mezi shodnými pásmy (blue, green, red, NIR1) u obou typů dat jsou minimální, simulaci lze tedy považovat za korektní a výsledky by tudíž měly odpovídat použití reálných dat Quickbird. Přesnost klasifikace bez nových pásem dat WorldView-2 byla výrazně nižší. Celková přesnost klasifikace metodou neuronových sítí byla 76,51 % u zářijového snímku a 74,72 % u srpnového snímku. Klasifikace luční vegetace

pomocí dat WorldView-2 tak oproti simulovaným datům Quickbird přináší výrazně lepší výsledky díky speciálním pásmům (coastal blue, yellow, red-edge a NIR2).

Hodnocení přesnosti klasifikace je jednou ze slabin diplomové práce. Pro klasifikaci i verifikaci přesnosti byly totiž použity stejné trénovací množiny. Stanovené přesnosti je tedy třeba brát s jistou rezervou. K hodnocení přesnosti klasifikace na základě legendy sestavené botanikem nebyl k dispozici žádný vhodný aktuální mapový podklad, neboť se jedná o legendu vytvořenou přímo pro potřeby diplomové práce. Nebylo tedy možné využít k verifikaci klasifikace ani vrstvu mapování biotopů z důvodu rozdílů v definici jednotlivých tříd. Ideální by bylo ověřit přesnost přímo v terénu, což však z časových důvodů již nebylo možné. Zhodnocení klasifikace z botanického hlediska provedl alespoň na základě vytvořených mapových výstupů botanik národního parku. Jak uvedl Mgr. Stanislav Březina, Ph.D. ve svém e-mailu z 11. 8. 2012 „*Relativně velkou přesnost má klasifikace „srpnových“ smilkových luk. V zářijových snímcích však relativně často dochází k záměně smilkových a pasených lokalit. Trojštětové louky jsou vymapovány slušně například na Výsluní, ale při zářijové klasifikaci na výše položených enklávách jsou umístěny do prostoru, kde by se dalo očekávat degradované porosty. Brusnicové porosty jsou naopak uvěřitelně vymapované na vysokohorských enklávách jako Richterovky nebo Modrý Důl, ale v údolí Úpy jsou leckde umístěny na místech reálných výskytů degradovaných luk. Podmáčené porosty jsou vymapovány na těch opravdu nejpodmáčenějších místech. Leckde jinde jsou i poměrně hodně podmáčené porosty klasifikovány jinak. Degradovaná společenstva jsou vymapována solidně, ale například na Zadních Rennerovkách jsou nadhodnocena na úkor smilkových luk. Rozsah pastvy se jeví často jako nadhodnocený. Co se týče ostatních managementů, např. na Zadních Rennerovkách se klasifikace degradovaných, mulčovaných a pasených porostů nepodobá reálu. Obecně se klasifikace srpnového snímku jeví jako zdařilejší než klasifikace zářijová.*“ Lze tedy říci, že srpnový snímek je botanikem považován za vhodnější ke klasifikaci lučních společenstev než zářijový, přestože přesnost klasifikace metodou Neural Net zářijového snímku hodnocená v ENVI vyšla mírně vyšší. Může to být dáno i tím, že na srpnovém snímku nebyla z důvodu haze klasifikována oblast Rennerovek a Klínovek, která se na zářijovém snímku jeví jako ne příliš zdařile klasifikovaná. Obecně lze souhlasit s tím, že srpnový snímek byl pro klasifikaci vhodnější zejména z důvodu, že na něm bylo méně lučních společenstev pokoseno (spaseno, mulčováno). To potvrdila i vyšší přesnost v případě využití metody Maximum Likelihood. Klasifikace zářijového snímku může být ale naopak ovlivněna tím, že terénní vzorky určené k natrénování jednotlivých tříd byly nasbírány v srpnu. V prodlevě mezi nasbíráním terénních dat a pořízením zářijového snímku

tak mohlo dojít na zájmových plochách ke změně jejich stavu, zejména co se týká managementu. Mgr. Stanislav Březina, Ph.D. ve svém e-mailu z 11. 8. 2012 dále uvedl *„Výsledky jsou cenné tím, že ukazují velké rozdíly v úspěšnosti klasifikace mezi jednotlivými lokalitami. To je zřetelné zejména při pohledu na vysokohorské enklávy typu Zadních Rennerovek a údolní luční vegetace typu Výsluní. Spíše jako hypotézu k následnému ověření lze uvést, že klasifikace, která funguje nahoře, má problémy v údolí a naopak. Rozdílnost těchto dvou lučních „světů“ by se měla brát v potaz při dalším rozvíjení práce.“*

Klasifikace na základě legendy Natura 2000 dosáhla výrazně nižší přesnosti v porovnání s klasifikací dle legendy sestavené botanikem. Přesnost klasifikace algoritmem neuronových sítí byla u srpnového snímku 47,40 % a 40,21 % u zářijového snímku. Avšak přesnosti klasifikací obou legend byly stanoveny odlišným způsobem. Jednu z nevýhod legendy Natura 2000 představuje absence managementových kategorií, přestože na obou snímcích ze srpna i září se vyskytují plochy, na kterých byl uplatněn nějaký druh managementu. Zejména pak na zářijovém snímku se tyto plochy vyskytují hojně, proto je zřejmě přesnost klasifikace ve srovnání se srpnovým snímkem nižší. Pro mapování biotopů Natura 2000 by tedy bylo vhodné využít snímek z počátku vegetačního období, kdy ještě nejsou luční společenstva posekána, spasena či mulčována. Přesnost klasifikace může být ovlivněna také tím, že pro legendu Natura 2000 nebyly sbírány zvláštní terénní vzorky, ale byly použity vzorky nasbírané pro legendu stanovenou botanikem a převedené do legendy Natura 2000 pomocí vrstvy mapování biotopů. Navíc vrstva mapování biotopů není zcela aktuální, kombinuje data z mapování, které probíhalo v letech 2000 až 2005, a data ze současného mapování, které probíhá od roku 2007.

7 Závěr

Cílem diplomové práce bylo zhodnotit možnosti družicových dat WorldView-2 pro klasifikaci luční vegetace na zájmovém území v Krkonošském národním parku. Klasifikace vycházela primárně z legendy sestavené botanikem, která zahrnovala celkem osm hlavních kategorií včetně dvou kategorií managementu. Navíc byla přidána kategorie mulčovaných luk, která se na snímku také vyskytovala. Dále byla provedena klasifikace na základě legendy sestavené z biotopů Natura 2000, vyskytujících se na modelovém území.

Z důvodu vyloučení vlivu ostatních druhů povrchů na přesnost klasifikace byla vytvořena maska luční vegetace, nad kterou byla následně provedena klasifikace. Na základě předchozích studií zabývajících se klasifikací luční vegetace, které využívaly k tomuto účelu spíše netradiční přístupy, byla zvolena metoda klasifikace pomocí umělých neuronových sítí v kombinaci s diskriminační analýzou. Tato metoda byla porovnána s klasickou metodou maximální věrohodnosti. Podle očekávání byla přesnost klasifikace metodou neuronových sítí vyšší než pomocí klasifikátoru maximální věrohodnosti, i když u srpnového snímku byl rozdíl v přesnosti obou metod minimální.

Jedním z cílů diplomové práce byla také klasifikace lučních společenstev z dat Quickbird za účelem zjištění, zda nová pásma přidaná v datech WorldView-2 přispějí ke zvýšení přesnosti klasifikace. Dostupná data Quickbird nebylo možné ortorektifikovat s takovou přesností, aby mohla být využita nasbíraná terénní data k natrénování jednotlivých tříd. Proto byla provedena klasifikace luční vegetace alespoň na základě simulace dat Quickbird pomocí dat WorldView-2. Klasifikace na základě simulovaných dat Quickbird dosáhla výrazně nižší přesnosti, což potvrdilo předpoklad, že nová pásma přidaná v datech WorldView-2 zlepši přesnost klasifikace luční vegetace.

Poměrně nízké přesnosti dosáhla potom klasifikace podle legendy Natura 2000. Avšak výsledky klasifikací dle obou legend nelze zcela porovnávat z důvodu odlišného stanovení přesnosti. Vrstva mapování biotopů poskytnutá AOPK, která byla využita k určení přesnosti klasifikace Natury 2000, nemohla být využita také ke stanovení přesnosti klasifikace legendy stanovené botanikem. Důvodem byla odlišná definice kategorií obou legend.

Důležitým krokem při provádění klasifikace je sběr terénních vzorků, které slouží jako trénovací data (Debba et al. 2005). V ideálním případě by se měl sběr terénních dat uskutečnit současně s pořízením družicového snímku (Carle et al. 2011). Sběr terénních dat pro účely této diplomové práce se uskutečnil bezprostředně po pořízení snímku WorldView-2 v srpnu

2011. U každého terénního vzorku byly zaměřeny souřadnice pomocí přístroje GPS zhruba ve středu daného lučního společenstva. Při definování trénovacích ploch se ukázalo, že do budoucna by bylo lepší, aby byly terénní vzorky zaměřovány jako polygon a ne pouze jako bod, aby bylo přesně vymezeno, které pixely je možné zařadit do dané trénovací plochy.

Další doporučenou metodou pro klasifikaci luční vegetace je objektová klasifikace. Nebylo v zadání ani v časových možnostech zahrnout tuto metodu do diplomové práce. V návaznosti na tuto práci by objektová klasifikace mohla přinést zlepšení výstupů klasifikace například u managementových kategorií, u kterých je patrná typická textura (např. řádkování).

8 Použité zdroje

AOPK ČR (2011). *Vrstva mapování biotopů*. [elektronická georeferencovaná databáze]. Verze 2011. Praha. Agentura ochrany přírody a krajiny ČR. [citováno 2011-5-10]. Rozšíření přírodních a přírodě blízkých stanovišť na území ČR.

BENEDIKTSSON, J. A.; SVEINSSON, J. R. Multisource remote sensing data classification based on consensus and pruning. *IEE Transactions on Geoscience and Remote Sensing*. 2003, 41, s. 932-936.

CARLE, M. V.; SASSER, CH.; TWILLEY, R. *Mapping deltaic wetland vegetation at the species-level using WorldView-2 multispectral imagery*. Baton Rouge: Louisiana State University, 2011. Dostupné z: <http://dgl.us.neolane.net/res/img/b7e069481eb86a90e18bdfacc9fbff5d.pdf>.

CINGOLANI, A. M. et al. Mapping vegetation in a heterogeneous mountain rangeland using landsat data: an alternative method to define and classify land-cover units. *Remote Sensing of Environment*, 2004, 92, s. 84–97.

DE'ATH, G.; FABRICIUS, K. E. Classification and regression trees: a powerful yet simple technique for ecological data analysis. *Ecology*. 2000, 81, s. 3178-3192.

DEBBA, P. et al. Optimal field sampling for targeting minerals using hyperspectral data. *Remote Sensing of Environment*. 2005, 99, s. 373–386.

DOBROVOLNÝ, Petr. *Dálkový průzkum Země. Digitální zpracování obrazu*. Brno: Masarykova univerzita, 1998. 208 s.

DOBROWSKI, Solomon Z., et al. Mapping mountain vegetation using species distribution modeling, image-based texture analysis, and object-based classification. *Applied Vegetation Science*. 2008, 11, s. 499-508.

E-mailová korespondence se Stanislavem Březinou [online], 11. 8. 2012, sbrezina@knap.cz.

GITELSON, Anatoly A., KAUFMAN, Yoram J. a MERZLYAK, Mark N. Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS. *Remote Sensing of Environment*. 1996, 3, s. 289-298.

GITELSON, Anatoly A. a MERZLYAK, Mark N. Spectral Reflectance Changes Associated with Autumn Senescence of *Aesculus Hippocastanum* L. and *Acer Platanoides* L. Leaves. Spectral Features and Relation to Chlorophyll Estimation. *Journal of Plant Physiology*. 1994, 143, s. 286-292.

GOPAL, S.; WOODCOCK, C. Theory and Methods for Accuracy Assessment of Thematic Maps Using Fuzzy Sets. *Photogrammetric Engineering and Remote Sensing*. 1994, 60, s. 181-188.

HUETE, A.: A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*. 1988, 25, s. 295-309.

CHYTRÝ, Milan. Vegetace České republiky: Travná a keříčková vegetace. Praha: Academia, 2007.

JARKOVSKÝ, Jiří, LITTNEROVÁ, Simona. *Vícerozměrné statistické metody – Diskriminační analýza* [online]. 2011 [cit. 2012-07-26]. Dostupné z: <http://www.iba.muni.cz/esf/res/file/bimat-prednasky/vicerozmerne-statisticke-metody/VSM-08.pdf>.

JORDAN, C. F.: Derivation of leaf area index from quality of light on the forest floor. *Ecology*. 1969, 50, s. 663-666.

KANNIAH, K. D. *Worldview-2 remote sensing data for tropical mangrove species classification*. Johor: University of Technology Malaysia, 2011. Dostupné z: <http://dgl.us.neolane.net/res/img/379c93d0d06868e23081ad9d7d6ba3a9.pdf>.

KRAHULEC, František, et al. Louky Krkonoš: Rostlinná společenstva a jejich dynamika. *Opera Corcontica*. 1996, 33, s. 1-252.

KÝNOVÁ, Andrea. *Tvorba map druhů povrchů s využitím neuronových sítí*. Brno, 2010. Diplomová práce. Masarykova univerzita. Vedoucí práce doc. RNDr. Petr Dobrovolný, CSc.

LANGLEY, S. K.; CHESHIRE, H. M.; HUMES, K. S. A comparison of single date and multitemporal satellite image classifications in a semi-arid grassland. *Journal of Arid Environments*. 2001, 49, s. 401–411.

LAUVER, Chris L.; WHISTLER, Jerry L. A Hierarchical-Classification of Landsat TM Imagery to Identify Natural Grassland Areas and Rare Species Habitat. *Photogrammetric Engineering and Remote Sensing*. 1993, 5, s. 627-634.

Mapování vegetace s využitím družicových snímků [online]. [cit. 2012-08-13]. Dostupné z: http://www.sci.muni.cz/~dobro/zemsky_povrch_vegetace.html.

MCMAHAN, Ben; WEBER, Keith T.; SAUDER, Joel. *Fuzzy Classification of Heterogeneous Vegetation in a Complex Arid Ecosystem*. Pocatello: Idaho State University, 2003. Dostupné z: http://giscenter-ims.isu.edu/research/techpg/nasa_wildfire/Final_Report/Documents/Chapter7.pdf.

MOHANTY, K. K.; MAJUMDAR, T. J. An artificial neural network (ANN) based software package for classification of remotely sensed data. *Computers and Geosciences*. 1996, 1, s. 81-87.

MUTANGA, Onesimo, Elhadi ADAM a Azong Moses CHO. High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. *International Journal of Applied Earth Observation and Geoinformation*. 2012, č. 18.

PEŠKOVÁ, Lucie. *Diskriminační analýza*. Olomouc, 2009. Dostupné z: <http://mant.upol.cz/soubory/OdevzdanePrace/B09/b09-15-lp.pdf&pli=1>. Bakalářská práce. Univerzita Palackého v Olomouci. Vedoucí práce Mgr. Jana Vrbková.

PRICE, Kevin P.; GUO, Xulin; STILES, James M. Optimal Landsat TM band combinations and vegetation indices for discrimination of six grassland types in eastern Kansas. *International Journal of Remote Sensing*. 2002, 23, s. 5031–5042.

ROUSE, J. W., HAAS, R. H., SCHELL, J. A., and DEERING, D. W., 1973: Monitoring vegetation systems in the great plains with ERTS. Third ERTS Symposium. NASA SP-351 I: 309-317.

SALOVAARA, K. J. et al. Classification of Amazonian primary rain forest vegetation using Landsat ETM+ satellite imagery. *Remote Sensing of Environment*. 2005, 97, s. 39–51.

SHA, Z., et al. Using a hybrid fuzzy classifier (HFC) to map typical grassland vegetation in Xilin River Basin, Inner Mongolia, China. *International Journal of Remote Sensing*. 2008, 8, s. 2317–2337.

STUART, N.; BARRATT, T.; PLACE, C. Classifying the neotropical savannas of Belize using remote sensing and ground survey. *Journal of Biogeography*, 2006, 33, s. 476–490.

ZHANG, J.; FOODY, G. M. A fuzzy classification of sub-urban land cover from remotely sensed imagery. *International Journal of Remote Sensing*. 1998, 19, s. 2721–2738.

Internetové zdroje:

<http://www.digitalglobe.com>

<http://www.exelisvis.com>

<http://www.gisat.cz>

<http://www.krnap.cz>

<http://www.pcigeomatics.com>

Seznam příloh

Příloha 1 CD s elektronickou verzí práce

Příloha 2 Seznam vzorků zaměřených v terénu

Příloha 3 Náhled zářijového snímku WorldView-2 (v pravých barvách)

Příloha 4 Náhled srpnového snímku WorldView-2 (v pravých barvách)

Příloha 5 Klasifikace luční vegetace z dat WorldView-2 algoritmem maximální věrohodnosti v Krkonoších v září 2011

Příloha 6 Klasifikace luční vegetace z dat WorldView-2 algoritmem neuronových sítí v Krkonoších v srpnu 2011

Příloha 7 Klasifikace luční vegetace z dat WorldView-2 algoritmem maximální věrohodnosti v Krkonoších v srpnu 2011

Příloha 8 Klasifikace luční vegetace ze simulovaných dat Quickbird algoritmem neuronových sítí v Krkonoších v srpnu 2011

Příloha 9 Klasifikace luční vegetace dle biotopů Natura 2000 algoritmem neuronových sítí v Krkonoších v září 2011

Příloha 10 Klasifikace luční vegetace dle biotopů Natura 2000 algoritmem neuronových sítí v Krkonoších v srpnu 2011

Příloha 11 Chybová matice klasifikace zářijového snímku algoritmem neuronových sítí

Příloha 12 Chybová matice klasifikace zářijového snímku algoritmem max. věrohodnosti

Příloha 13 Chybová matice klasifikace srpnového snímku algoritmem neuronových sítí

Příloha 14 Chybová matice klasifikace srpnového snímku algoritmem max. věrohodnosti


Příloha 2 Seznam vzorků zaměřených v terénu

Northing	Easting	GNSS Height	Typ společenstva	Legenda
-988301,278	-638483,641	866,602	bohatá smilková louka (sileno nardetum)	3
-988323,388	-638565,875	847,781	pastvina	2
-988317,782	-638719,579	826,745	přechod mezi sileno nardetum a trojštětovou loukou	3/6
-988283,605	-638712,052	838,811	trojštětová louka	6
-988272,024	-638796,975	835,691	přechod mezi sileno nardetum a trojštětovou loukou	3/6
-988251,282	-638864,805	837,658	sileno nardetum	3
-988186,536	-638868,295	855,526	extrémně chudé sileno nardetum	3
-988221,160	-638929,559	843,613	chudá smilková louka	3
-988194,273	-639012,548	842,973	chudá smilková louka	3
-988168,215	-639083,743	843,359	vychudlá smilková louka na přechodu k vřesovištím	3
-988181,424	-639116,302	837,158	sileno nardetum	3
-988200,221	-639091,676	833,674	vychudlé sileno nardetum	3
-988205,858	-639167,059	824,566	vychudlé sileno nardetum	3
-988128,767	-639303,202	827,214	sileno nardetum s přechodem k trojštětovým loukám	3/6
-988166,277	-639328,536	821,608	přechod k trojštětovým loukám	6
-988188,448	-639360,330	823,219	sileno nardetum	3
-988167,979	-639368,047	830,781	sileno nardetum	3
-988180,078	-639450,358	837,784	sileno nardetum s přechodem k trojštětovým loukám	3/6
-988185,394	-639540,479	849,084	sileno nardetum s přechodem k trojštětovým loukám	3/6
-988304,848	-639422,788	809,681	sileno nardetum s přechodem k trojštětovým loukám	3/6
-988248,563	-639273,794	794,006	trojštětová louka	6
-988283,545	-639291,115	784,900	pcháčová louka	7
-987369,551	-639050,954	1055,500	sileno nardetum	3
-987348,872	-639080,633	1061,767	chudé sileno nardetum	3
-987419,666	-639124,512	1054,077	sileno nardetum	3
-987549,708	-639084,796	1018,299	sileno nardetum s pupavou	3
-987536,130	-639027,591	1088,845	ruderální vegetace se starčkem	4
-986335,899	-640301,926	1254,417	na hranici ruderálu	6
-986437,381	-640267,634	1242,798	arnico callunetum	5
-986431,139	-640288,530	1241,498	mezi sileno nardetum a sukcesí smrkového lesa	3/4
-985467,931	-643212,786	1062,950	sileno nardetum	3
-985394,097	-643228,456	1082,887	arnico callunetum	5
-985183,912	-643365,175	1153,843	degradační stadium smilkové louky	3
-986876,423	-643820,439	951,020	extrémně chudé sileno nardetum	3
-986905,102	-643828,996	951,574	chudé sileno nardetum	3
-986978,478	-643683,645	960,054	degradované silene nardetum	3
-987535,388	-642060,931	849,841	přechod mezi trojštětovou a pcháčovou loukou, část sileno nardetum	6
-990774,932	-641653,247	1115,241	zrašelinělé nardetum	3
-990785,168	-641688,396	1114,151	zrašelinělé nardetum	3
-990776,778	-641733,780	1113,376	degradační fáze podmáčených luk se starčkem a kýchavicí	4
-990745,810	-641738,283	1116,453	pcháčová louka	7
-988879,940	-644130,368	1204,410	šřovikoviště	4

-988628,652	-644172,618	1238,346	degradovaná vlhká louka	4
-989750,997	-643450,251	1093,725	chudé sileno nardetum	3
-989771,194	-643486,013	1091,588	kulturní melandrio phleetum	8
-985676,514	-642080,202	899,676	trojštětová smilková louka	6
-985652,959	-642091,827	900,147	rašelinná louka	7
-987480,077	-641842,247	857,437	eurotrávník	8
-987543,941	-641846,310	847,510	kulturní louka přechod k sileno nardetu	3
-985775,097	-644187,423	1192,328	borůvkoviště	5
-985750,064	-644216,378	1200,646	poslední stádium degradace smilkových trávníků v sukcesi lesa	4
-985770,012	-644309,124	1202,775	přechod mezi solidago nardetum a sileno nardetum	3
-985918,050	-644341,907	1159,852	degradační stadium smilkové louky s dominantní lipnicí chaixovou	3
-985885,933	-644244,546	1165,453	arnico callunetum	5
-985911,000	-645560,127	1341,760	solidagini nardetum	3
-985956,852	-645555,106	1339,432	solidagini nardetum typické	3
-985990,502	-645538,377	1337,861	degradační fáze s deschampsii	4
-985927,580	-646314,538	1292,537	rašeliniště	7
-985693,618	-646847,946	1210,561	ruđerál s převahou vrbovky	4
-985641,771	-646973,389	1200,182	pastvina, kde byl aplikován roundup na šťovík	2
-985786,728	-646756,789	1211,722	rumexoviště	4
-985896,752	-646270,744	1302,191	slatiništní rašeliniště nevápněné	7
-986309,729	-645787,906	1338,659	solidagini nardetum (s rezervou)	3
-987458,413	-647561,658	1169,693	melandrio-phleetum	8
-992983,020	-649146,425	579,701	trojštětová louka s ovsíkem	6

Příloha 3 Náhled zářijového snímku WorldView-2 (v pravých barvách)


DRUŽICOVÝ SNÍMEK WORLDVIEW-2
oblast Krkonoš v září 2011



Michaela POMHAČOVÁ
Praha 2012

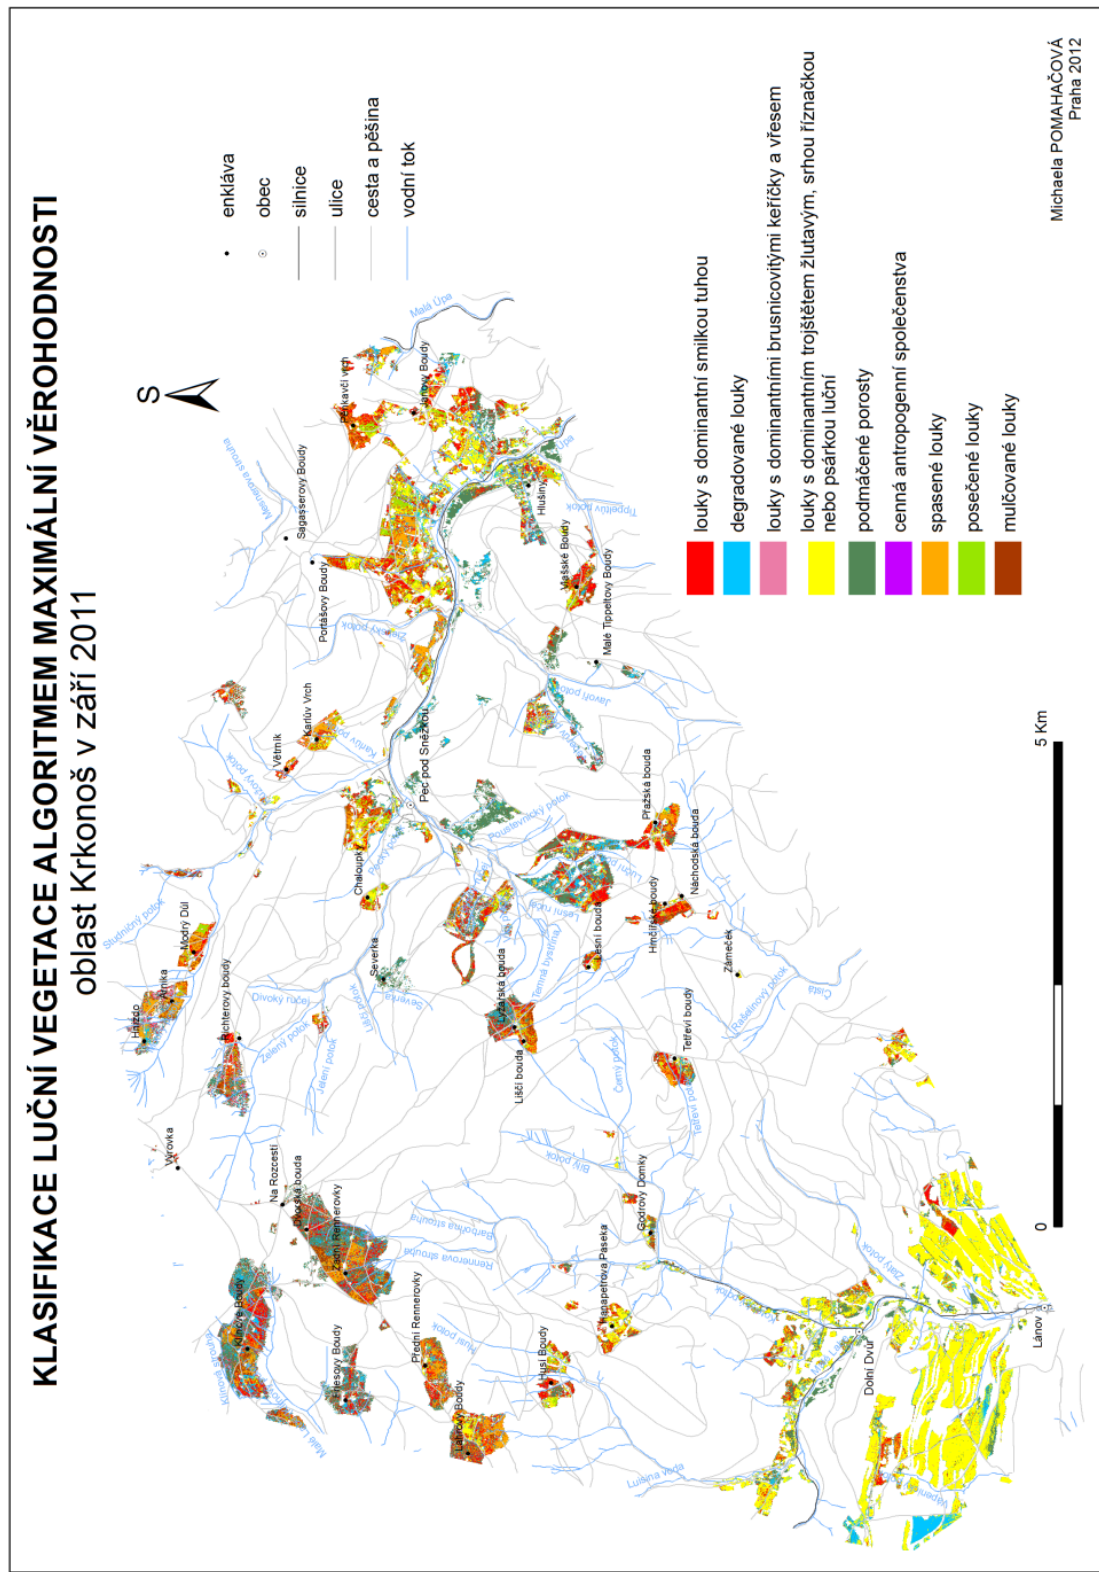
Příloha 4 Náhled srpnového snímku WorldView-2 (v pravých barvách)

DRUŽICOVÝ SNÍMEK WORLDVIEW-2
oblast Krkonoš v srpnu 2011

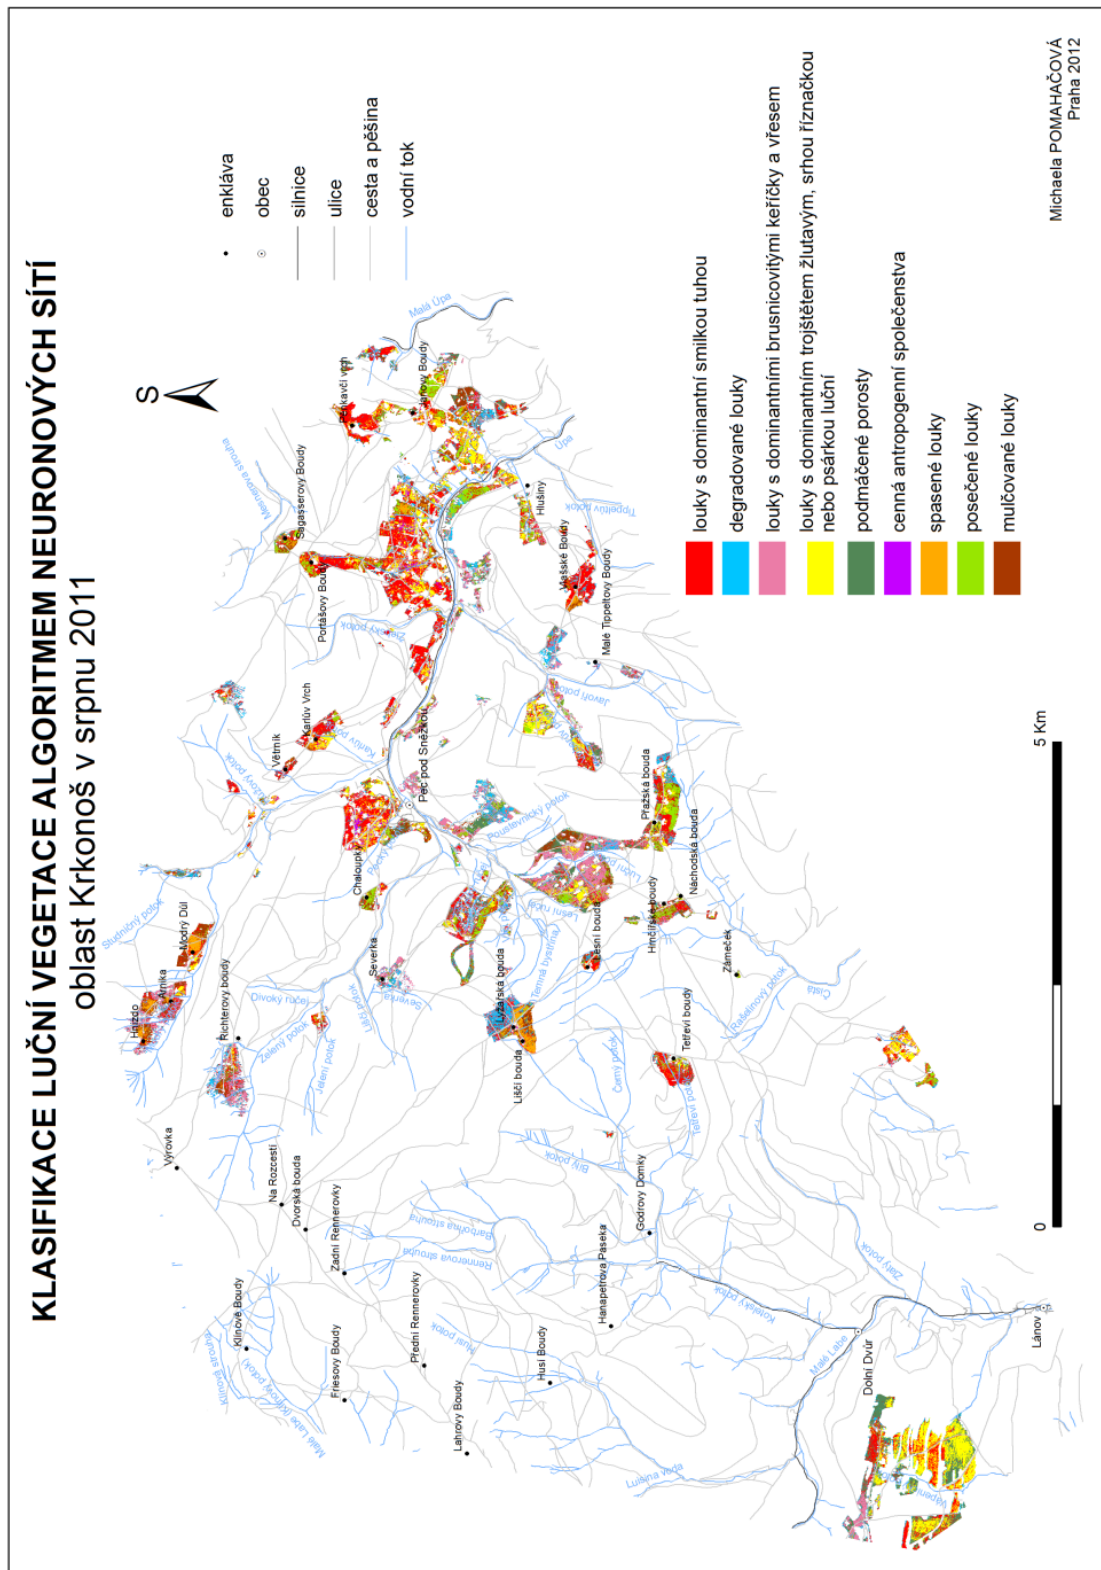


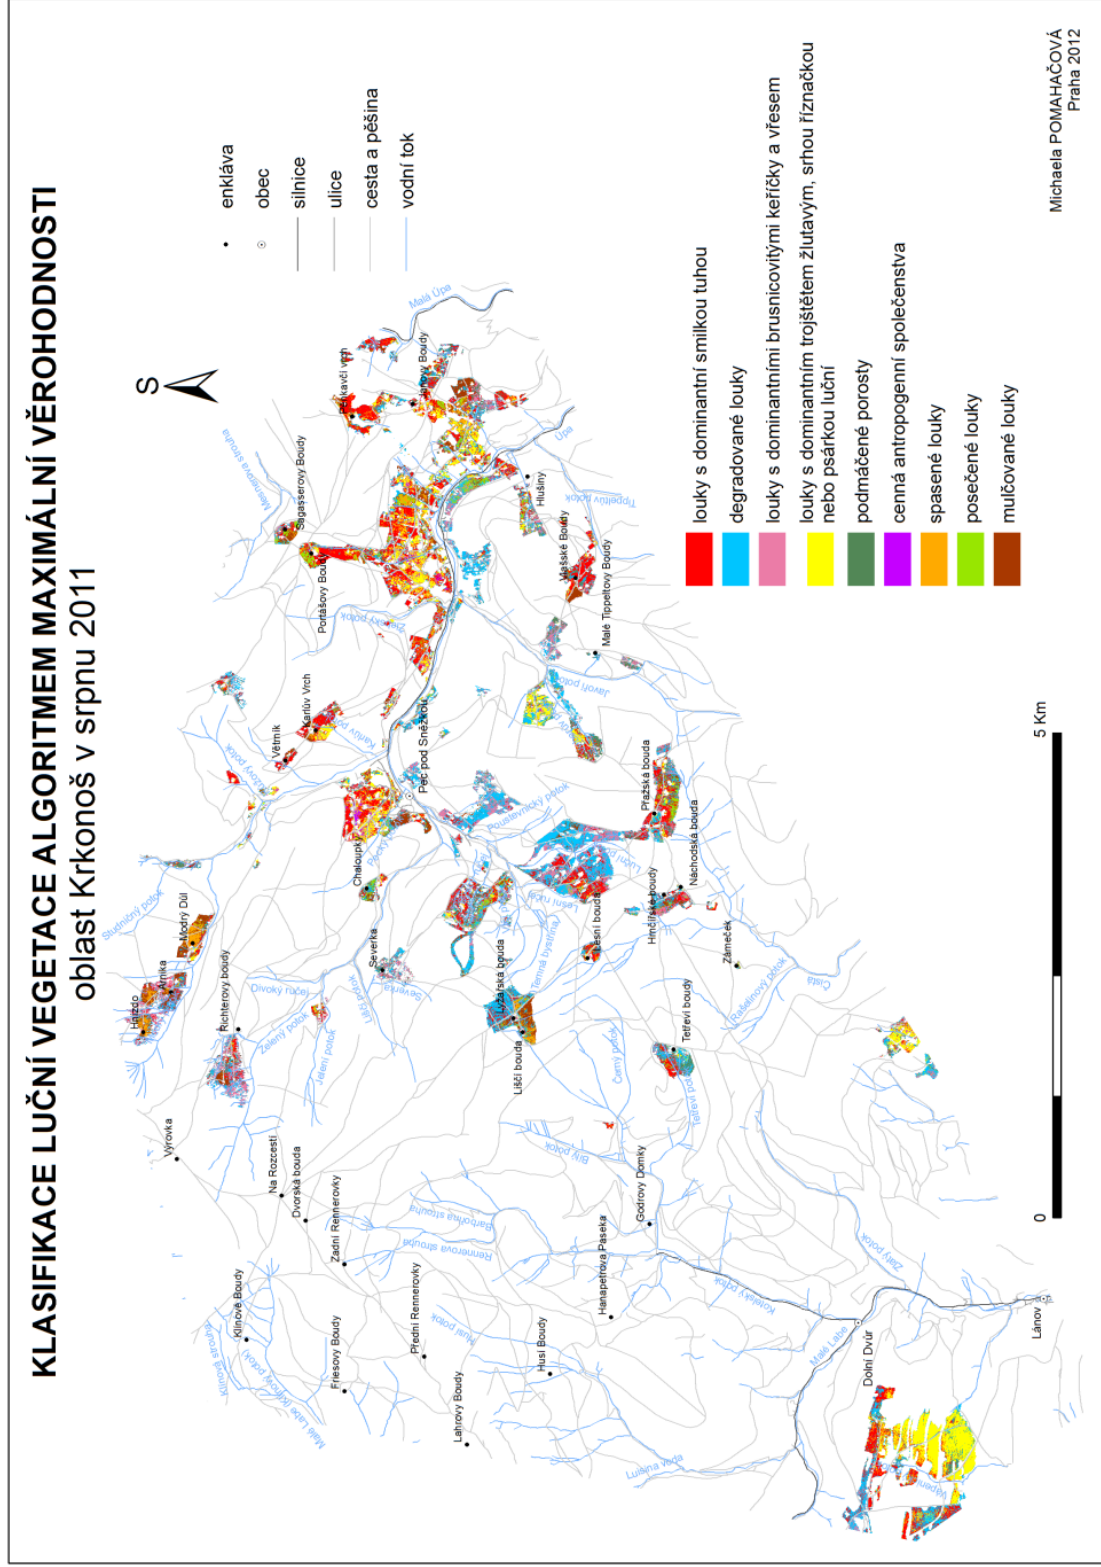
Michaela POMAHOVÁ
Praha 2012

Příloha 5 Klasifikace luční vegetace z dat WorldView-2 algoritmem maximální věrohodnosti v Krkonoších v září 2011

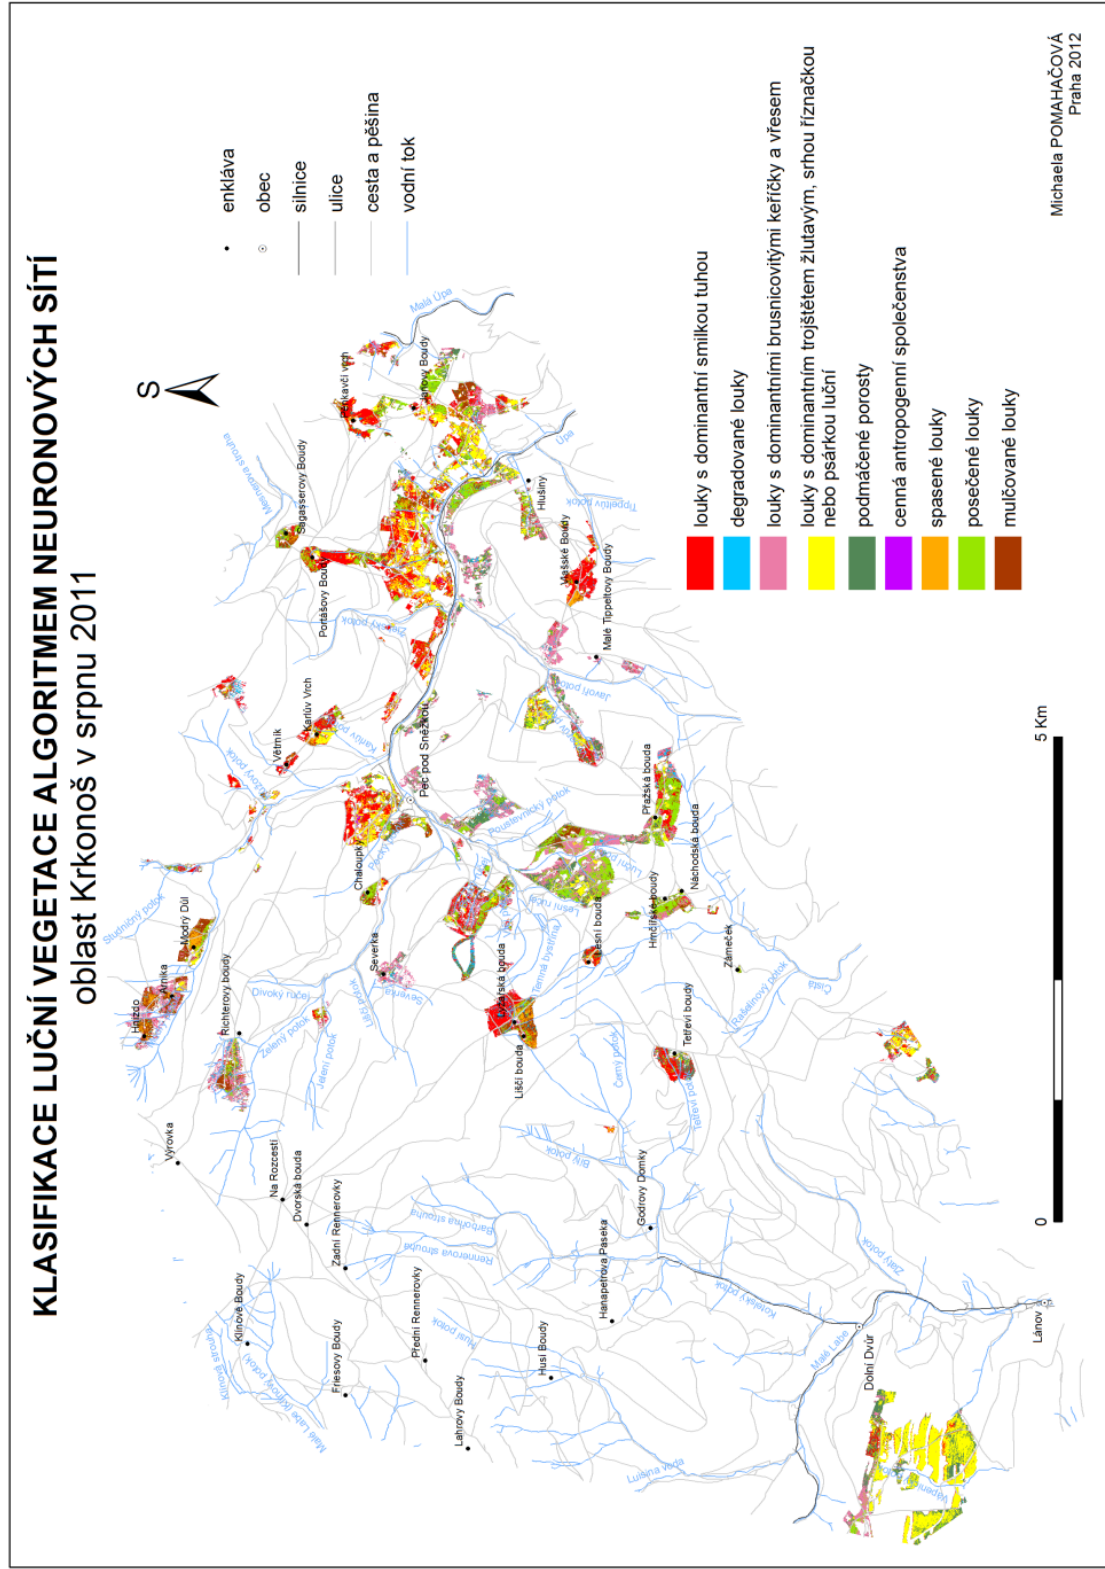


Příloha 6 Klasifikace luční vegetace z dat WorldView-2 algoritmem neuronových sítí v Krkonoších v srpnu 2011

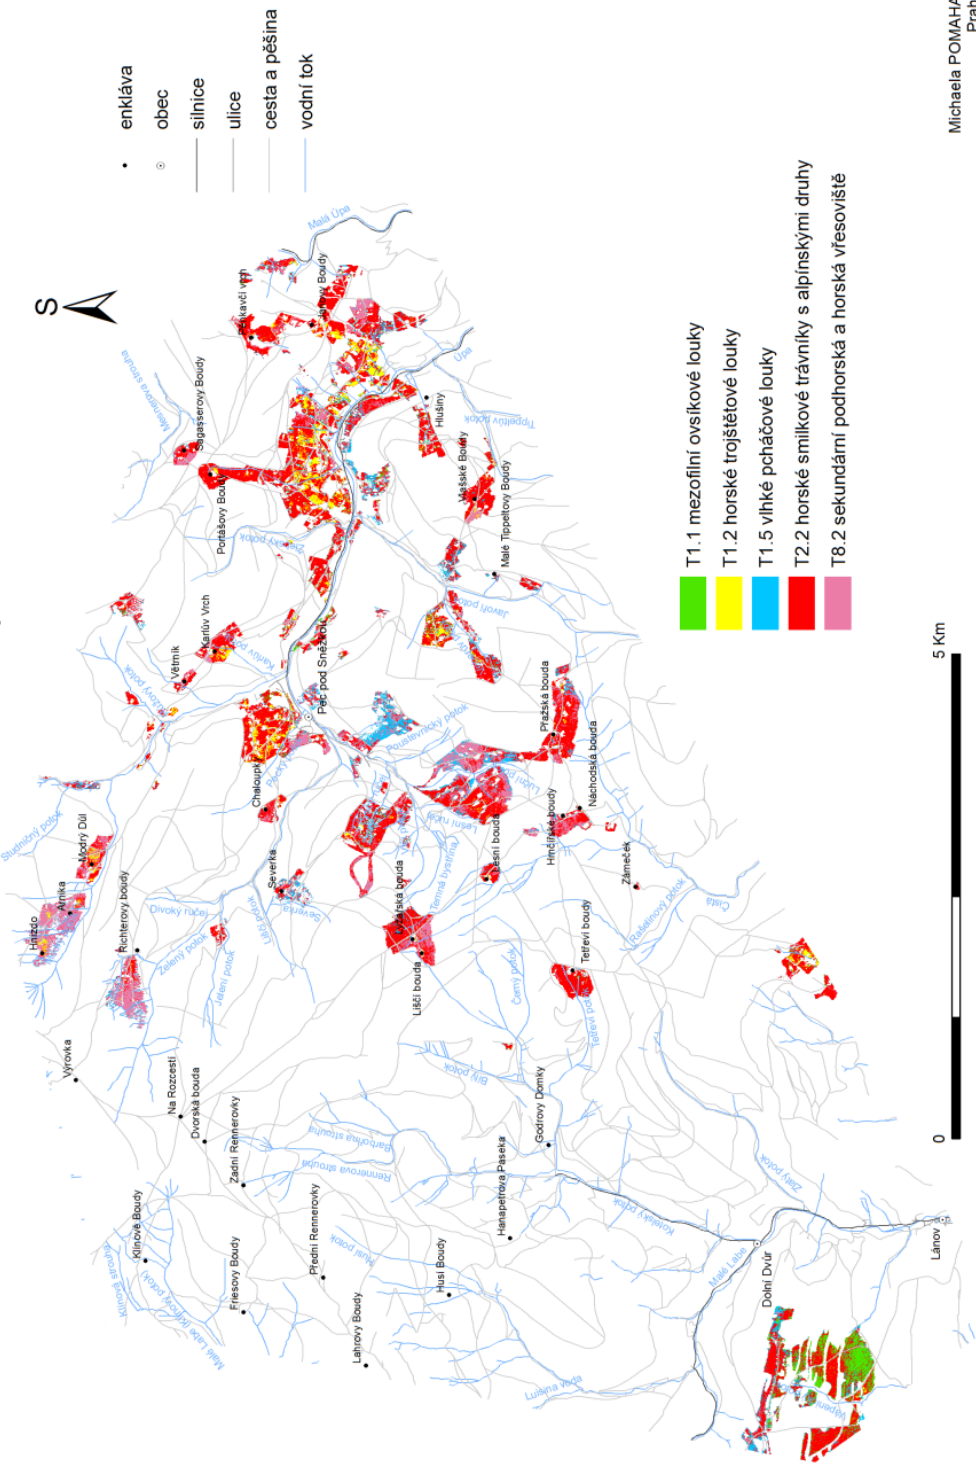




Příloha 8 Klasifikace luční vegetace ze simulovaných dat Quickbird algoritmem neuronových sítí v Krkonoších v srpnu 2011



KLASIFIKACE LUČNÍ VEGETACE DLE NATURE 2000 ALGORITMEM NEURONOVÝCH SÍTÍ oblast Krkonoš v srpnu 2011



Příloha 11 Chybová matice klasifikace zářijového snímku algoritmem neuronových sítí

Overall Accuracy = (4280/4696) 91.1414%

Kappa Coefficient = 0.8957

Ground Truth (Pixels)

Class	antropogenni	brusnicovite	degradovane	mulcovane	nardus stricta
Unclassified	0	0	0	1	0
antropogenni	108	0	6	0	0
brusnicovite	0	321	61	0	0
degradovane	1	5	597	0	2
mulcovane	0	0	0	231	0
nardus stricta	14	19	25	12	1197
pasene	0	0	9	11	1
podmacene	0	3	28	0	0
posekane	0	0	4	0	32
trojstetove	31	0	4	0	0
Total	154	348	734	255	1232

Ground Truth (Pixels)

Class	pasene	podmacene	posekane	trojstetove	Total
Unclassified	0	0	0	0	1
antropogenni	0	0	0	0	114
brusnicovite	0	11	0	0	393
degradovane	0	15	0	0	620
mulcovane	0	4	0	0	235
nardus stricta	1	41	24	2	1335
pasene	362	5	5	0	393
podmacene	17	397	0	0	445
posekane	22	0	445	0	503
trojstetove	0	0	0	622	657
Total	402	473	474	624	4696

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
antropogenni	70.13	94.74	108/154	108/114
brusnicovite	92.24	81.68	321/348	321/393
degradovane	81.34	96.29	597/734	597/620
mulcovane	90.59	98.30	231/255	231/235
nardus stricta	97.16	89.66	1197/1232	1197/1335
pasene	90.05	92.11	362/402	362/393
podmacene	83.93	89.21	397/473	397/445
posekane	93.88	88.47	445/474	445/503
trojstetove	99.68	94.67	622/624	622/657

(Zdroj: ENVI 4.7, úpravy: vlastní)

Příloha 12 Chybová matice klasifikace zářijového snímku algoritmem max. věrohodnosti

Overall Accuracy = (3927/4695) 83.6422%

Kappa Coefficient = 0.8085

Ground Truth (Pixels)

Class	antropogenni	brusnicovite	degradovane	mulcovane	nardus stricta
Unclassified	0	0	0	0	0
antropogenni	154	0	0	0	0
brusnicovite	0	314	75	0	0
degradovane	0	1	374	0	3
mulcovane	0	1	0	253	0
nardus stricta	0	20	180	0	1036
pasene	0	2	10	0	11
podmacene	0	10	79	1	22
posekane	0	0	0	0	135
trojstetove	0	0	16	0	25
Total	154	348	734	254	1232

Ground Truth (Pixels)

Class	pasene	podmacene	posekane	trojstetove	Total
Unclassified	0	0	0	0	0
antropogenni	0	0	0	0	154
brusnicovite	0	2	0	0	391
degradovane	0	0	0	3	381
mulcovane	0	4	0	0	258
nardus stricta	0	5	1	56	1298
pasene	310	7	5	0	345
podmacene	0	455	0	0	567
posekane	92	0	468	2	697
trojstetove	0	0	0	563	604
Total	402	473	474	624	4695

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
antropogenni	100.00	100.00	154/154	154/154
brusnicovite	90.23	80.31	314/348	314/391
degradovane	50.95	98.16	374/734	374/381
mulcovane	99.61	98.06	253/254	253/258
nardus stricta	84.09	79.82	1036/1232	1036/1298
pasene	77.11	89.86	310/402	310/345
podmacene	96.19	80.25	455/473	455/567
posekane	98.73	67.14	468/474	468/697
trojstetove	90.22	93.21	563/624	563/604

(Zdroj: ENVI 4.7, úpravy: vlastní)

Příloha 13 Chybová matice klasifikace srpnového snímku algoritmem neuronových sítí

Overall Accuracy = (5743/6329) 90.7410%

Kappa Coefficient = 0.8914

Ground Truth (Pixels)

Class	antropogenni	brusnicovite	degradovane	mulcovane	nardus_stricta
Unclassified	0	3	0	1	0
antropogenni	317	0	0	0	0
brusnicovite	0	335	0	0	27
degradovane	0	7	279	3	32
mulcovane	0	0	0	351	0
nardus_stricta	20	9	39	0	1520
pasene	0	0	17	59	0
podmacene	2	4	0	0	27
posekane	0	0	25	0	0
trojstetove	48	0	0	0	37
Total	387	358	360	414	1643

Ground Truth (Pixels)

Class	pasene	podmacene	posekane	trojstetove	Total
Unclassified	0	45	0	0	49
antropogenni	7	0	0	27	351
brusnicovite	0	2	14	0	378
degradovane	0	21	2	0	344
mulcovane	0	0	1	0	352
nardus_stricta	31	0	50	8	1677
pasene	832	0	11	0	919
podmacene	0	537	0	0	570
posekane	0	0	672	0	697
trojstetove	7	0	0	900	992
Total	877	605	750	935	6329

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
antropogenni	81.91	90.31	317/387	317/351
brusnicovite	93.58	88.62	335/358	335/378
degradovane	77.50	81.10	279/360	279/344
mulcovane	84.78	99.72	351/414	351/352
nardus_stricta	92.51	90.64	1520/1643	1520/1677
pasene	94.87	90.53	832/877	832/919
podmacene	88.76	94.21	537/605	537/570
posekane	89.60	96.41	672/750	672/697
trojstetove	96.26	90.73	900/935	900/992

(Zdroj: ENVI 4.7, úpravy: vlastní)

Příloha 14 Chybová matice klasifikace srpnového snímku algoritmem max. věrohodnosti

Overall Accuracy = (5693/6280) 90.6529%

Kappa Coefficient = 0.8913

Ground Truth (Pixels)

Class	nardus_stricta	degradovane	brusnicovite	trojstetove	podmacene
Unclassified	0	0	0	0	0
nardus_stricta	1352	32	0	4	8
degradovane	29	318	0	7	0
brusnicovite	96	0	355	0	0
trojstetove	102	0	0	850	0
podmacene	23	10	0	0	552
antropogenni	6	0	0	74	0
mulcovane	9	0	0	0	0
pasene	3	0	0	0	0
posekane	23	0	0	0	0
Total	1643	360	355	935	560

Ground Truth (Pixels)

Class	antropogenni	mulcovane	pasene	posekane	Total
Unclassified	0	0	0	0	0
nardus_stricat	3	0	25	0	1424
degradovane	0	0	0	8	362
brusnicovite	0	0	0	26	477
trojstetove	17	0	20	0	989
podmacene	0	0	0	0	585
antropogenni	367	0	0	0	447
mulcovane	0	413	23	0	445
pasene	0	0	775	5	783
posekane	0	0	34	711	768
Total	387	413	877	750	6280

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
nardus_stricta	82.29	94.94	1352/1643	1352/1424
degradovane	88.33	87.85	318/360	318/362
brusnicovite	100.00	74.42	355/355	355/477
trojstetove	90.91	85.95	850/935	850/989
podmacene	98.57	94.36	552/560	552/585
antropogenni	94.83	82.10	367/387	367/447
mulcovane	100.00	92.81	413/413	413/445
pasene	88.37	98.98	775/877	775/783
posekane	94.80	92.58	711/750	711/768

(Zdroj: ENVI 4.7, úpravy: vlastní)