

UNIVERZITA KARLOVA V PRAZE
Přírodovědecká fakulta
Katedra aplikované geoinformatiky a kartografie



**VYUŽITÍ MULTISPEKTRÁLNÍCH DRUŽICOVÝCH DAT
PRO KLASIFIKACI LESNÍCH POROSTŮ
POŠKOZENÝCH DISTURBANCEMI**

**CLASSIFICATION OF FOREST DAMAGED BY DISTURBANCE
USING MULTISPECTRAL SATELLITE DATA**

Diplomová práce

Bc. Barbora Šmausová

srpen 2016

Vedoucí diplomové práce: RNDr. Přemysl Štych, Ph.D.

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

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

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

V Jablonci nad Nisou dne 4. srpna 2016

.....

Barbora Šmausová

Poděkování

Na tomto místě bych ráda poděkovala všem, kteří mi poskytli podklady pro vypracování této práce. Zvláště děkuji svému vedoucímu RNDr. Přemyslu Štychovi, PhD. za odborné vedení a konzultování diplomové práce, za jeho vstřícnost, trpělivost a za veškeré cenné rady a připomínky. V neposlední řadě je mou milou povinností poděkovat svým rodičům, příteli a přátelům za morální a materiální podporu, které se mi dostávalo po celou dobu studia.

Využití multispektrálních družicových dat pro klasifikaci lesních porostů poškozených disturbancemi

Abstrakt

Hlavním cílem diplomové práce je vytvoření metodického postupu vhodného pro klasifikaci poškozených lesních porostů na vybraném území Národního parku Šumava. K tomuto účelu jsou využity multispektrální snímky WorldView-2 a Landsat 8. Práce klade důraz na odlišení jednotlivých fází vývoje lesa postiženého lýkožroutem smrkovým. Dle zvolené legendy, zahrnující více fází rozpadajícího se i obnovujícího se lesa, jsou snímky klasifikovány metodami Neural Network, Support Vector Machine a objektovou klasifikací. Následná aplikace těchto metod na zvolené snímky vyžadovala vhodný výběr parametrů a pravidel k dosažení optimálních výsledků. Výsledky práce porovnávají a hodnotí výsledné klasifikace. Dalším výstupem práce je zhodnocení vlivu zpracovávaných snímků WorldView-2 a Landsat 8 na výsledný výstup klasifikace. Veškeré výsledky práce jsou hodnoceny pomocí celkové přesnosti, chybových matic a kappa koeficientu.

Klíčová slova: lesní porost, disturbance, NP Šumava, WorldView-2, Landsat 8

Classification of forests damaged by disturbance using multispectral satellite data

Abstract

The main objective of this thesis is to create an appropriate methodological procedure for classifying damaged forest in the selected area of Šumava National Park. For this purpose, multispectral imagery WorldView-2 and Landsat 8 are used. Work emphasis on distribution of each phase of forest development affected by bark beetle. According to selected legend, involving multiple stages of damaged but also recovering forest, the images are classified by Neural Network, Support Vector Machine and object classification methods. Application of these methods on selected images required a suitable choice of parameters and rules to achieve optimal results. The results of this thesis compare and evaluate the final classification. Another outcome of this work is to evaluate the influence of the processed images WorldView-2 and Landsat 8 on the final classification performance. All work results are assessed by overall precision, error matrix and kappa coefficient.

Key words: forest, disturbance, NP Šumava, WorldView-2, Landsat 8

OBSAH

PŘEHLED POUŽITÝCH ZKRATEK	7
SEZNAM MAP, OBRÁZKŮ A TABULEK	8
1 ÚVOD A CÍLE PRÁCE	10
2 ÚVOD DO PROBLEMATIKY	12
2.1 Principy dálkového průzkumu Země	12
2.2 Využití DPZ při výzkumu lesních porostů.....	13
2.3 Disturbance a zdravotní stav lesní vegetace.....	14
2.4 Spektrální projev vegetace	16
2.4.1 Zářivé vlastnosti krajinných prvků.....	16
2.4.2 Vegetační indexy	18
2.4.3 Spektrální projev vegetace narušené disturbancemi.....	20
2.5 Klasifikace.....	20
2.5.1 Pixelová klasifikace.....	21
2.5.2 Neřízená klasifikace	21
2.5.3 Řízená klasifikace.....	21
2.5.4 Objektová klasifikace	24
2.5.5 Klasifikace lesních porostů poškozených disturbancemi	25
3 ZÁJMOVÉ ÚZEMÍ	27
4 DATA A METODY	29
4.1 Použitá data	29
4.2 Použitý software.....	31
4.3 Předzpracování dat	32
4.4 Klasifikace.....	34
4.4.1 Legenda	34
4.4.2 Trénovací množina	38
4.4.3 Support Vector Machine.....	39
4.4.4 Neural Networks.....	40
4.4.5 Segmentace.....	41

4.4.6 Tvorba klasifikační báze.....	44
4.5 Hodnocení přesnosti.....	46
5 VÝSLEDKY	48
5.1 Porovnání přesnosti klasifikací obrazových dat.....	48
5.2 Výsledky klasifikací snímku WorldView-2 a Landsat 8	50
5.3 Porovnání relativního zastoupení tříd v klasifikaci.....	52
6 DISKUZE	55
6.1 Data	55
6.2 Legenda	55
6.3 Postup a výsledky.....	57
7 ZÁVĚR.....	61
POUŽITÉ ZDROJE INFORMACÍ	63
SEZNAM PŘÍLOH.....	69

PŘEHLED POUŽITÝCH ZKRATEK

DPZ	Dálkový Průzkum Země
EVI	Enhanced Vegetation Index
L8	Landsat 8
NDVI	Normalized Difference Vegetation Index
NIR	Near-Infrared
NN	Neural Network
OBIA	Object Based Image Analysis
RBF	Radial Basis Function
RGI	Red-Green Index
ROI	Region Of Interest
SAVI	Soil-Adjusted Vegetation Index
SVM	Support Vector Machine
SWIR	Short-Wave Infrared
TVI	Transformed Ratio Vegetation Index
VHR	Very High Resolution
VI	Vegetation Index
WV2	WorldView-2

SEZNAM MAP, OBRÁZKŮ A TABULEK

Graf 1:	Relativní zastoupení tříd v klasifikacích SVM a NN	54
Obrázek 1:	Dělení elektromagnetického spektra	12
Obrázek 2:	Spektrální křivka odrazivosti listu	17
Obrázek 3:	Spektrální křivka odrazivosti lesní vegetace	18
Obrázek 4:	Princip Support Vector Machine	22
Obrázek 5:	Schéma neuronové sítě	23
Obrázek 6:	Poloha zájmového území v ČR	27
Obrázek 7:	Spektrální pásma družice WorldView-2	29
Obrázek 8:	Poloha nasbíraných bodů před ortorektifikací	32
Obrázek 9:	Poloha nasbíraných bodů po ortorektifikaci	33
Obrázek 10:	Letecký snímek a fotografie třídy A1	35
Obrázek 11:	Letecký snímek a fotografie třídy A2	36
Obrázek 12:	Letecký snímek a fotografie třídy A3	36
Obrázek 13:	Letecký snímek a fotografie třídy A4	37
Obrázek 14:	Letecký snímek a fotografie třídy B	37
Obrázek 15:	Letecký snímek a fotografie třídy C1	37
Obrázek 16:	Tvarová heterogenita s vyznačenými problémovými segmenty	43
Obrázek 17:	Scale parametr s vyznačením problémových segmentů	44
Obrázek 18:	Zobrazení tříd A4 a A2 v nástroji Sample editor	45
Obrázek 19:	Rozlišení třídy A4 a C1 klasifikací OBIA a SVM	51
Obrázek 20:	Rozlišení třídy A1 a A3 klasifikací OBIA a NN	51
Obrázek 21:	Rozlišení třídy B klasifikací SVM	52
Obrázek 22:	Třída E dle klasifikace SVM a OBIA snímku WV2	53
Tabulka 1:	Spektrální pásma družice WorldView-2	30
Tabulka 2:	Spektrální pásma družice Landsat 8	31
Tabulka 3:	Použité vegetační indexy	34
Tabulka 4:	Trénovací body	39

Tabulka 5:	Kernelovy transformace	39
Tabulka 6:	Aplikované parametry SVM na snímky L8 a WV2	40
Tabulka 7:	Aplikované parametry NN na snímky L8 a WV2	41
Tabulka 8:	Parametry segmentace snímků L8 a WV2	43
Tabulka 9:	Kontrolní body	47
Tabulka 10:	Celková přesnost a Kappa index klasifikace SVM	48
Tabulka 11:	Celková přesnost a Kappa index klasifikace NN	49
Tabulka 12:	Celková přesnost a Kappa index klasifikace OBIA	50
Tabulka 13:	Relativní zastoupení tříd u klasifikací snímku WV2	53

1 ÚVOD A CÍLE PRÁCE

Stav lesních porostů v Čechách i v zahraničí je výsledkem složitého historického vývoje zahrnujícího kulturní, hospodářské i politické aspekty na straně jedné a fyzickogeografické podmínky na straně druhé. V minulosti byl hlavní význam lesů viděn v jejich hospodářské funkci zdroje dřeva. Současné vnímání lesních porostů spíše směřuje k pochopení jejich velkého významu pro krajinu. Jejich vliv na životní prostředí je tak významný, že je nezbytné tyto ekosystémy stále více sledovat a monitorovat jejich stav a změny, zdravotní stav i vazby na okolní prostředí.

Pro účely sledování lesních porostů je vhodné využít právě obrazová data dálkového průzkumu Země (DPZ). Jejich výhoda spočívá v získávání informací z rozsáhlého území k jednomu datu a v možnosti jednotného vyhodnocování dat pro celou sledovanou plochu, což je, oproti využití klasického pozemního šetření, časově i materiálně velmi úsporné. Jednou z nejvýznamnějších aplikací DPZ v lesnictví je analýza zdravotního stavu lesní vegetace. Pro tento účel jsou nejčastěji využívány infračervené letecké snímky, případně multispektrální satelitní data. Zcela aktuální jsou pak snahy o využití družicových snímků s vysokým a velmi vysokým prostorovým rozlišením jako Sentinel-2, IKONOS, QuickBird nebo WorldView.

Jedním ze základních přístupů, jak lesní porosty monitorovat a získat informace o jejich stavu, je klasifikace prostorových dat. Klasifikace lesních porostů je vždy odvozená od účelu, kterému má ve výsledku sloužit a také odpovídá datům, na jejichž podkladě bude klasifikace vykonána. Pro mnoho účelů je tak dostačující vymezení základních kategorií lesního porostu (listnatý, jehličnatý a smíšený les), jejichž definice je možné považovat za ustálené a relativně přesně definované. Poněkud jiná situace nastane, pokud les zasáhnou disturbační události, které narušují stabilitu lesních ekosystémů a zvýší heterogenitu vegetačního pokryvu. V tomto případě vyvstává požadavek na detailnější klasifikaci lesa pro účely stanovení aktuálního stavu či predikce vývoje lesní vegetace. Požadavky se týkají především určení jednotlivých vývojových stádií lesa nebo míry poškození (či obnovy) lesa. Právě v tomto případě je na místě použít data velmi vysokého prostorového rozlišení a pokročilejších klasifikačních metod (např. Support Vector Machine), jelikož mnohé požadované třídy se díky vysoké heterogenitě a dynamice poškozeného lesa ne zcela přirozeně určují na podkladě tradičně užívaných dat a metod. Mnohé porosty jsou obtížně určitelné a pro jejich finální zařazení je zapotřebí terénní výzkum, testování, hledání správných spektrálních příznaků a expertní hodnocení přesnosti klasifikace.

Hlavní cíle této diplomové práce vychází z aktuálních témat diskutovaných v literatuře i z aktuálního dění na území NP Šumava. Napadení lesa lýkožroutem smrkovým v NP Šumava nabízí ideální příležitost, jak rozvinout a otestovat myšlenku

klasifikace poškozeného lesního porostu pomocí dat DPZ, viz např. Hart a Veblen (2015). Hlavním cílem diplomové práce je tedy vytvoření metodického postupu vhodného pro klasifikaci poškozených lesních porostů na vybraném území Národního parku Šumava za použití multispektrálních dat WorldView-2 a Landsat 8. Práce klade důraz na rozlišení jednotlivých fází vývoje lesa postiženého kůrovcem a umožní tak detailnější vyhodnocení stavu území zasaženého v minulých letech disturbancemi. Sledované kategorie jsou stanoveny na základě terénního výzkumu, vhodnosti datových vstupů a rešerše relevantní odborné literatury. Při stanovení klasifikační nomenklatury se též braly v potaz názory potencionálních koncových uživatelů, jako např. hydrologů či ochránců přírody.

Z metodického hlediska je hlavním úkolem definování trénovací množiny a vhodný výběr parametrů vstupujících do klasifikace algoritmy Support Vector Machine a Neural Networks. Dále pak tvorba klasifikační báze, která přesně stanovuje jednotlivé parametry vedoucí k určení definovaných kategorií v objektové klasifikaci. Dalším cílem práce je porovnání a zhodnocení použitých pokročilých klasifikačních metod Support Vector Machine, Neural Networks a objektové klasifikace. Důležitou součástí diplomové práce je též zhodnocení vlivu vstupních dat na výslednou klasifikaci.

Do výzkumu se vstupovalo s těmito následujícími hypotézami:

- Projev tříd lesních porostů v různých stupních jejich poškození a obnovy bude velmi podobný a jejich rozlišení bude tím pádem obtížnější.
- Výsledná klasifikace snímku WorldView-2 bude vzhledem k jeho prostorovému rozlišení detailnější a přesnější oproti klasifikaci snímku Landsat 8.
- Největší vliv na výsledek klasifikací SVM a NN bude mít volba vstupních parametrů a trénovací množiny, stejně tak jako u objektové klasifikace definování segmentů a výběr vhodných pravidel pro klasifikační bázi.

Text práce je rozdělen do sedmi částí. Po úvodním představení práce následuje část teoretická, kde je čtenář seznámen s problematikou hodnocení lesních porostů pomocí dálkového průzkumu Země. Dále tato část obsahuje stručný popis klasifikačních algoritmů použitých v rámci práce. Následuje popis zkoumaného území, na který navazuje další část textu popisující použitá data a metody. Hlavní část práce se věnuje popisu a diskusi použitých metod a dosažených výsledků. Závěr práce pak shrnuje nejdůležitější dosažené poznatky.


2 ÚVOD DO PROBLEMATIKY

2.1 Principy dálkového průzkumu Země

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

Prostředníkem, který dokáže přenést informaci mezi zkoumaným objektem a naším okem či senzorem v měřicí aparatuře, je v dálkovém průzkumu Země povětšinou *elektromagnetické záření* (Dobrovolný, 1998). Elektromagnetické záření vzniká zrychleným nebo zpomaleným pohybem nabitých částic. Z toho vyplývá, že různé druhy elektromagnetického záření lze odlišit jejich vlnovou délkou, souhrnně je nazýváme elektromagnetické spektrum. To je možné dělit dle jeho vlastností do několika kategorií (viz Obrázek 1).

Obrázek 1: Dělení elektromagnetického spektra



Zdroj: URL 1

V DPZ je nejvíce využíván střed spektra zahrnující záření od ultrafialového po mikrovlnné. *Ultrafialové záření*, jehož užití je velmi omezeno díky jeho rozptylu v atmosféře, se využívá především v oblasti geologie např. při detekci ložisek kovů.

Velmi důležitým aktérem v procesu dálkového průzkumu Země je lidský zrak, ten reaguje na oblast spektra nazývanou *viditelné záření*. Ač je oblast relativně úzká, je velmi důležitá. Nachází se v ní maximum vyzařování Slunce a zároveň viditelné záření velmi dobře prostupuje atmosférou, což ho činí lépe použitelným při dalším zpracování (Kolář, Halounová, Pavelka, 1997).

Intervaly spektra viditelného záření jsou rozpoznatelné i lidským okem, které je vnímá jako různé spektrální barvy. Viditelné světlo je složeno z fialové, modré, zelené, žluté, oranžové a červené barvy v intervalu vlnové délky $0,4 \mu\text{m} - 0,7 \mu\text{m}$. Základ těchto barev je tvořen modrou, zelenou a červenou, jejich skládáním lze získat zbylé

barvy spektra. Principu skládání barev se využívá při digitální prezentaci obrazu, kde intenzita vyzářování tří zářičů (R = red, G = green, B = blue) tvoří výsledný obraz.

Infračervené záření je v porovnání s ostatními poměrně širokou oblastí spektra. Interval od 0,72 μm do 3000 μm , zahrnuje pět kategorií, z nichž čtyři jsou pro DPZ velmi důležité. Blízké infračervené záření (NIR) je významný ukazatel při studiu vegetace. V intervalu vlnové délky 0,72 μm – 1,3 μm dochází u rostlin k vysoké odrazivosti, proto je NIR využíváno v oblastech lesnictví, zemědělství či např. ekologie. Krátkovlnné záření (SWIR) nachází vhodné využití při detekci vody a sněhu. Záření střední vlnové délky a záření dlouhé vlnové délky zaujímají interval 3 μm – 15 μm a společně se uplatňují při sledování tepelné bilance povrchů. Interval vlnových délek 15 μm – 3000 μm nazýváme dlouhým infračerveným zářením, to je pohlcováno v atmosféře a v DPZ se tedy nevyužívá.

Interval nejdelších vlnových délek (1 mm – 1 m) využívaný v DPZ se nazývá *mikrovlnné záření*. Využívá se především v radarech, které patří mezi aktivní senzory - vysílají záření a přijímají jeho odraz (Kolář, Halounová, Pavelka, 1997).

2.2 Využití DPZ při výzkumu lesních porostů

Metody DPZ jsou uplatňovány v mnoha oborech lidské činnosti od urbánního plánování po sledování vegetačního pokryvu. Právě monitoring lesního porostu je velmi rozšířenou kategorií výzkumu, které se dálkový průzkum Země věnuje již od počátku svého vzniku. V oboru lesnictví se DPZ uplatňuje z mnoha důvodů, mezi hlavní patří rychlé získání a zpracování dat o velkých územních celcích, možnost využití spektrálních vlastností pro určení zdravotního stavu vegetace nebo např. možnost monitoringu míry poškození lesa disturbancí. Mezi další charakteristiky lesa, které můžeme pomocí DPZ sledovat, patří například mapování zalesněné plochy či holých sečí, odhad biomasy, klasifikace lesních porostů, zjišťování škod po požárech nebo identifikace poškozeného a suchého lesa (Hais, 2009).

Všeobecně praktikovaný postup při průzkumu lesní vegetace probíhá v několika krocích. Prvním krokem se logicky stává sběr dat, zpravidla v podobě leteckých a družicových snímků či laserových dat. Satelitní snímky se začaly při výzkumu lesních porostů využívat ve větší míře zhruba před 20 lety, díky komerčnímu zpřístupnění snímků s rozlišovací schopností pod 20 m. Právě hodnocení zdravotního stavu lesa za použití družicových dat s různým rozlišením se věnuje např. Wang (2009). Jejich výhodou oproti leteckým snímkům je nižší náročnost při zpracování, vyšší spektrální, radiometrická i rozlišovací schopnost či pokrytí velkých ploch území (Garčár et al., 2010). Naopak letecké snímky se dají pořídit za nižší cenu a jejich prostorové rozlišení je většinou vyšší (Hájek, 2006). Kromě multispektrálních dat

je možné využití i dat hyperspektrálních, radarových nebo dat z leteckého laserového skenování (LiDAR, LLS). Právě zvyšující se dostupnost těchto dat přináší nové možnosti do oblasti hodnocení vlastností lesních porostů, např. hodnocení lesní struktury ve vertikálním směru (Ke, Quackenbush, Im, 2010).

Sběr dat pomocí DPZ je pro výzkum vegetace velmi cenný. Monitoring lesních porostů pomocí dálkového průzkumu umožňuje zaznamenat údaje z rozsáhlých ploch i těžko dostupných míst nevhodných pro terénní průzkum. Měření lze také periodicky opakovat, což zajistí nejen aktuálnost dat, ale i možnost vyhodnocení změn, které na území nastaly. Pozemní měření je oproti DPZ poměrně drahé a časově náročné, je však možné využít ho jako doplňující způsob výzkumu např. pro ověřování či kalibraci dat (Tomppo et al., 2008).

Pokud jsou nasbírána vhodná data, je možné provést digitální zpracování obrazu a pokračovat s analýzou vegetačního krytu. Dle Dobrovolného (1998) je cílem následující analýzy vegetačního pokryvu diferenciací co největšího počtu druhů zemského pokryvu a následná charakteristika vegetace. Analýza by měla podat informace o jevech a procesech pojících se s vegetací. Mezi tyto procesy řadíme obsah vody, fyziologický stres rostlin, fenofáze či chemické a mechanické poškození (Dobrovolný, 1998). Při analýze lesních porostů uplatňujeme především znalosti spektrálního projevu vegetace (viz kapitola 2.4). V současné době však již nestačí pouze spektrální informace, čím dál větší procento autorů věnuje pozornost spíše struktuře lesních porostů (např. hustota, množství biomasy, prostorové uspořádání) než pouhému monitorování jejich rozsahu či zdravotního stavu. Pro tyto účely je možné využití i dalších příznaků jako je například informace o textuře obrazových dat, která dle mnoha studií velmi zvyšuje přesnost klasifikace (např. Moskal a Franklin 2002; Sarker a Nichol 2011).

2.3 Disturbance a zdravotní stav lesní vegetace

„Disturbance (narušení) je pojem, kterým v ekologii společenstev označujeme událost, která odstraní organismy, spontánně nebo uměle, a vytváří tak prostor pro kolonizaci jedinci stejného nebo jiného druhu.“ (Košulic, 2009). Frelich (2002) uvádí, že disturbance jsou hlavní silou, která řídí dynamiku většiny lesních ekosystémů na světě. Stejně tak stávající všeobecně přijímané vědecké názory zdůrazňují právě dynamiku a nerovnovážnost ekologických systémů, v nichž přírodní disturbance nejsou ničím cizorodým. Podle Košulice (2009) je důležité oddělovat příčiny disturbance lesů na hospodářské a přirozené. Rozdíl mezi antropogenními vlivy (odlesnění, těžba, znečištění atd.) a přírodními vlivy totiž určuje charakter projevu disturbance, její rozsah, intenzitu a frekvenci (Hesslerová, Kučera, 2006). Disturbance způsobené přírodními

faktory lze dělit na biotické a abiotické. Mezi abiotické disturbance řadíme laviny, povodně, požáry, vichřice, extrémní sucha či zemětřesení. Biotické disturbance způsobují například invazivní druhy rostlin a živočichů (Hesslerová, Kučera, 2006).

Je zřejmé, že země s vysokou lesnatostí postihnou dříve či později problémy spojené s poškozením lesních porostů disturbancemi. V poslední době se vědecké články zajímají o téma disturbancí ve střední a západní Evropě daleko více než tomu bylo dříve, a to především v souvislosti s dynamikou lesa. Kulakowski a Bebi (2004) považují za významné činitele vítr a hmyz, ty dle autorů ovlivňují právě dynamiku horských lesů střední Evropy. Bohužel oblast střední a částečně západní Evropy neumožňuje zkoumat vliv těchto disturbačních činitelů na úrovni rozsáhlých celků horských lesů, jako je tomu například v Kanadě (Kulakowski, Bebi, 2004).

Stav lesní vegetace na území Česka je analyzován již od 90. let v souvislosti s úbytkem lesa v severních Čechách (Zemek, Heřman, Klouda, 1999). Nejvíce zkoumanými lesními celky v Čechách jsou Národní parky Krkonoše a Šumava. Krkonošský národní park je výjimečný, co se vegetace týče, především díky svým lučním společenstvím, která byla předmětem výzkumu například Doriče (2013) či Hromádkové (2015). S dlouhodobými problémy s disturbancemi, ať už větrnými či následnými invazemi kůrovce, se potýká nejvíce NP Šumava, který je i díky svému přesahu do německého Bavorska velmi často zkoumán českými i zahraničními autory (např. Adamczyk a Osberger (2015)).

Tématu hodnocení lesních porostů po napadení lýkožroutem smrkovým se věnuje i celá řada zahraničních autorů, jejichž studie se liší typem použitých dat i metodou zpracování. Časté je použití jak leteckých (např. Hájek, Svoboda, 2007; Meddens, Jeffrey a Vierling, 2011) tak družicových snímků (např. Wang, 2009; Denison, Brunelle, Carter, 2010). Mezi nejpoužívanější družicové snímky k hodnocení kůrovcem napadeného lesa patří snímky Landsat TM nebo ETM+, a to díky svému prostorovému rozlišení 30 m a časovému rozlišení 16 dní. Dalšími faktory ovlivňujícími jejich oblíbenost je jistě možnost stáhnutí těchto snímků z internetu zdarma i možnost použití časové řady od roku 1972 do současnosti (Gisat, 2007). Prostorovým rozlišením 30 m se snímky Landsat řadí mezi data s vyšším prostorovým rozlišením, na trhu však existuje i spousta dalších možností, jaké prostorové rozlišení použít. Výběrem vhodného prostorového rozlišení se zabývali např. Meddens, Jeffrey a Vierling (2011). Naopak Wang (2009) dokázal, že lze použít i snímky MODIS s nízkým prostorovým rozlišením 1 km.

2.4 Spektrální projev vegetace

2.4.1 Zářivé vlastnosti krajinných prvků

Jak již bylo uvedeno v předchozí kapitole, základním fyzikálním jevem dálkového průzkumu je interakce elektromagnetického záření se zkoumaným látkovým objektem. Pro stanovení určitých fyzikálních vlastností měřené látky či objektu z naměřených hodnot spektrální intenzity odraženého záření je využíváno spektrálních vlastností různých materiálů (Kolář, Halounová, Pavelka, 1997). Můžeme říci, že pro každou látku na zemském povrchu existuje specifická spektrální charakteristika. Tu vyjádříme sestavením závislosti mezi odrazivostí a vlnovou délkou daného objektu. Takto vzniklou závislost označujeme jako *spektrální křivku odrazivosti* (Dobrovolný, 1998). Znalost vztahu mezi spektrální charakteristikou a příslušnými stavovými parametry (např. vlhkost, výška, hustota, stáří) pomáhá určit nejvýhodnější spektrální pásma pro měření (Kolář, Halounová, Pavelka, 1997).

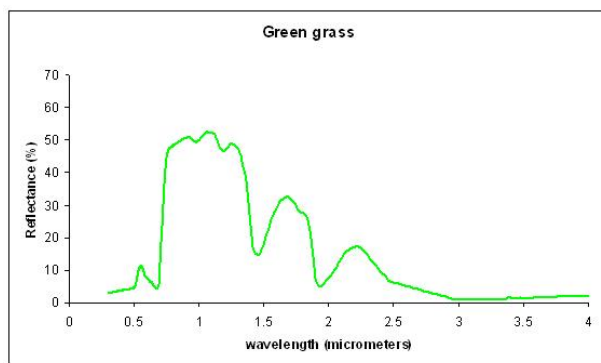
Vzhledem k vysoké rozmanitosti krajinných objektů na planetě Zemi je nemožné sestavit přesný popis spektrálních vlastností každého druhu. Lze však obecně oddělit čtyři skupiny, které se vyznačují specifickými zářivými vlastnosti: pevný povrch bez vegetace, vegetační povrch, voda a plynné látky (Kolář, Halounová, Pavelka, 1997). Vzhledem k tématu diplomové práce bude podrobněji rozebrána spektrální charakteristika vegetace.

Vegetace se na zemském povrchu vyskytuje ve formě lesních či travních porostů a zemědělských plodin a díky své dominanci v krajině se tak stává častým objektem zkoumání DPZ. Co pro Zemi činí vegetaci tak vzácnou, je především schopnost fotosyntézy. Fotosyntéza může proběhnout díky chlorofylu, který je obsažený v listu (Campbell, Wynne, 2011). Tento zelený pigment obsažený v listu absorbuje sluneční záření a spolu s odrazivými a emisními vlastnostmi dalších částí rostliny (např. buněčné tekutiny, celulózy, tuků, proteinů, cukrů), určuje finální spektrální projev vegetace (Jones, Vaughan, 2010). Spektrální křivku odrazivosti listu lze rozdělit na tři části (Obrázek 2): oblast pigmentační absorpce (0,4 – 0,7 μm), oblast vysoké odrazivosti neboli buněčné struktury (0,7 – 1,3 μm) a oblast vodní absorpce (1,3 – 3 μm) (Kolář, Halounová, Pavelka, 1997).

Zmiňovaný chlorofyl spolu s karoteny nejvíce ovlivňuje spektrální křivku listu v její první části. Ve viditelné části spektra pohlcují většinu záření v modré (0,45 μm) a červené (0,65 μm) části spektra. Mezi těmito absorpčními pásy se vytváří lokální maximum odrazivosti v zelené (0,54 μm) části spektra. Tyto vlastnosti určují charakter první části křivky tzv. pigmentační absorpce (Lobo, Ersoy, Miles, 2000).

V blízké infračervené části spektra se projevuje vliv morfologie listu a dalších komponent v buněčné stěně rostlin (Jones, Vaughan, 2010). Výrazný nárůst odrazivosti v intervalu cca od 0,75 μm do 1,35 μm , je dán malou absorpcí infračerveného záření pokožkou listu. Z toho lze vyvodit, že odrazivost u zdravých listů je velmi vysoká (Campbell, Wynne, 2011).

Obrázek 2: Spektrální křivka odrazivosti listu



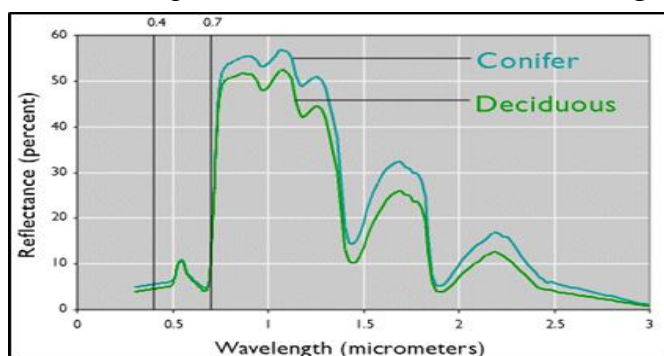
Zdroj: URL 2

Jako jeden z nejdůležitějších spektrálních projevů vegetace pro účely DPZ můžeme označit část křivky (kolem 700 nm) nazývanou *red-edge*, kde oblast absorpce strmě přechází ve vysokou odrazivost (Jones, Vaughan, 2010). Rozdílu odrazivosti naměřených v těchto dvou oblastech je využíváno jako indikátoru přítomnosti zelené hmoty. Z tzv. *vegetačního indexu* ($VI = NIR - RED$) pak vychází další modifikované a složitější poměry, kterými se bude zabývat jedna z dalších kapitol (Kolář, Halounová, Pavelka, 1997).

Třetí částí spektrální křivky listu je oblast vodní absorpce. Jak již název napovídá, jsou zde díky obsahu vody v listu výrazné absorpční pásy na vlnových délkách 1,4 μm , 1,9 μm a 2,7 μm . Lokální maxima se vyskytují na vlnových délkách 1,6 μm a 2,2 μm (Kolář, Halounová, Pavelka, 1997).

Obecně je třeba brát v potaz, že daná charakteristika spektrální křivky je uváděna pro list obecně. Při zkoumání vegetace v DPZ však daleko častěji přicházíme do styku s větším měřítkem vegetace. Spektrální křivku pak ovlivňují i další části rostliny jako např. kmeny, větve a květy. Pro jehličnaté stromy, které budou hlavním předmětem zkoumání diplomové práce, je křivka mírně rozdílného tvaru (Obrázek 3), ovšem se stejnými charakteristickými prvky.

Obrázek 3: Spektrální křivka odrazivosti lesní vegetace



Zdroj: URL 3

2.4.2 Vegetační indexy

Vegetační indexy využívají různých kombinací pásem multispektrálních družicových dat. Tyto kombinace vytvoří jednopásmový obraz reprezentující určitý stav vegetace, nejčastěji její vitalitu, zdravotní stav či pouhou přítomnost. Jak již bylo popsáno v předchozí kapitole, vegetace prokazuje charakteristické znaky spektrální odrazivosti. Vegetační indexy z těchto poznatků vychází a to použitím nejčastěji červeného a blízkého infračerveného pásma. Dle Joshi (2011) jsou vegetační indexy používány k přesné inventarizaci globálního rozložení vegetačních typů, tedy i jejich biofyzikálních (např. biomasa, LAI) a strukturních vlastností (např. hustota zápoje).

Z hlediska výpočtu lze vegetační indexy rozdělit do dvou velkých skupin na poměrové a ortogonální. Poměrové indexy jsou, jak již název napovídá, vyjádřeny poměrem odrazivosti povrchů v červené části spektra a NIR. Ortogonální indexy pak vyjadřují lineární kombinaci původních pásem multispektrálního obrazu. Příkladem ortogonálních indexů je například transformace TASSELED CAP (Dobrovolný, 1998).

Normalizovaný vegetační index NDVI (Normalized Difference Vegetation Index), poprvé popsal Rouse et al. (1974) vzorcem:

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

Výsledné hodnoty se nacházejí v intervalu od -1 do 1, přičemž čím je hodnota vyšší, tím je větší i obsah vegetace. Typické hodnoty pro zelenou vegetaci se pohybují v intervalu od 0,2 do 0,8. Při práci s tímto indexem je problémem možná práce s negativními hodnotami, proto Deering a Rouse (1975) vytvořili index TVI, který problém negativních hodnot řeší přidáním konstanty 0,5 a odmocninou ve vzorci.

$$TVI = \sqrt{\frac{NIR - RED}{NIR + RED} + 0.5}$$

Výpočet odmocniny je určen k zavedení normálního rozdělení a k opravě NDVI hodnot, které se blíží k Poissonovu rozdělení. Po technické stránce se indexy NDVI a TVI neliší, nicméně pro bezproblémové použití TVI je třeba, aby vstupní hodnoty byly větší než -0,50, což nemusí být vždy dodrženo.

Index RGI (ang. Red-Green Index) je v podstatě obrácený standardní jednoduchý poměr (Simple Ratio). Tento index byl navržen autory Richardsonem a Wiegandem v roce 1977.

$$RGI = \frac{RED}{GREEN}$$

Jednoduchý poměrový vegetační index je poměr nejvyšší odrazivosti, kdy absorpční pásma chlorofylu umožňují snadné porozumění a jsou efektivní v širokém rozpětí podmínek. Hodnoty indexu se pohybují od nuly do více než 30 (Dobrovolný, 1998). RGI index je používán při detekci vegetace napadené kůrovcem, a to především ve fázi red attack. Aplikace indexu spočívá ve zvýraznění barevné změny listů od zelené k červené barvě vlivem zvětšujícího se podílu athokyanu. Používá se především pro odhad vývoje olistění a jako indikátor stresu (Meddens et al., 2013).

V odborné literatuře lze dohledat množství studií zabývajících se analýzou vegetace s pomocí vegetačních indexů. Práce většinou hodnotí metody využití dat pořízených v infračervené oblasti spektra i samotné vegetační indexy. Posouzení třinácti vegetačních indexů se věnuje Veraverbeke et al. (2012), který dané indexy testuje na vegetačním pokryvu obnovujícím se po požárech. Autoři závěrem podporují index SAVI pro prostředí s jedním typem vegetace (např. právě krajina po požáru), všeobecně však za nejvýhodnější index označují NDVI pro jeho schopnost minimalizovat vliv variability vegetace. Index NDVI ve své studii využil i Solberg et al. (2007), který s jeho pomocí a s využitím středního infračerveného pásma záření vytvořil jednoduché mapy defoliace ze snímku SPOT. Výsledky práce ukázaly, že defoliace způsobená hmyzem může být mapována i na snímcích SPOT pouze na základě zvýšení odrazivosti v pásmu SWIR a snížení hodnot NDVI. Hrdina (2006) používá indexu NDVI a TASSELED CAP pro analýzu sezónních změn vegetace kvantifikováním vegetačního charakteru krajiny. Lépe než index NDVI hodnotí autoři Jin a Sader (2005) index NDMI (Normalized Difference Moisture Index), který dle autorů koreluje s obsahem vody v lesní vegetaci mnohem lépe než klasický index NDVI. Mezi další výhody NDMI autoři řadí i schopnost odhalit lehčí poruchy ve zdravotním stavu či větší přesnost. Index RGI ve své studii testovali například Coops, Wulder a White (2006), který vidí jeho vhodné využití pro separování napadených a zdravých stromů, mezi nevýhody však řadí nedostatečné oddělení stínů.

2.4.3 Spektrální projev vegetace narušené disturbancemi

Chování spektrální křivky se obecně mění v závislosti na vegetačním cyklu či v důsledku stresů, kterým je vegetace vystavena. U vegetace ve špatném zdravotním stavu všeobecně dochází k nárůstu hodnot odrazivosti v červené části spektra a k poklesu v blízké infračervené části. První projev o změně stavu nemocné vegetace je možné vidět právě v infračervené části spektra, kde můžeme zaregistrovat první známky zhoršení vitality vegetace ještě dříve, než jsou vidět pouhým okem při terénním průzkumu.

Konkrétně závisí velikost odrazivosti na obsahu vody v listu (či jehlici), pokud je hodnota menší než 55 % vlhkosti, ztrácí rostlina značnou část chlorofylu. Z toho vyplývá, že v pásmu kolem 660 nm dojde k nárůstu odrazivosti. Dalším projevem nedostatku vlhkosti je změněná struktura listu projevující se v NIR (Kolář, Halounová, Pavelka, 1997).

Lesní vegetace se velmi často potýká s napadením invazivními druhy rostlin a živočichů. V NP Šumava je to konkrétně lýkožrout smrkový či obecněji kůrovec (ang. bark beetle). Podobně invazivní druhy hmyzu se vyskytují (či vyskytovali) i na území Rakouských Alp, Britské Kolumbie v Kanadě, Finského Lahti či v menší míře v Nízkých Tatrách na Slovensku (Wermelinger, 2004).

Průběh napadení lesního porostu lýkožroutem smrkovým lze dělit do několika fází. V první fázi napadení zůstává jehličí stále zelené, avšak stromy jsou již atakované kůrovcem, tuto fázi označujeme jako *green-attack*. Pokud se lesy nachází v této fázi, je velmi obtížné je oddělit od zdravé vegetace. Oddělením napadené vegetace ve fázi *green-attack* a zdravých stromů se zabývali například autoři Immitzer a Atzberger (2014), kteří za použití několika metod klasifikovali snímek WorldView-2. V dalším stádiu napadení již začíná jehličí světlat a později zcela reznout. Příčinou je úbytek vody a následná ztráta chlorofylu. Fáze *red-attack* se na spektrální křivce projeví poklesem odrazivosti v zelené části spektra a naopak zvýšením v červené části spektra. Po 3 až 5 letech začne jehličí opadávat a kůra stromu tzv. zešediví, porost je ve fázi *grey-attack*. Les v tomto stádiu je již bez jehličí a téměř bez kůry, jeho spektrální projev se již blíží spíše holé půdě či lučním porostům (Wulder et al., 2006).

2.5 Klasifikace

Klasifikací obrazu rozumíme rozřazení jednotlivých obrazových prvků do informačních tříd. Cílem tohoto procesu je nahradit hodnoty radiometrických charakteristik původního obrazu novými hodnotami, jež zachycují příslušnost k určité kategorii.

Typ a obsah nové informace závisí na zaměření projektu. Typy informačních tříd stanovujeme na počátku klasifikace (Dobrovolný, 1998).

Klasifikace je prováděna na základě hodnocení podobnosti jednotlivých prvků obrazových dat. Vlastnosti, které jsou používány pro rozhodování o míře podobnosti, označujeme jako rozhodovací pravidla. Samotný algoritmus, který řadí prvky do tříd na základě těchto pravidel, pak nazýváme klasifikátor. Jako rozhodovací pravidla lze použít různé vlastnosti prvků. Nejčastěji je využíváno spektrálního chování či odvozených spektrálních vlastností prvků (např. spektrální indexy). Mezi další možné charakteristiky pak patří prostorové chování prvků, jako je textura, vzájemná vzdálenost, velikost nebo tvar.

2.5.1 Pixelová klasifikace

Jak již název napovídá, základním obrazovým prvkem vstupujícím do klasifikace je pixel, ke kterému se vztahují jednotlivá rozhodovací pravidla. Vzhledem k velikosti obrazových dat vstupujících do klasifikace je pochopitelné, že je snaha o co největší automatizaci procesu. V závislosti na okamžiku, kdy do klasifikace vstupuje zpracovatel, dělíme klasifikaci na řízenou a neřízenou.

2.5.2 Neřízená klasifikace

Metody neřízené klasifikace mají na vstupu zadaný počet cílových tříd v obraze určený zpracovatelem. Tento druh klasifikace tedy patří k plně automatizovaným procesům pracujících na principu shlukových analýz. Na základě statistického rozdělení pixelů v příznakovém prostoru pak algoritmus přiřadí pixely do jednotlivých tříd. Výhodou těchto metod je jistě nižší nárok na znalost informace na začátku procesu a rychlejší vyhodnocení. K nejčastěji používaným algoritmům neřízené klasifikace řadíme metodu ISODATA nebo K-means clustering.

2.5.3 Řízená klasifikace

Řízená klasifikace již klade nárok na určitý vstup od zpracovatele ve formě tzv. trénovacích ploch. Trénovací plochy tvoří trénovací množiny, které odpovídají počtu požadovaných tříd. Trénovací vzorky lze stanovit na základě nám známých dat např. z terénního průzkumu nebo z mapových podkladů. Daná množina se v klasifikačním procesu používá pro sestavení příznaků převážně spektrálního charakteru. Ačkoli je řízená klasifikace náročnější na vstup ze strany zpracovatele, výsledky bývají přesnější.

Pro řízenou klasifikaci vegetace v DPZ je již dlouho používáno mnoho tradičních klasifikátorů jako např. maximum likelihood, minimum distance nebo parallelepiped. Technologie však pokročily a je stále častější použití nových klasifikačních algoritmů,


keré si nachází své stálé místo v tradičních metodách dálkového průzkumu vegetace. Mezi tyto algoritmy můžeme řadit neuronové sítě či metodu podpůrných vektorů (Gidudu, Hulley, Marwala, 2007). Metody uměle vytvořených neuronových sítí (Neural Network) a podpůrných vektorů (Support Vector Machine) patří mezi tzv. učící mechanismy. Oba algoritmy jsou také řízenými neparametrickými klasifikacemi, což znamená, že zde není předpoklad normálního rozložení dat. Tento fakt je největší výhodou daných klasifikací, protože ve většině případů mají data dálkového průzkumu Země nerovnoměrné statistické rozložení, se kterým navíc jednodušší klasifikátory nedokáží efektivně pracovat (Jones, Vaughan, 2010).

Support Vector Machine

Support Vector Machine (SVM) je metoda strojového učení patřící k relativně novým metodám tzv. jádrových algoritmů (Vapnik, 1995). Ty se snaží pomocí efektivních algoritmů nalézt lineární hranice a zároveň reprezentovat vysoce složité nelineární funkce. Jedním ze základních principů SVM je převod vstupního prostoru do vícedimenzionálního prostoru, kde již lze od sebe třídy lineárně oddělit (Gidudu, Hulley, Marwala, 2007).

Dle původní definice se SVM algoritmus snaží najít optimální nadrovinu, která separuje data do předdefinovaného počtu tříd v souladu s trénovací množinou. Optimální nadrovina je taková, že body leží v opačných poloprostorech a hodnota minima vzdáleností bodů od roviny je co největší (viz Obrázek 4). Pro popis nadroviny lze využít nejbližší body nazývané podpůrné vektory – support vectors (Zhu, Blumberg, 2002). Ze své podstaty je SVM binární klasifikátor, nicméně existují postupy, pomocí kterých lze adaptovat metodu tak, aby bylo možné dotazovat se na více tříd. Tyto dva přístupy nazýváme One versus one and One versus all (Gidudu, Hulley, Marwala, 2007).

Obrázek 4: Princip Support Vector Machine



Zdroj: URL 4

Neural Networks

Neuronové sítě (NN) představují algoritmy, které se snaží napodobit procesy probíhající v nervové soustavě, kde síť specializovaných nervových buněk - neuronů zpracovává signál a mění jej na informace. Základní vlastností vycházející z biologických vzorů neuronových sítí je schopnost učení (Jones, Vaughan, 2010). Základním prvkem umělé neuronové sítě jsou neurony vzájemně propojené do sítě tzv. váhovými koeficienty. Daný prvek sčítá všechny příchozí hodnoty vážených spojení a vyhodnotí výslednou hodnotu, která je nelineární funkcí jeho součtu (Lantora, Vašková, 2006).


Neuron může přijímat mnoho vstupů, avšak tvoří pouze jeden výstup, který lze definovat funkcí $F(x)$:

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

kde x_i představuje hodnotu i -tého vstupu a w_i je váha i -tého vstupu.

Uspořádání neuronové sítě zahrnuje kromě vstupních a výstupních vrstev obvykle také vnitřní skryté vrstvy (Dobrovolný, 1998). Neurony ve vstupní vrstvě (tzv. zdrojové uzly) zajišťují příjem vstupů zvenčí do sítě (viz Obrázek 5). Tato vrstva má spíše pasivní charakter, jelikož její funkce spočívá především v rozdělení a přenesení signálu do dalších vrstev. Následující skrytá vrstva nemusí být pouze jedna, ale lze volit i vyšší počet, který významně ovlivňuje celkovou přesnost výstupu. Její funkcí je především zpřesňování výpočtu. Konec celé sítě představuje výstupní vrstva, která představuje konečný výstup. Řízená klasifikace NN využívá k natrénování učící algoritmus zpětného šíření (Back propagation). Na základě trénovacích dat jsou pak upravovány váhy spojení mezi neurony.

Obrázek 5: Schéma neuronové sítě



Zdroj: URL 5

2.5.4 Objektová klasifikace

Výše zmíněné metody patří do skupiny pixelových klasifikací a neberou tak v úvahu kontextové nebo topologické informace o krajině. Objektově orientovaná klasifikace obrazu (OBIA) tyto nedostatky řeší. Základní myšlenka OBIA se zaměřuje právě na interpretaci sémantických informací na snímcích, které nejsou reprezentovány v jediném pixelu, ale v obrazových objektech a jejich vzájemných vztazích (Halounová, 2003). Tyto objekty pak věrohodněji reprezentují celky vegetace na zemském povrchu (Addink, De Jong, Pebesma, 2007). Kromě spektrálních informací je vhodné využít i jiné informace objektů: tvarové, texturální a topologické vztahy. Tato metoda je vhodná, i pokud nejsou k dispozici koncové členy nebo se překrývají ve spektrálním prostoru (Jones, Vaughan, 2010).

První fází objektové klasifikace obrazu, je *segmentace*. Segmentace představuje rozdělení obrazových dat do oddělených shluků pixelů (segmentů). Limitním příkladem segmentace je rozpad obrazu na jednotlivé pixely, na druhé straně by celý obraz byl jediným obrazovým objektem. Při segmentaci je třeba vycházet ze základního pravidla, kdy objekty by měly být tak malé, aby byly pro daný účel dostatečně homogenní a zároveň co největší, aby se s nimi dalo efektivně pracovat a zkoumat jejich prostorové vztahy a vazby mezi nimi. Dle zvoleného algoritmu se pak přihlíží k prostorovým charakteristikám objektů, jako je tvar či velikost, či k texturálním příznakům.

Segmentační algoritmy lze rozdělit do několika kategorií podle jejich přístupů. Top-down segmentace postupuje od největších objektů k menším, na počátku je tedy celý obraz jako jeden segment a ten je dále dělen na požadovanou velikost. Mezi top-down algoritmy patří například Chessboard segmentace, Quadtree segmentace, Contrast filter segmentace či Contrast split segmentace (Trimble, 2012). Bottom-up princip postupuje naopak od nejmenších objektů (pixelů) k větším, řadí se sem například algoritmus Multiresolution segmentation.

Klasifikace OBIA probíhá na principu zařazování jednotlivých objektů do tříd, které popisují sémantický význam objektů. Tento postup může být založen jak na tzv. tvrdých klasifikátorech (např. metoda rozhodovacího stromu) tak na měkkých klasifikátorech, kam řadíme fuzzy systémy. Fuzzy model využívá tzv. funkce příslušnosti (membership function), logické operátory (and, or, not) a pravidla „jestliže-pak“. Funkce příslušnosti graficky reprezentuje míru náležení objektů do jednotlivých klasifikačních tříd. Popis jednotlivých tříd je charakterizován pomocí tzv. klasifikačních pravidel, jejich souhrn se pak označuje jako klasifikační báze (Gisat, 200-?).

2.5.5 Klasifikace lesních porostů poškozených disturbancemi

Prvním důležitým krokem, který musí autor při klasifikaci řešit, je stanovení počtu tříd. V oblasti Velkých jezer bylo například možné rozdělit různé druhy stromů (až 22 typů) za pomoci multitemporálních dat z více časových období až s 83% přesností. Při použití pouze jednoho časového období se počet kategorií snížil na zhruba polovinu (Wolter et al. 1995). Brodský, Kolomazník a Bartaloš (2009) ve své práci o OBIA klasifikaci vegetace rozlišují kategorie: stále zelený les, listnatý les a křovinatý porost, upozorňují ovšem na fakt, že dané území je třeba lépe znát a segmentaci vhodně řídit. Podrobněji les klasifikují GLC klasifikační systém a GlobCover, kde počet tříd převyšuje standardní tři. Oba klasifikační systémy využívají pro definici tříd hustotu vegetace na určované ploše. Pokud bychom se při vymezení tříd zaměřili přímo na plochy postižené disturbancí, je dle literatury (např. Bromová, 2012) vhodné kategorizovat dle zápoje korun stromů, hustoty porostů či dle vegetačních indexů. Zajímavě srovnává vymezení stádií lesa poškozeného disturbancí Franklin et al. (2002), kde porovnává rozložení tříd od různých autorů a snaží se vytvořit jejich průnik.

Výběrem nejvhodnější metody ke klasifikaci lesa poškozeného disturbancí i konkrétně lýkožroutem smrkovým se zabývalo mnoho autorů v zahraničí i u nás. Studie monitorující biologické poruchy lesa v Evropě se zaměřují především na metodu pixelovou, tu použili například autoři Meddens, Jeffrey a Vierling (2011) nebo White et al. (2005), kteří pomocí ní detekovali stádium napadení kůrovcem red-attack. DeRose, Long a Ramsey (2011), hodnotili napadený lesní porost pomocí vegetačních indexů ze snímků Landsat a následnou pixelovou klasifikací dosáhli celkové přesnosti v rozmezí 80 – 82 %. Na rozdíl od většiny studií používajících masku vegetace, zahrnuli Hicke a Logan (2009) do své práce i travní porosty. Pomocí klasifikátoru maximální pravděpodobnosti pak rozdělili snímek do 3 kategorií: zdravé stromy, poškozené stromy a travní porosty. Studie úspěšně oddělila červené stromy od zdravých a od travních porostů i díky indexu RGI a využití odrazivosti v zeleném pásmu. Celková přesnost klasifikace byla 86 %.

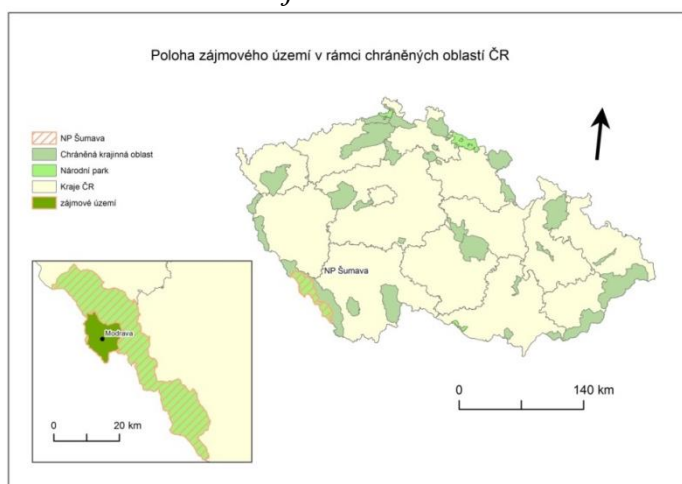
Jak již bylo popsáno výše, jednodušší pixelové metody dávají poměrně dobré výsledky, ovšem s tím jak přichází snímky s lepším prostorovým i spektrálním rozlišením je hodně rozvíjena oblast novějších klasifikátorů jako SVM, NN či OBIA. Hájek a Svoboda (2007) použili objektovou klasifikaci pro vyhodnocení odumírání horského lesa v NP Šumava na vysoce texturovaných leteckých snímcích. Z práce vyplynulo, že přístupem tvorby zákonité sekvence procesů lze klasifikovat obrazová data s poměrně vysokou mírou automatizace a to především díky tomu, že se jedná o posloupnost typizovaných algoritmů přenositelnou ve formě znalostní báze. Lihanová (2013), která použila také objektovou klasifikaci, přidala do algoritmu i lidarová data,

s jejichž pomocí bylo možné kategorii zdravé vegetace rozdělit dle výše porostu. Latifi et al. (2014) pomocí OBIA klasifikoval snímky Landsat za 11leté období na území Bavorského národního parku s cílem zmapovat související třídy úmrtnosti lesa. Metodu SVM úspěšně použili Hart a Veblen (2015), kteří klasifikovali les napadený kůrovcem z družicových i leteckých snímků.

3 ZÁJMOVÉ ÚZEMÍ

Zájmovým územím této studie je oblast centrální Šumavy se zaměřením na lokality s významným rozpadem horských smrčín vlivem přemnožení lýkožrouta smrkového. Národní park Šumava, ležící na jihu až jihozápadě Česka, je naším největším národním parkem již od roku 1991 a zaujímá celkovou plochu 680 km². Zkoumaná oblast kopíruje hranici poskytnutého snímku WorldView-2 (viz Obrázek 6) a pokrývá 105 km² z NP Šumava.

Obrázek 6: Poloha zájmového území v ČR



Zdroj: ArcČR 500 digitální geografická databáze Arcdata Praha, s. r. o. (upraveno autorem)

Nadmořská výška v zájmové oblasti dosahuje v průměru 1100 – 1200 m n. m., kde nejvyššími vrcholy na snímku jsou Velká Mokrůvka 1370 m n. m. a vrch Luzný 1373 m n. m., nejnižším bodem pak obec Modrava s nadmořskou výškou cca 980 m n. m, viz Příloha 1. Hydrologicky spadá oblast do subpovodí Roklanského a Modravského potoka, které je součástí povodí Otavy. Hlavním krajinným pokryvem v NP Šumava jsou horské smrčiny, rašeliniště (např. Rokytská, Rybářenská, Roklanská slat') a horské louky. Většina z těchto krajinných pokryvů byla v minulosti ovlivněna ve větší či menší míře hospodářským řízením lesů, a to zejména těžbou dřeva či pastvou dobytka. Přestože tyto aktivity trvaly dlouhou dobu, můžeme na území NP Šumava stále najít roztroušené zbytky pralesa (Zemek et al., 2003). Přirozené zastoupení smrku se v národním parku dříve pohybovalo kolem 51 %, aktivitou člověka se však v průběhu posledních 250 let podíl smrku postupně zvyšoval až na současných cca 80 %. Smrk tak převládá i v podmínkách, kde v přírodních lesích převažovala jedle s bukem. V NP se kromě smrčín nachází mnoho dalších specifických druhů rostlin a živočichů, je zde proto ustanoven zvláštní režim ochrany životního prostředí.

Jádrová oblast Šumavy je ovlivněna lýkožroutem smrkovým dlouhodobě. V roce 1726 byly zaznamenány první zmínky o škodách po větrné kalamitě způsobené

kůrovcem. Dále je třeba zmínit období 1868-1870, kdy kalamita postihla 5-7 milionů m³ dřeva. Krátce před vznikem NP Šumava došlo také k několika kalamitám např. v letech 1984-1985, kdy na Modravě padlo až 120 000 m³ lesa. Po roce 1990 začal rozsah napadení stoupat především díky opakujícím se kalamitám a sérii suchých a teplých let, která významně snížila odolnost lesa. Výrazné rozšíření kůrovce v roce 1995 pak vedlo k vyhlášení bezzásahového území o rozloze 1325 ha. Díky důsledné asanaci se v následujících letech dařilo snižovat objem kůrovcových těžeb, což se projevilo výrazným úbytkem nově napadených oblastí. V druhé polovině 90. let byly v okolí bezzásahového pásma prováděny holosečné těžby, aby se zabránilo dalšímu šíření kůrovce. Extrémně suché a teplé počasí roku 2003 však bylo mimořádně příznivé pro rozvoj kůrovce a vedlo tak k opětovnému oslabení smrkových porostů (Hais, 2009).

Současný stav porostu je stále ještě silně ovlivněný předchozími kalamitami. Většinu plochy tvoří holina s fragmenty zbylých porostů. Leží zde velké množství padlých stromů, které podlely větrné kalamitě Kyril z ledna roku 2007. Ležící stromy se pak staly vhodným místem pro nálet lýkožroutů, jejichž populace se neustále zvyšuje. Aktuální území postižené kalamitním přemnožením lýkožrouta smrkového v okolí Březníku je na východní straně ohraničené Velkou a Malou Mokrůvkou, na západě zasahuje až k Roklanu. Severní hranici tvoří přibližně linie Medvědí – Studená hora a na jihu je studovaná oblast vymezena státní hranicí s mírným přesahem do Německa (Hais, 2009).


4 DATA A METODY

4.1 Použitá data

WorldView-2

Primárním datovým zdrojem studie jsou multispektrální snímky WorldView-2, pořízené 17. 9. 2015 za bezoblačné oblohy. Složený výsledný snímek je zasazen do souřadného systému UTM (pásmo 33) elipsoid WGS-84 s polohovou přesností 5 m. Prostorové rozlišení pro panchromatický snímek je 0,46 m a pro multispektrální snímek 1,84 m. Družice je velmi flexibilní, díky čemuž dokáže nasnímat až 680 000 km² za den. Stejně jako předchozí verze WorldView-1 a Quickbird jsou i snímky WorldView-2 distribuovány v pěti možných úrovních - Basic 1B, Basic Stereo dvojice, Standard 2A, Ortho-Ready Standard (OR2A) a Orthorectified. Poskytnutý snímek je úrovně OR2A.

Obrázek 7: Spektrální pásma družice WorldView-2



Zdroj: URL 6 (upraveno autorem)

Satelit WorldView-2 nabízí velmi vysoké prostorové rozlišení s 8 spektrálními pásmy (Obrázek 7). Těchto 8 spektrálních kanálů zahrnuje 4 typická pásma (modré, zelené, červené a blízké infračervené) a 4 nově přidaná pásma (pobřežní, žluté, red edge a blízké infračervené 2) výrazně zvyšující možnost hodnocení dat (Tabulka 1).

Nově zahrnutá pásma:

- *Pobřežní pásmo* (Coastal Blue) umožňuje provádět batymetrické studie zaměřené na chlorofyl a penetraci vody.

- *Žluté pásmo* (Yellow) poskytuje uživateli daleko lepší vjem snímku než klasická kombinace RGB. Lidské oko je na žlutou část spektra více citlivé a výsledné snímky tak více připomínají lidské vnímání.

- *Pásmo Red Edge* (RE) umožňuje kvalitnější analýzu vegetace a přesnější hodnocení jejího zdravotního stavu, než je možné dosáhnout pouze s pásmy RED a NIR.

- *Blízké infračervené pásmo 2* (NIR 2) je vhodné pro analýzu atmosférických podmínek, které ho ovlivňují méně než NIR 1, se kterým se částečně překrývá.

Tabulka 1: Spektrální pásma družice WorldView-2

Označení pásma	Název spektrálního pásma	Rozsah od (μm)	Rozsah do (μm)
1	COASTAL	0.40	0.45
2	BLUE	0.45	0.51
3	GREEN	0.51	0.58
4	YELLOW	0.59	0.63
5	RED	0.63	0.69
6	RED EDGE	0.71	0.75
7	NIR 1	0.77	0.90
8	NIR 2	0.86	1.04

Zdroj: metadata snímku WorldView-2 (upraveno autorem)

Landsat 8

Cílem družice Landsat 8 je pokračovat ve snímání zemského povrchu podobným způsobem, jak tomu činily předchozí družice Landsat 1-7. Družice Landsat 8 byla vypuštěna na svoji dráhu v březnu 2013. Prostorové rozlišení u panchromatických snímků je 15 metrů, u multispektrálních snímků pak 30 metrů. Snímky z družice Landsat, vzhledem k jejich dostupnosti již od roku 1972 a jejich bezplatné distribuci, patří k nejvyužívanějším datům v oblasti monitoringu vegetace pomocí DPZ. Právě z tohoto důvodu byl snímek použit i pro tuto práci jako doplněk ke snímku WorldView.

Použitý snímek Landsat 8 byl nasnímán dne 12. 10. 2016 nad zájmovým územím, tedy 25 dní po použití snímku WorldView-2. Snímek Landsat 8 obsahuje 7 spektrálních pásem zahrnující 4 pásma viditelného záření (pobřežní, modré, zelené a červené) a 3 pásma infračervená (NIR, SWIR 1 a SWIR 2). Jejich rozsah udává Tabulka 2.

Tabulka 2: Spektrální pásma družice Landsat 8

Označení pásma	Název spektrálního pásma	Rozsah od (μm)	Rozsah do (μm)
1	COASTAL	0.43	0.45
2	BLUE	0.45	0.51
3	GREEN	0.52	0.6
4	RED	0.63	0.68
5	NIR	0.85	0.89
6	SWIR 1	1.56	1.66
7	SWIR 2	2.1	2.3

Zdroj: metadata snímku Landsat 8 (upraveno autorem)

Terénní data

Ještě před začátkem zpracování snímku bylo třeba provést v zájmové oblasti terénní průzkum a vybrat sledované typy lesního pokryvu pro změření kontrolních bodů pomocí GPS. Pro účel klasifikace bylo nasbíráno 80 bodů reprezentující různé typy vegetačních pokryvů na území snímku WorldView-2 v lokalitě Březníku, Poledníku a Modravských slatí. Sběr terénních dat se uskutečnil v termínu 8. – 9. 10. 2015, tedy 21 dní po zachycení zpracovávaného snímku WorldView-2. Body byly nasbírány pomocí přístroje GPS Trimble Geoexplorer 3000 Geo XT.

Řazení nasbíraných bodů do příslušných kategorií legendy proběhlo již v terénu a bylo následně upřesněno dle ortofota a dle fotografií pořízených při samotném šetření v NP Šumava. Mezi kontrolní body byly nakonec z terénního výzkumu zahrnuty pouze body (celkem 79), které jednoznačně charakterizovaly danou kategorii a neležely v území, které by zkruslovalo spektrálně či texturálně vlastnosti jednotlivých kategorií (viz Příloha 2).

4.2 Použitý software

Pro zpracování dat byly nejvíce využívány softwary ENVI 5.2 a eCognition Developer 8.7. Software ENVI je vytvořený především pro vizualizaci, analýzu a prezentaci digitálních snímků. Pro tyto účely můžeme využít nástroje pro geometrickou korekci, terénní analýzy, práci s rastrem i vektorem nebo např. spektrální analýzy.

Program eCognition Developer je určen pro vytváření a vývoj bází pro objektovou klasifikaci a jejich převedení do funkčního klasifikačního modelu, který je dále možné převést do hotového řešení v jednoduchém grafickém prostředí. Tato technologie

umožňuje efektivní a komplexní analýzu dat v automatizované formě. Obsahuje kompletní řadu funkcí a nástrojů zaměřených na segmentaci a následnou klasifikaci leteckých a družicových snímků.

Pro vizualizaci výsledků a výstupů byl použit program ArcGIS 10.2, který je tvořen řadou produktů pro vytváření, editaci, analýzu a vizualizaci geografických prostorových dat.

4.3 Předzpracování dat

Ortorektifikace

Poskytnutá data z družice WorldView-2 byla dodaná poskytovatelem na úrovni Ortho Ready Standart (OR2A). Data již byla radiometricky a geometricky upravená. U úrovně OR2A však není prováděna korekce na topografický reliéf jako např. u 2A. Produkt je vytvořen projekcí obrazových dat na průměrnou výšku, buď vypočítané z výškového modelu (DMT), nebo dodanou zákazníkem. Přesnost geometrických korekcí byla kontrolována pomocí polohy bodů naměřených v terénu i pomocí bodů nasbíraných nad ortofotem (např. vodní plochy či parkoviště). Snímek se od těchto dat lišil řádově o několik metrů (Obrázek 8), což při prostorovém rozlišení 1,84 m může vykazovat nepřesnosti. Z tohoto důvodu bylo třeba snímek před použitím ortorektifikovat.

Obrázek 8: Poloha nasbíraných bodů před ortorektifikací



Zdroj: tvorba autora

Ortorektifikace je definována jako proces odstranění geometrického zkreslení snímku způsobeného rozdílnou vzdáleností nebo výškou terénu. Výsledek procesu ortorektifikace pak nazýváme ortofoto (Dobrovolný, 1998). Přesnost ortorektifikace závisí na kvalitě a přesnosti podkladových dat, tedy na digitálním modelu terénu a na vlíčovacích bodech.

Ortorektifikaci lze provádět více způsoby a ve více možných programech. Jeden z možných přístupů je vytvoření orbitálního satelitního modelu na základě znalosti všech potřebných parametrů družice (oběžné dráhy, senzoru). Nevýhodou této metody je nutnost tvorby samostatného modelu pro každou družici.

U snímků z družice WorldView-2 bylo možné použít novější metodu *racionálních polynomických funkcí*. Podstatou této metody je aproximace orbitálního družicového modelu pomocí vícerozměrných polynomických funkcí. Hodnoty vstupních parametrů jsou dodávány společně se satelitními daty v podobě speciálních metadat jako tzv. Koeficienty racionálních funkcí (RPC – Rational Polynomial Coefficients). Tuto metodu lze vykonat i s velmi malým počtem vlíčovacích bodů nebo dokonce bez nich. Vzhledem k tomu, že získaná data již obsahovala přidaný soubor s koeficienty (*.rpb), byla využita tato metoda ortorektifikace.

V softwaru ENVI lze provést ortorektifikaci prostřednictvím koeficientů racionální funkce přímo pro senzor WorldView (*RPC Orthorectification workflow*). Pro provedení funkce je potřeba digitální model terénu v rastrovém formátu, který byl vytvořen v softwaru ArcGIS (*Topo to Raster*) na základě vrstevnic ZABAGED. Hodnota Geoid offset je již vypočtena přímo v pracovním prostředí funkce, pro jistotu však byla ověřena pomocí Geoid Height Calculator poskytovaným organizací UNAVCO. Pro území pokryté snímkem se hodnota Geoid offset, která představuje rozdíl mezi střední hladinou moře a povrchem geoidu, rovnala cca +47 m. Jak lze vidět na Obrázku 9, po ortorektifikaci již poloha bodů na snímku odpovídala jejich reálnému zaměření.

Obrázek 9: Poloha nasbíraných bodů po ortorektifikaci



Zdroj: tvorba autora

Vegetační indexy

Největší přínos vegetačních indexů spočívá ve vytvoření jednopásmového obrazu reprezentujícího přítomnost a stav vegetace z různých kombinací pásem multispektrálních družicových dat (viz kapitola 2.4.3). Můžeme říci, že použití vegetačních indexů ve větší míře odstartovalo vypuštění družice Landsat v roce 1972. Právě pro účely studií pracujících se snímky z družice Landsat byly vytvořeny nejpoužívanější vegetační indexy jako NDVI, RGI, TVI a další. Tato diplomová práce má však k dispozici i velmi kvalitní snímek WorldView-2, který se od snímků Landsat liší v mnohém. Zajímavé pro hodnocení vegetačních indexů je především nově přidané pásmo Red-Edge, pomocí kterého by bylo možné upravit vegetační indexy přímo pro potřeby daného snímku a této studie.

Na snímcích Landsat 8 a WorldView-2 bylo testováno několik poměrových indexů, jejichž přehled lze vidět v Tabulce 3. Definované vegetační indexy byly použity především pro tvorbu klasifikační báze při klasifikaci OBIA, zároveň však hrály důležitou roli u počátečních fází přípravy snímku např. při ověřování trénovací množiny.

Tabulka 3: Použité vegetační indexy

Vegetační index	Definice	Číslo kanálu	
		WV2	L8
NDVI	$NDVI = (NIR-RED)/(NIR+RED)$	7; 5	5; 4
RGI	$RGI = RED/GREEN$	5; 3	5; 4
SAVI	$SAVI = (1+L)*(NIR-RED)/(NIR+RED+L)$	7; 5	5; 4
EVI	$EVI = G*(NIR-RED)/(NIR+C1*RED-C2*BLUE+L)$	7; 5; 2	5; 4; 2

Zdroj: Adamczyk, Osberger (2015); Joshi (2011); Matsushita et al., (2007), upraveno autorem

4.4 Klasifikace

4.4.1 Legenda

Před samotnou klasifikací snímku bylo třeba určit legendu a definovat jednotlivé klasifikační třídy. Samotná legenda vycházela především z terénního šetření a z literárních zdrojů zabývajících se vlivem jednotlivých stádií napadení kůrovcem na lesní porosty. Většina klasifikačních systémů používá pro klasifikaci lesů pouze tři třídy (jehličnatý, smíšený, listnatý), což pro naše účely nepostačuje. Především díky vhodným datům WorldView-2 s vysokým prostorovým rozlišením a 8 spektrálními pásmy bylo možné stanovit legendu podrobnější.

Zkoumané území je velmi heterogenního charakteru s výskytem velkého počtu různých stádií lesa, ať už napadeného kůrovcem či zdravého, byla tedy potřeba jistá míra generalizace pro stanovení vhodného počtu kategorií lesa. Stanoveno bylo 9 kategorií, z nichž 3 kategorie jsou nelesního charakteru, a 6 kategorií charakterizuje lesní vegetaci.

Poměrně důležitou roli při klasifikaci dat WorldView-2 hraje čas jejich pořízení. Zkoumaný snímek byl nasnímán v září v 10 hod 33 min, tedy za azimutu 170° a výšky slunce 43°. Z tohoto důvodu bylo nutné vyřešit problematiku stínů, které se na snímku ve velké míře vyskytovaly a ovlivnily by tak výstupní klasifikaci. Spektrální projev stínů se obecně blíží vodním plochám, což bylo ověřeno generováním spektrálních

profilů na daných místech a jejich porovnáním s jinými třídami. Přiřazení stínů ke kategorii vodních ploch následně potvrdily i hodnoty vegetačních indexů.

Vzhledem k nižšímu prostorovému rozlišení snímku Landsat 8 byla legenda upravena na 8 kategorií. Vynechána byla třída vodních ploch, která je na snímku reprezentována jezírky v klečových porostech, jejichž rozměr byl pod stanovenou minimální mapovací jednotkou (30 x 30 m).

1. Zdravá lesní vegetace (Třída A1)

Třída představuje zdravý nepoškozený les, na kterém nejsou patrné známky poškození či napadení kůrovcem. Lesní vegetace v této kategorii zahrnuje stromy s větší hustotou zastoupení tak, že koruny tvoří souvislý zápoj, viz Obrázek 10. Díky tomu jsou do kategorie zahrnuty stromy od cca 6 metru výšky. Na zkoumaném území se vyskytoval nejen jehličnatý, ale i listnatý les o rozloze cca 0,5 km². Vzhledem k takto malé ploše vůči celkové rozloze snímku a zároveň k povaze výzkumu byl listnatý les zařazen také do této kategorie.

Obrázek 10: Letecký snímek a fotografie třídy A1



Zdroj: URL 7, tvorba autora

2. Napadená lesní vegetace (Třída A2)

Kategorie napadené lesní vegetace zahrnuje vzrostlé stromy, které již vykazují značné známky poškození lýkožroutem smrkovým. Stromy v této kategorii mají vyšší hustotu zastoupení (cca 50 – 70 %), kde na některých místech můžeme hovořit téměř o „zápoji“ poškozených korun. To znamená především, že stromy mají ještě velkou část větví a některé i jehličí, i když již ve viditelně napadeném stavu (Obrázek 11). Třída zahrnuje fáze red-attack a grey-attack. Stádium red-attack se na snímku nachází ve většině případů v době jeho přechodu do fáze grey-attack. Jednotlivé zrelé a nahnědlé stromy jsou tak obklopeny většinou mrtvých a šedých stromů. Především díky tomuto důvodu byly obě stádia napadení zařazeny do jedné třídy. Podloží napadeného lesa tvoří traviny, popadané větve či kmeny, mechové porosty a borůvčí.

Obrázek 11: Letecký snímek a fotografie třídy A2



Zdroj: URL 7, tvorba autora

3. Regenerující lesní vegetace (Třída A3)

Třída regenerujícího lesa je z hlediska celého území velmi heterogenní. Všeobecně ji charakterizují malé smrčky v hustotě cca 10 stromů na 20 m², viz Obrázek 12. Tyto mladé stromy, jejichž výška nepřekračuje 6 m, jsou nerovnoměrně rozseté mezi ojedinělými pahýly mrtvých stromů a není u nich ještě patrný zápoj korun. Podloží bývá převážně složené z vysokých travin, mechů a popadaných kmenů.

Obrázek 12: Letecký snímek a fotografie třídy A3



Zdroj: URL 7, tvorba autora

4. Mrtvý les (Třída A4)

Lesní porosty v kategorii mrtvý les charakterizují pahýly mrtvých vzrostlých stromů, které již nemají téměř žádné větve a jsou rozmístěny velmi sporadicky po dané ploše. Na zemi se nachází velké množství kmenů, větví a vývrátů. Suché stromy jsou popadané z velké míry díky silným větrům (Obrázek 13). Podloží tvoří vysoké traviny. Spektrální projev třídy se velmi blíží holé půdě.

Obrázek 13: Letecký snímek a fotografie třídy A4



Zdroj: URL 7, tvorba autora

5. Slatě (Třída B)

Specifickou třídou pro území NP Šumava jsou jistě horská vrchoviště či slatě, které mají na snímku hojné zastoupení. Dominující vegetací ve slat'ových porostech je kleč a vodomilné rostliny. Plochy slatí jsou podmáčené a mají většinou specifický oválný či kulatý tvar s vodní plochou uprostřed (Obrázek 14). Spektrální projev této třídy je velmi podobný zdravému lesu.

Obrázek 14: Letecký snímek a fotografie třídy B



Zdroj: URL 7, tvorba autora

6. Lesní paseky a holoseče (Třída C1)

Lesní paseky a louky charakterizují volně rostoucí traviny na plochách bez výskytu stromů. Na pasekách se můžeme setkat s pařezy, suchými větvemi a povětšinou drnovým pokryvem (Obrázek 15). Do třídy jsou zahrnuty i plochy mrtvého lesa vytěženého od lesníků od větví a kmenů popadaných na zemi či holoseče.

Obrázek 15: Letecký snímek a fotografie třídy C1



Zdroj: URL 7, tvorba autora

7. Louky (Třída C2)

Do kategorie luk řadíme hospodářsky využívané plochy sečených travinatých porostů povětšinou v okolí zástavby.

8. Vodní toky a plochy (Třída E)

Kategorie zahrnuje větší vodní toky a plochy vyskytující se na snímku. Především se tedy jedná o Roklanský potok či Vydru a jezírka nacházející se ve slat'ových porostech. Do kategorie spadají i stíny vyskytující se na snímku.

9. Zástavba a zpevněné plochy (Třída F)

Zástavba se na snímku vyskytuje v poměrně malém procentu, z hlediska klasifikace je však důležité ji oddělit jako samostatnou třídu. Do kategorie řadíme i zpevněné plochy tedy např. parkoviště či komunikace.

4.4.2 Trénovací množina

Pro řízenou klasifikaci, jako je SVM, je výběr trénovací množiny naprosto zásadní. Na základě těchto bodů či polygonů pak algoritmus staví klasifikaci celého obrazu. Vzhledem k velkému vlivu trénovacího souboru na celkovou úspěšnost klasifikace je nezbytným krokem provedení analýzy jeho kvality.

Software ENVI nabízí řadu možností, jak nasbírané body zájmu (Region Of Interest – ROI) hodnotit. Jednou z nich je například maximální míra separability (*Compute Separability*). Tato metoda řeší separabilitu skrze transformovanou odchylku, což je výpočet vážené vzdálenosti mezi průměrnými vektory uvažovaných tříd, tedy jednodušeji řečeno počítá spektrální odlišnost mezi vybranými ROI páry. Spočtená hodnota se pohybuje od 0 do 2 a udává, jak dobře jsou vybrané ROI statisticky odlišné. Hodnoty větší než 1,9 udávají, že ROI páry jsou statisticky dobře odlišitelné. Naopak hodnoty pod 1 říkají, že kategorie se budou překrývat.

Další možností, jak ROI hodnotit, je tzv. n-D visualizer, pomocí kterého můžeme pozorovat shluky jednotlivých tříd v podobě pixelů. Jednotlivé ROI lze v nástroji i upravovat výběrem vhodných pixelů, které se nepřekrývají s jinou třídou.

Vzhledem k tomu, že naměřené body v terénu vykazovaly velmi malou separabilitu, byla trénovací množina nasbírána nad ortofotem. Výběr bodů byl pak následně ověřen i pomocí vegetačních indexů a kombinací spektrálních pásem. Byly nalezeny reprezentativní body pro každou třídu klasifikace (viz Příloha 2). Počet trénovacích bodů pro jednotlivé třídy se pohyboval od 11 pro třídu zástavba do 27 pro třídu mrtvý les (Tabulka 4).

Tabulka 4: Trénovací body

Třída	A1	A2	A3	A4	B	C1	C2	E	F	celkem
Počet bodů	25	24	20	27	16	23	11	11	11	168

Zdroj: tvorba autora

4.4.3 Support Vector Machine

Použití Support Vector Machine klasifikátoru zahrnuje nejen vhodný výběr trénovací množiny, ale i výběr vhodných parametrů vstupujících do klasifikace. V softwaru ENVI je možné zvolit typ Kernelovy funkce (lineární, RBF, sigmoidní a polynomiální), dále je možné nastavit hodnotu γ parametru (pro lineární a RBF funkci), penalty parametru a také prahovou hodnotu.

Penalty parametr

Penalty parametr definuje rozsah povolených chyb (Camps-Valls et al., 2004). Jinými slovy umožňuje ovládat určitý stupeň špatného zařazení pixelu ke třídě. Volba vysoké hodnoty parametru bude SVM klasifikátor nutit k minimalizaci chyb a tudíž k přesnější klasifikaci, to bude mít naopak za následek menší míru generalizace. V programu ENVI je možné volit hodnoty od 0,01 do 100.

Kernelova funkce

Jádrová transformace prostoru příznaků slouží k transformaci lineárně neseparovatelné úlohy na lineárně separovatelnou při hledání dělicí nadroviny. Software ENVI nabízí čtyři možnosti výběru funkce a to lineární, polynomiální, RBF (Radial Basis Function) a sigmoidní. V Tabulce 5 jsou uvedeny jádrové funkce K pro jednotlivé transformace.

Tabulka 5: Kernelovy transformace

transformace	matematický vzorec
Lineární funkce	$K(x_i, x_j) = x_i^T x_j$;
RBF	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$, $\gamma > 0$
Polynomiální funkce	$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d$, $\gamma > 0$
Sigmoidní funkce	$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

Zdroj: ENVI, (γ – gamma parametr, d – polynomiální stupeň, r – bias term)

Parametr γ definuje šířku působnosti každého samostatného trénovacího příkladu. Nižší parametr gamma povolí klasifikátoru pohybovat se ve větším okruhu kolem trénovacího pixelu. Je možné volit pro něj hodnoty od 0,01 do 1000. Defaultní hodnota nabízená v programu ENVI je inverzní k počtu pásem vstupujících do procesu.

Parametry zvolené do procesu v této práci vychází především z již otestovaných kombinací použitých v literatuře (např. Hromádková, 2015), které podávaly kvalitní výsledky (viz Tabulka 6).

Tabulka 6: Aplikované parametry SVM na snímky L8 a WV2

Kombinace	Kernel function	Gamma parametr	Penalty parametr	Prahová hodnota	Stupeň polynomu
1	RBF	10	50	0	-
2	RBF	default	90	0	-
3	RBF	default	100	0	-
4	polynomial	default	90	0	6
5	polynomial	default	100	0	6

Zdroj: tvorba autora (pozn. hodnota default - snímek Landsat 8 $\gamma = 0,143$, snímek WorldView-2 $\gamma = 0,125$)

4.4.4 Neural Networks

Klasifikační metoda neuronových sítí tvoří vrstvu neuronů dle vstupních spektrálních kanálů, které do ní vstupují. Výstupní vrstva se pak skládá z neuronů, kde každý představuje jednu z klasifikovaných tříd. Prováděná klasifikace neuronových sítí představuje typ vícevrstvé dopředné sítě a pro učení se používá algoritmus zpětného šíření.

Program ENVI, kde byla klasifikace prováděna, umožňuje volbu několika parametrů, pomocí nichž je možné ovlivnit výsledek a proces tvorby neuronové sítě.

Training Threshold Contribution (TTC)

Parametr TTC ovlivňuje vnitřní váhy jednotlivých uzlů sítě. Minimální hodnotou, kterou lze zvolit, je 0, při této hodnotě neprobíhá žádná změna vnitřních vah uzlů. Pokud naopak zvolíme hodnotu velmi vysokou (maximum = 1), může síť ztratit schopnost správně generalizovat.

Training Rate (TR)

Training Rate hodnota stanovuje změny vah neuronové sítě. Její rozmezí je stejně jako TTC od 0 do 1. Pomocí parametru TR lze urychlit proces trénování, což sebou bohužel nese vyšší riziko oscilací a tedy větší pravděpodobnost nejednoznačného výsledku trénovacího procesu.

Training Momentum (TM)

Pomocí TM parametru lze ovlivnit riziko oscilací vyplývající z předchozího parametru TR. Volba vyšších hodnot než nuly umožní urychlit proces trénování bez oscilací, může však způsobit nestabilitu trénovacího procesu.

Volit je možné i počet skrytých vrstev (*Number of Hidden Layers*), který se obecně doporučuje stanovit na jednu až dvě vrstvy (Camps-Valls et al., 2004; Šíma a Neruda, 1996). Dále je možné nastavit počet iterací parametrem *Number of Training Iterations* či hodnotu směrodatné odchylky parametrem *Training RMS Exit Criteria*. Fáze trénování pak probíhá do té doby, než dosáhne zadaného počtu iterací či dokud neklesne hodnota směrodatné odchylky pod daný práh. Předčasné ukončení procesu na základě dosažení prahové hodnoty nebylo umožněno, tedy RMS parametr byl nastaven na hodnotu 0. Dané parametry ve velké míře ovlivňují chování celého procesu, proto jejich výběru byla věnována dostatečná pozornost. Dle literatury (např. Oubrechtová (2012)) bylo otestováno více variant nastavení parametrů a dle výsledků byly vybrány nejpřesnější vzorky (viz Tabulka 7).

Tabulka 7: Aplikované parametry NN na snímky L8 a WV2

Kombinace	TTC	TR	TM	Počet iterací	Počet skrytých vrstev
1	0.2	0.2	0.4	1000	1
2	0.3	0.2	0.5	1000	1
3	0.1	0.2	0.5	1000	1
4	0.2	0.2	0.4	5000	1
5	0.3	0.2	0.5	5000	1

Zdroj: tvorba autora

4.4.5 Segmentace

Objektová klasifikace se snaží na základě objektů (segmentů) co nejvíce napodobit vizuální interpretaci za pomoci různých počítačových procedur. Je tedy nezbytné se více zaměřit na správné definování a vyčlenění objektů tak, aby co nejvíce odpovídaly účelu klasifikace a zároveň skutečnosti. Dle literatury je vhodná segmentace limitující podmínkou k dosažení úspěšné objektové klasifikace (Baatz, Shäppe, 2000).

Z mnoha algoritmů nabízených v programu eCognition k segmentaci je nejvíce využívanou a prověřenou metodou *Multiresolution segmentation*. Patří mezi nejsložitější metody segmentace a daným algoritmem umožňuje provádět segmentaci obrazu nezávisle na jeho rozlišení a počtu kanálů. Jedná se o segmentační metodu typu bottom-up, tedy na začátku procesu vnímáme jako objekty samotné pixely. Pro dosažení výsledné sítě homogenních objektů je možné volit hodnoty několika parametrů.

Jejich celkovým účelem je dosažení definovaného prahu spektrální a tvarové heterogenity (Trimble, 2012).

Spektrální heterogenita (*hcolor*) je popsána vzorcem:

$$h_{color} = \sum_{k=1}^n w_k \sigma_k$$

kde σ_k je směrodatná odchylka hodnot pásma k

w_k je váha pro pásmo k

n je počet segmentovaných pásem

V programu eCognition je možné upravit spektrální heterogenitu přiřazením vah jednotlivým spektrálním pásmům, pomocí čehož můžeme upřednostnit důležitost jednoho pásma před ostatními. Snímek WorldView-2 nabízí celkem 8 pásem, z nichž byla vybrána pásma Green, Red-Edge a NIR, která ukazují o stavu vegetace nejvíce informací a byla jim přidělena vyšší váha (2) než pásmům zbylým. U snímku Landsat 8 byla ponechána všem spektrálním pásmům totožná váha (1).

Tvarová heterogenita (*hshape*) může být vyjádřena dvěma složkami: kritériem kompaktnosti (*hcomp*) a kritériem hladkosti (*hsmooth*):

$$h_{comp} = \frac{l}{\sqrt{n}}; \quad h_{smooth} = \frac{l}{b}$$

$$h_{shape} = w_{comp} h_{comp} + (1 - w_{comp}) h_{smooth}$$

kde l je obvodová délka hraniční linie segmentu


n je velikost segmentu měřená v pixelech

b je nejkratší délka obvodu čtyřúhelníku, opsaného obrazovému segmentu

w_{comp} je váha pro kritérium kompaktnosti, uživatelem definovaná v rozmezí od 0 do 1

Tvarovou heterogenitu je možné upravit pomocí kritéria *shape*, na jejímž základě je dopočtena hodnota spektrálního kritéria jako doplněk do 1. Na stejném principu pracuje i parametr kompaktnosti (*compactness*), dle kterého je dopočtena hodnota hladkosti (*smooth*) také jako doplněk do 1. Při volbě vysoké hodnoty pro spektrální kritérium dochází k vytváření objektů s nepřirozeným tvarem hranic (viz Obrázek 16), je proto nutné zvolit hodnoty tak, aby výsledné objekty měly přijatelný tvar a zároveň v nich nebyly pixely s naprosto odlišnou spektrální informací.

Obrázek 16: Tvarová heterogenita s vyznačenými problémovými segmenty



Zdroj: tvorba autora (A: $shape=0,2$, B: $shape=0,6$)

V případě zvoleného území byla pro snímek WorldView-2 vybrána hodnota 0,3 pro tvarové kritérium a 0,7 pro spektrální kritérium. Pro parametr kompaktnosti bylo vyzkoušeno několik kombinací pro nalezení nejvhodnější hodnoty. Při volbě vyšších hodnot pro hladkost docházelo k tvorbě segmentů s velmi nepřirozeným a složitým tvarem, proto byly zvoleny hodnoty pro kompaktnost 0,7 a pro hladkost 0,3. Pro snímek Landsat 8 byly zvoleny hodnoty vypsány v Tabulce 8.

Tabulka 8: Parametry segmentace snímků L8 a WV2

Snímek	Tvarové kritérium	Spektrální kritérium	Kompaktnost	Hladkost	Měřítko
WorldView-2	0.3	0.7	0.7	0.3	40
Landsat 8	0.4	0.6	0.6	0.4	30

Zdroj: tvorba autora

Jako poslední lze zvolit měřítkový parametr (*scale*), který pracuje s odmocninou celkového kritéria sloučení objektů (f) daného vztahem:

$$f = w_{color}h_{color} + (1 - w_{color})h_{shape}$$


$$scale \geq \sqrt{f}$$

kde w_{color} představuje váhu pro spektrální kritérium definovanou uživatelem

Jak plyne z uvedených vzorců, *scale* parametr ovlivňuje velikost výsledných objektů. Vzhledem k velké heterogenitě vegetačního pokryvu na území NP Šumava bylo velmi náročné vybrat vhodný měřítkový parametr tak, aby vyhovoval celému zkoumanému území. Vysoká hodnota měřítkového parametru například nebyla vhodná pro oblasti mrtvého a obnovujícího lesa, kde docházelo ke slučování rozdílných tříd do jednoho segmentu. Naopak oblasti s výskytem luk či klečových porostů nižší hodnoty měřítka zbytečně dělily na malé segmenty (viz Obrázek 17).

Po důkladném testování různých variant byla nejlépe vyhodnocena hodnota $scale = 40$ pro snímek WorldView-2 a hodnota $scale = 30$ pro snímek Landsat 8.

Obrázek 17: Scale parametr s vyznačením problémových segmentů



Zdroj: tvorba autora (A: $scale = 60$, B: $scale = 30$)

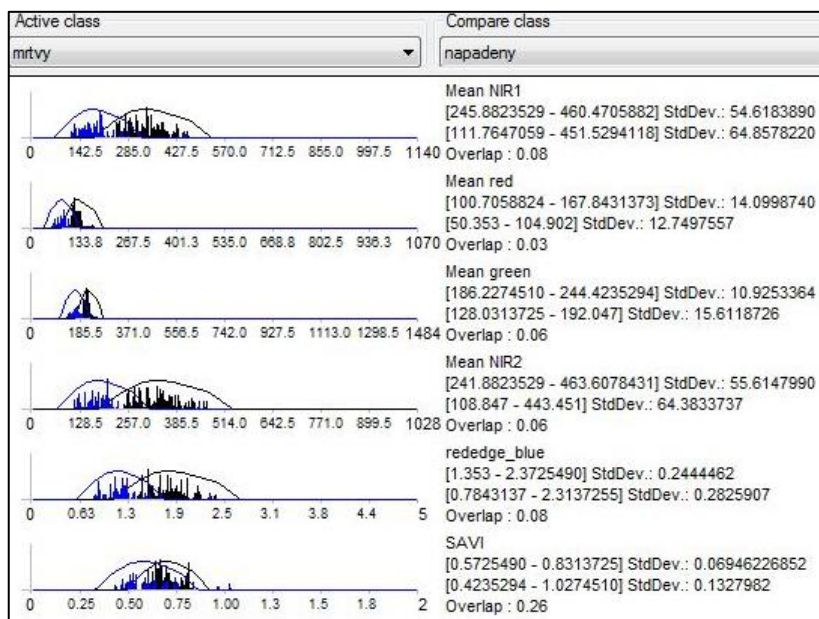
4.4.6 Tvorba klasifikační báze

Vhodně definované segmenty vytvořené na základě dat z družicového snímku nám umožňují sestavit klasifikační bázi a klasifikovat družicový snímek. Zvolenou metodu rozhodovacího stromu lze v programu eCognition tvořit v panelu *Process Tree*, kde je možné tvořit nové třídy a definovat jejich parametry. Tato metoda byla zvolena především kvůli možnosti jednodušeji iterovat procesy a řetězit nástroje založené na poloze daných segmentů (např. hranice). Mezi výhody patří i snazší hodnocení přesnosti jednotlivých kroků a jejich vlivu na celkový proces.

Na začátku tvorby rozhodovacího stromu je množina všech dat, které je možné dělit do dalších podskupin dle podmínky, zda daný parametr splňuje či ne. Pro stanovení vhodných prahových hodnot lze využít v programu eCognition více nástrojů. V případě této práce bylo nejvíce využito panelu *Feature View* a *Sample editoru*. Panel *Feature View* umožňuje u jednotlivých příznaků (např. NDVI) posouvat práh hodnot a zobrazit tak segmenty, které budou zahrnuty do vybraného intervalu.

Sbírání a editace vzorků, jak lze *Sample editor* označit, funguje na opačném principu. Pokud je možné zjistit u vybraných segmentů, do jaké kategorie by měly být zařazeny (např. na základě trénovacích dat), je možné je použít jako tzv. *Samples*. Po jejich nasbírání pak v nástroji *Sample editor* můžeme porovnávat třídy mezi sebou a vytvořit si tak určitou databázi vzorků, u nichž známe jejich projev v rámci daných příznaků. Na Obrázku 18 je tak např. vidět projev mrtvého lesa a napadeného lesa v rámci sledovaných indexů a vybraných spektrálních pásem na snímku WorldView-2.

Obrázek 18: Zobrazení tříd A4 a A2 v nástroji Sample editor



Zdroj: tvorba autora

Prvním krokem klasifikační báze se stalo oddělení kategorií nepředstavujících vegetaci, tedy vody a zástavby (třídy E a F). K tomuto účelu bylo využito indexu SAVI a také pásma blízkého infračerveného záření. Díky oddělení těchto kategorií bylo možné dále klasifikovat pouze vegetaci.

Dalším krokem se stalo hledání pravidla pro oddělení třídy C1 a třídy C2 od kategorií lesního porostu. Nejlepší výsledky přinesl vegetační index EVI, který vyčlenil obě kategorie při $EVI > 0$. Následné oddělení hospodářsky využívaných luk (třída C2) od třídy C1 bylo provedeno s použitím indexu RGI.

Zásadní pro výzkum práce bylo samozřejmě rozlišení tříd lesa, tedy A1 – A4 a kategorie B. Při vymezování těchto kategorií bylo možné uvažovat o dvou skupinách tříd, v rámci kterých kategorie vykazují velmi podobné spektrální charakteristiky, a je tedy složitější najít vhodný příznak k jejich rozlišení. Jednu skupinu tvoří zdravé lesní porosty a slatě, druhou skupinu pak napadená lesní vegetace a již mrtvý les. Na hranici těchto dvojic je možné umístit obnovující se lesní porost, který ještě díky nízké výšce netvoří zápoj a vykazuje tak spektrální chování podobné třídám A2 i A3.

Nejlepší výsledky, po otestování více variant nastavení prahových hodnot, byly dosaženy s pomocí indexů RGI a NDVI, díky kterým se podařilo definovat všechny kategorie lesů. Kategorie klečových porostů vykazovala téměř shodnou spektrální charakteristiku jako zdravé lesy a i díky velmi suchému období před nasnímáním snímku nebylo možné využít speciálních charakteristik indikujících vlhkost vegetace a půdy k odlišení této třídy. Kategorie B byla díky těmto důvodům zahrnuta do třídy A1.

Pro konečné zpřesnění klasifikační báze byly použity nástroje *Class-Related features*, které umožňují zohlednit v klasifikaci i jednotlivé vztahy mezi objekty, jako je například hranice objektu či vzdálenost. Konkrétní hodnoty použité v rámci rozhodovacích stromů jsou zobrazeny v Přílohách 3 a 4.

4.5 Hodnocení přesnosti

Před hodnocením přesnosti klasifikací byly výsledné výstupy ze snímku WorldView-2 upraveny pomocí nízkofrekvenčního mediánového filtru o velikosti 5x5 pixelů (*Filter - Convolutions and Morphology – Convolutions – Median*), který pomohl odstranit izolované pixely.

Přesnost klasifikací je možné zhodnotit na základě chybové matice a kappa koeficientu. Chybová matice zahrnuje několik možných hodnocení přesnosti. V první řadě je to *celková přesnost* (overall accuracy – OA), která je definovaná jako poměr celkového počtu správně klasifikovaných pixelů a celkového množství klasifikovaných pixelů.

Dále je také možné odvodit chybovou matici pro každou třídu. První možností je hodnocení pomocí *zpracovatelské přesnosti* (producer accuracy - PA), tedy poměrem správně klasifikovaných pixelů a reálným počtem pixelů dané třídy z kontrolních bodů. V praxi nám zpracovatelská přesnost říká, že pokud dosáhneme například 89 % PA v kategorii lesů, tak 89 % pixelů, které jsou ve skutečnosti lesem, bylo vyklasifikováno do této třídy. Druhou možností hodnocení je pak *uživatelská přesnost* (user accuracy - UA), která udává pravděpodobnost, že pixel mající určitou třídní příslušnost opravdu do dané třídy spadá. Tedy pokud uživatelská přesnost třídy louka vychází například 95 %, znamená to, že 95 % pixelů označených jako louka v mapě je ve skutečnosti opravdu pokryto lučními porosty.

Kappa koeficient, porovnává přesnost klasifikace (PP) s přesností náhodného zařazení pixelů do tříd (PO) dle poměru:

$$K = \frac{(PP - PO)}{(1 - PO)}$$

Výsledné hodnoty Kappa koeficientu se pohybují od 0 do 1. Výsledkem je pravděpodobnost, s jakou se klasifikační metoda vyhnula chybám, které by nastaly při pouhém náhodném přiřazování tříd jednotlivým pixelům.

Přesnost klasifikací byla hodnocena pomocí bodů nasbíraných v terénu (viz Příloha 2), které je v SW ENVI 4.7 možné využít pro metodu Ground Truth ROIs (*Classification – Post Classification – Confusion Matrix*). Vzhledem k povaze terénního měření, které bylo zaměřeno na problémové kategorie lesa, bylo třeba kontrolní body

doplnit body sesbíranými nad ortofotem o kategorie vodních ploch, zástavby a lučních porostů tak, aby byl vyvážený poměr bodů pro všechny třídy, viz Tabulka 9. Abychom zabránili nadhodnocení výsledků, nebyl žádný z trénovacích pixelů využitý jako kontrolní pixel pro hodnocení přesnosti.

Tabulka 9: Kontrolní body

Třída	A1	A2	A3	A4	B	C1	C2	E	F	celkem
Počet bodů	20	16	12	17	10	15	6	7	6	109

Zdroj: tvorba autora

Pro srovnání výsledků klasifikací ze snímků WV2 a L8 bylo využito zejména informací získaných při terénním výzkumu. Již v průběhu sbírání kontrolních bodů byly v zájmové oblasti vytipovány možné problematické oblasti pro jednotlivé kategorie. Při porovnávání výsledků klasifikací zkoumaných snímků pak bylo přihlíženo především k těmto lokalitám, které se nacházely ve větší míře kolem kontrolních bodů. Mezi další ukazatele, hodnotící použitá klasifikovaná data, pak byly zařazeny např. přesnosti jednotlivých tříd či jejich relativní zastoupení.

Poměrně důležité je upozornit na výsledné hodnocení přesnosti objektové klasifikace, kde bylo provedeno hodnocení stejným procesem jako u NN a SVM. V literatuře se tímto problémem zabývali např. Ke, Quackenbush a Im (2010), kde autoři upozorňují na rozdíl hodnocení správného zařazení pixelů a segmentů, které mají každý jinou velikost. Logicky bychom tak měli udělit špatně zařazenému většímu objektu vyšší váhu než menšímu. I přes tyto zmiňované nedostatky bylo rozhodnuto použít výše zmiňované metody, které jsou tradičně používanými metodami hodnocení přesnosti (např. Ozdemir et al., 2005).

5 VÝSLEDKY

Tato kapitola popisuje a shrnuje výsledky získané v průběhu zpracování diplomové práce. Jsou zde zhodnoceny a porovnány výsledky klasifikací multispektrálních snímků WorldView-2 a Landsat 8, kterých bylo dosaženo aplikací výše popsané metodiky. Cílem práce bylo nalézt a následně vyklasifikovat vhodný počet kategorií lesních porostů postižených disturbancí tak, aby byla rozlišena jednotlivá stádia poškození či obnovy lesa na zvoleném území NP Šumava.

Klasifikace použitých snímků byla provedena pomocí algoritmů Support Vector Machine a Neural Network v pěti variantách nastavení parametrů. Kombinace parametrů, které dosáhly nejlepších výsledků, zobrazují Přílohy 8, 9, 11 a 12. Dále byla provedena objektová klasifikace za použití metody rozhodovacího stromu, jehož parametry jsou zobrazeny v Přílohách 3 a 4. Výsledky klasifikace OBIA obou snímků jsou vizualizovány v Přílohách 10 a 13.

5.1 Porovnání přesnosti klasifikací obrazových dat

Následující kapitola se bude zabývat hodnocením přesnosti testovaných klasifikací. Tato přesnost je reprezentována více ukazateli, mezi které patří celková přesnost klasifikace či Kappa index. Přesnost klasifikací zpracovávaných v programu ENVI (SVM a NN) byla vypočtena za pomoci funkce *Confusion Matrix* na základě bodů nasbíraných při terénním šetření. Celková přesnost klasifikací a vypočítaný Kappa index pro jednotlivé kombinace parametrů daného algoritmu jsou obsaženy v Tabulkách 10 a 11.

Tabulka 10: Celková přesnost a Kappa index klasifikace SVM

SVM	Parametry				WorldView-2		Landsat 8	
Kombinace	Kernel function	Gamma parametr	Penalty parametr	Stupeň polynomu	celková přesnost (%)	kappa index	celková přesnost (%)	kappa index
1	RBF	10	50	-	76.15	0.73	68.63	0.64
2	RBF	default	90	-	84.40	0.82	69.61	0.65
3	RBF	default	100	-	84.40	0.82	70.59	0.66
4	polynomial	default	90	6	84.40	0.82	70.59	0.66
5	polynomial	default	100	6	86.24	0.84	70.59	0.66

Zdroj: tvorba autora, (pozn. hodnota default - snímek Landsat 8 $\gamma = 0,143$, snímek WorldView-2 $\gamma = 0,125$)

Celková přesnost klasifikace SVM se pohybuje dle zvolené kombinace parametrů v rozmezí hodnot 76,15 % - 86,24 % pro snímek WV2 a 68.63 % - 70.59 % pro snímek L8. Jak vidíme, nejlepších výsledků bylo dosaženo za použití Kombinace 5, kde byla aplikována polynomiální funkce s defaultním nastavením parametrů dle programu ENVI. Nejhorší výsledky pak vykazuje Kombinace 1, kde bylo u funkce RBF více upraveno nastavení gamma parametru a penalty parametru oproti nabízeným hodnotám. Pokud porovnáme výsledky přesnosti zpracovávaných snímků WV2 a L8, je patrný vliv lepšího prostorového rozlišení a více dostupných spektrálních pásem u snímku WV2, jehož klasifikovaný obraz dosahuje celkové přesnosti o řád vyšší než u snímku L8.

Tabulka 11: Celková přesnost a Kappa index klasifikace NN

NN	Parametry				WorldView-2		Landsat 8	
	Kombinace	Training Threshold Contribution	Training Rate	Training Momentum	Počet iterací	celková přesnost (%)	kappa index	celková přesnost (%)
1	0.2	0.2	0.4	1000	80.73	0.78	67.65	0.63
2	0.3	0.2	0.5	1000	81.65	0.79	68.63	0.64
3	0.1	0.2	0.5	1000	81.65	0.79	69.61	0.65
4	0.2	0.2	0.4	5000	81.65	0.79	64.71	0.59
5	0.3	0.2	0.5	5000	78.90	0.76	65.69	0.60

Zdroj: tvorba autora

Pokud porovnáme výsledky algoritmu SVM s algoritmem NN (Tabulka 11), vidíme, že hodnoty celkové přesnosti NN jsou celkově nižší průměrně o 2,5 %. U obou zkoumaných snímků bylo dosaženo nejvyšší celkové přesnosti a kappa indexu při volbě Kombinace 3. Stejných hodnot celkové přesnosti pak dosáhly u snímku WV2 i Kombinace 2 a 4, což je s největší pravděpodobností odraz menšího počtu kontrolních bodů použitých k hodnocení přesnosti. Jak si lze povšimnout, i přes zvýšení počtu iterací nedošlo ke zlepšení výsledků a tudíž k větší přesnosti, naopak u Kombinace 5 je celková přesnost snímku WV2 nejnižší.

U klasifikace OBIA byla přesnost klasifikace měřena v programu eCognition na základě tvorby TTA mask. Výsledná celková přesnost a kappa index klasifikace OBIA je zobrazeny v Tabulce 12 pro oba použité snímky.

Tabulka 12: Celková přesnost a Kappa index klasifikace OBIA

družice	celková přesnost (%)	kappa index
WV2	72,73	0,67
L8	39,84	0,27

Zdroj: tvorba autora

Celkovou přesnost 72,73 % klasifikace snímku WV2 lze po přihlédnutí k vysoké heterogenitě vegetace na vybraném území označit za relativně kvalitní výsledek. To samé však nelze říci o klasifikaci snímku L8, kde bylo dosaženo celkové přesnosti 39,84 %, což je velmi nízká hodnota. V případě této klasifikace je nízká celková přesnost L8 odrazem mnoha faktorů, jako např. vyšší počet tříd v legendě, nižší prostorové rozlišení.

Z výsledné celkové přesnosti či kappa indexu si můžeme udělat hrubý a rychlý přehled o úspěšnosti klasifikace. Pro podrobnější výsledky a jejich lepší interpretaci je však třeba zohlednit například chybové matice (viz Přílohy 5 - 7), vizuální hodnocení i relativní zastoupení tříd, o čemž bude pojednáno v dalších kapitolách. V následujícím textu budou více rozebrány výsledky klasifikací s nejlepšími výsledky celkové přesnosti, tedy Kombinace 5 pro algoritmus SVM a Kombinace 3 pro algoritmus NN spolu s klasifikacemi OBIA.

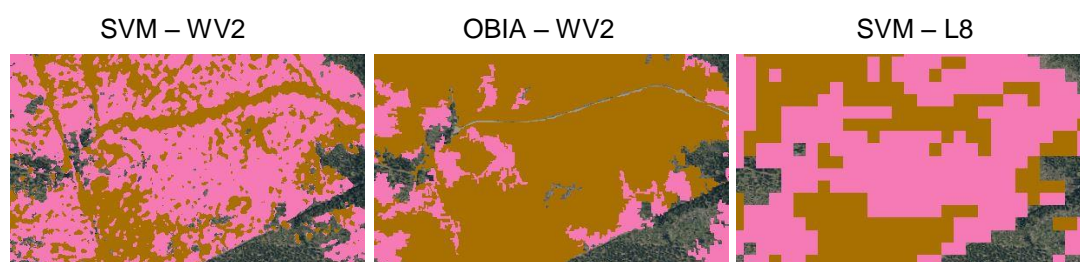
5.2 Výsledky klasifikací snímku WorldView-2 a Landsat 8

Původním předpokladem vycházejícím z hypotéz práce bylo očekávané komplikovanější rozlišení tříd lesních porostů v různých stupních jejich poškození a obnovy. Nejhorší výsledky byly předpokládány u tříd napadeného (A2), mrtvého (A4) a regenerujícího lesa (A3). U těchto kategorií se spektrální projev velmi prolíná s jinými třídami, díky čemuž byla očekávána jejich častější záměna mezi sebou či například s kategorií lesních pasek (C1). Tento předpoklad byl ve větší míře potvrzen a to především u klasifikace snímku WV2. U snímku L8 bylo rozložení chyb více rovnoměrné v celém spektru tříd, viz Příloha 6.

Jak se ukázalo v průběhu klasifikace, nejhůře oddělitelnými třídami se staly právě kategorie A1 - 4. Nejpřesněji tyto kategorie rozlišila klasifikace SMV snímku WV2, kde bylo dle chybové matice nesprávně zařazeno pouze 10 kontrolních pixelů z celkových 63 v rámci těchto tříd. Třída napadeného lesa A2 byla ve většině případů zaměněna za kategorii mrtvého lesa A4. Tento fakt je samozřejmě spojený s velmi tenkou hranicí mezi oběma třídami, zejména ve smyslu obsahového vymezení třídy (spektrální charakteristiky). Jak ukázaly výsledky, těžko oddělitelnými kategoriemi v rámci objektové klasifikace se staly i třídy A4 a C1, u kterých bylo dosaženo

uživatelské přesnosti 44 % a 60 %. Zejména pak plochy mrtvého lesa, kde se již nevyskytovalo větší množství popadaných kmenů, byly často řazeny do kategorie C1. Toto dokládá i Obrázek 19, který ukazuje klasifikaci těchto dvou kategorií v severní části zájmového území. U klasifikace OBIA snímku WV2 byl na vymezení kategorií C1 a C2 použit vegetační index RGI v kombinaci s indexem EVI, který je více citlivý k rozdílům na množství vegetace v hustě zalesněných oblastech a lépe odstraňuje vliv atmosféry nebo zemského povrchu pod vegetací (Matsushita et al., 2007). Na oddělení tříd C1 a C2 byl testován v OBIA i vegetační index NDVI, ten však dosahoval přesnosti o 5 – 8 % procent nižší než v případě použití indexů EVI a RGI.

Obrázek 19: Rozlišení třídy A4 a C1 klasifikací OBIA a SVM



Zdroj: tvorba autora, (pozn. růžová barva – třída A4, hnědá barva - třída C1)

Pokud se již les obnovil do té míry, že se na travnatém povrchu vyskytovala i vyšší vegetace, byl v klasifikačním systému určen jako třída A3. Nejlepších výsledků uživatelské přesnosti (UA) u kategorie A3 dosáhly dle chybových matic (Příloha 5 a 7) metody SVM a OBIA aplikované na snímek WV2. Za kategorii obnovujícího se lesa A3 byly nejčastěji zaměňovány třídy A1, A4 a C1 či C2, což se projevilo například v oblasti nízkých stromků a křovin při hranici zdravého lesa nebo v místech lesních světlin či průřezů. Jak je vidět na Obrázku 20, „rozdobenost“ kategorie A3 mírně snížila tvorba segmentů u objektové klasifikace, ale i menší prostorové rozlišení snímku L8.


Obrázek 20: Rozlišení třídy A1 a A3 klasifikací OBIA a NN



Zdroj: tvorba autora, (pozn. světle zelená barva – třída A3, tmavě zelená barva - třída A1)

Zajímavé výsledky přinesly klasifikace snímků v oblasti tříd slatí a zdravého lesa. Vzhledem ke klečovému porostu v oblasti vrchovišť a velmi suchému roku 2015 se kategorie B projevila na snímcích s téměř totožnými spektrálními vlastnosti jako kategorie A1. Tento fakt znemožnil třídu B rozlišit v procesu tvorby klasifikační báze při objektové segmentaci. Klasifikace SVM a NN snímku WV2 však rozlišily třídu B velmi kvalitně s téměř 100% přesností. U snímku L8 bylo taktéž dosaženo vysoké celkové přesnosti 90 %. Pokud však zhodnotíme celkový výstup z klasifikací L8 (Přílohy 11 a 12), vidíme, že slatě jsou velmi často na místech s výskytem jiné vegetace, nejčastěji zdravého a obnovujícího se lesa. Chybně určené pixely se nacházejí ve větší míře na okraji jiných kategorií, jak je vidět i na Obrázku 21.

Obrázek 21: Rozlišení třídy B klasifikací SVM



Zdroj: tvorba autora, (pozn. červeně vyznačena oblast slatí, modrá barva – třída B)

Rozloha kategorie B je tak za použití algoritmu SVM na klasifikovaných snímcích L8 téměř dvojnásobná oproti klasifikaci snímku WV2. Tento jev je způsoben nižším prostorovým rozlišením snímku L8, kde v sobě pixely nosí informaci více typů vegetačních pokryvů a pro použité algoritmy SVM a NN je tak obtížné najít jednoznačné řešení.

5.3 Porovnání relativního zastoupení tříd v klasifikaci

Relativní zastoupení tříd je dáno poměrem plochy, která byla přiřazena k určité třídě, k celkové ploše klasifikovaného území. Procentuální porovnání zastoupení jednotlivých tříd krajinného pokryvu výsledných klasifikací snímku WorldView-2 je vyčísleno v Tabulce 13.

Jak vidíme v Tabulce 13, největší rozdíly mezi výsledky klasifikací můžeme najít v kategoriích A2, A3, A4 a C1. Jak již bylo zmíněno, třída B byla při tvorbě OBIA klasifikace zahrnuta pod třídu A1, bylo proto očekáváno, že relativní zastoupení třídy A1 bude o tato procenta vyšší než u klasifikací SVM a NN. Jak však v Tabulce 13 vidíme, podíl třídy A1 v OBIA je naopak ze všech klasifikačních metod nejnižší.


Tabulka 13: Relativní zastoupení tříd u klasifikací snímku WV2

	SVM	NN	OBIA
třída	rozloha (%)	rozloha (%)	rozloha (%)
A1	28,9	27,5	26,6
A2	7,4	10,9	9,1
A3	24,6	31,5	30,2
A4	20,8	17,6	22,1
B	4,5	2,1	-
C1	12,0	8,2	10,7
C2	0,9	1,2	1,1
E	0,8	0,8	0,1
F	0,1	0,1	0,1

Zdroj: tvorba autora

Hodnoty kategorií A1 i A2 jsou u všech klasifikací na podobné úrovni (viz Tabulka 13). Rozloha třídy A3 je u algoritmu SVM nižší o cca 6 % než u zbylých metod. Na úkor této kategorie je však navýšena plocha lesních pasek C1. U algoritmů SVM a NN vidíme, že kategorie E je silně nadhodnocena oproti objektové klasifikaci. Tento fakt lze vysvětlit četným zastoupením stínů na snímku, které byly do třídy vodních ploch zařazeny. U klasifikace OBIA se však tvorbou segmentů menší plochy stínů přiřadily k jinému určenému vegetačnímu pokryvu a jejich celková plocha se tak výrazně zmenšila, viz Obrázek 22.


Obrázek 22: Třída E dle klasifikace SVM a OBIA snímku WV2



Zdroj: tvorba autora, (pozn. modrá: třída E - SVM, červená: třída E - OBIA)

Relativní zastoupení tříd na klasifikovaném snímku WV2 odpovídá ve své podstatě dosažené celkové přesnosti a dalším ukazatelům úspěšnosti klasifikace. Zajímavé srovnání přináší Graf 1, kde vidíme relativní zastoupení tříd pro klasifikace SVM a NN obou zpracovávaných snímků. Jak lze z Grafu 1 pozorovat, největší rozdíly v rámci jedné kategorie jsou u třídy A4, která představuje mrtvý les. Naopak u kategorií A1 a C1 je relativní zastoupení tříd u všech metod velmi vyrovnané a liší se maximálně o cca 5 %.

Graf 1: Relativní zastoupení tříd v klasifikacích SVM a NN



Zdroj: tvorba autora

U poměrů třídy B lze názorně pozorovat problém popsany výše, a to jak výrazně převyšují plochy slat'ových porostů u snímku L8 poměr u klasifikací snímků WV2. Díky tomu pak klesá relativní plocha u kategorií A1, A2 či A4. Největší relativní zastoupení na klasifikovaných obrazech snímku L8 zaujímá kategorie A3, která představuje obnovující se les.

6 DISKUZE

V této práci byly testovány tři pokročilé přístupy ke klasifikaci vegetace v rámci NP Šumava. Na zvolených družicových snímcích byla provedena klasifikace lesního porostu narušeného disturbancí s cílem rozlišení požadovaného počtu kategorií rozpadu a obnovy lesa. Dalším cílem práce pak bylo porovnání vhodnosti použitých dat Landsat 8 a WorldView-2 a zhodnocení jejich vlivu na výsledné výstupy klasifikací.

6.1 Data

Pro předloženou diplomovou práci bylo využito multispektrálních dat WorldView-2 a Landsat 8. Tyto dva snímky byly vybrány především kvůli jejich odlišnostem a možnosti zajímavého porovnání jejich vlastností. U snímku WorldView-2 s vysokým prostorovým rozlišením 1,82 m byla očekávaná vyšší přesnost v případě klasifikace heterogenní lesní vegetace. Dále bylo u snímku předpokládáno, že provedené klasifikace nad těmito daty budou schopny lépe odlišit menší plochy. Klasifikace snímku Landsat 8 s prostorovou přesností 30 m pak měla přinést poznání a porovnání s výsledky z klasifikací kvalitativně lepších dat. Ověřovaly se tak možnosti a omezení volně dostupných multispektrálních dat Landsat.

Velkou výhodou obou snímků byla jistě jejich bezoblačnost i již provedené radiometrické a geometrické korekce. Snímek WV2 však bylo nutné ortorektifikovat. Tento krok by bylo možné vynechat při použití snímků úrovně Ortorectified namísto OR2A. Vzhledem k pořízení snímku WV2 v podzimním termínu se na snímku nalézalo více zastíněných ploch vyskytujících se zejména podél zdravé vysoké vegetace. Tyto plochy byly v legendě přiřazeny k vodním plochám, což ovlivnilo výsledné zastoupení třídy E v klasifikaci. Pro účely srovnání výsledků bylo zapotřebí, aby byly použité snímky nasnímány ve stejném časovém období. Vzhledem k tomu, že oba snímky byly pořízeny v časovém období jednoho měsíce, byla tato podmínka splněna. Zkoumaný lesní porost tak s velkou pravděpodobností neprošel významnějšími změnami, které by se projevíly rozdílně na klasifikovaném obraze.

6.2 Legenda

Jedním z hlavních cílů této práce bylo stanovení vhodné legendy s dostatečným počtem tříd, které by charakterizovaly zkoumané území. Kategorie bylo nutné zvolit tak, aby pokryly celé spektrum rozpadu a obnovy poškozeného lesa.

Jednou z možností, jak zpřesnit proces klasifikace lesních porostů, je tvorba masky vegetace. Tuto metodu ve své práci zvolili např. Adamczyk a Osberger (2015) či Lihanová (2013). V případě této práce však bylo záměrem zahrnout do klasifikace

i třídy pasek, luk a holosečí, které mají blízký spektrální projev kategoriím mrtvého i regenerujícího lesa a zkoumané území tak klasifikovat uceleně. Především pro další práci s klasifikovanými snímky, například pro analýzu míry poškození lesa disturbancemi, je nezbytné zahrnout i plochy, kde byl les vytěžen lesníky (holoseč) či se obnovuje přirozenou cestou. Rozlišení těchto kategorií by pak mohlo pomoci i při monitoringu míry zásahu člověka do krajiny.

Jak již bylo v textu popsáno, fáze napadení lýkožroutem smrkovým s výrazným spektrálním projevem nazýváme red attack a grey attack. Ve vytvořené legendě jsou tyto dva stupně zahrnuty do třídy napadeného lesa (A2). Hlavním důvodem, proč bylo takto postupováno, byl aktuální stav lesa, kdy fáze red attack právě přecházela v grey attack a nebyla tak znatelná výraznější hranice mezi oběma fázemi. Kategorie mrtvého lesa (A4) pak zahrnuje následující fázi rozpadu lesa v literatuře často označovanou jako suchý les. Studie věnující se dané problematice člení napadené lesní porosty podobně na 2 – 3 kategorie. Jejich definice se však různí. Velmi často se lze setkat s dělením lesa na zdravý a suchý porost. Tyto kategorie zvolili např. Hájek a Svoboda (2007), kteří ke klasifikaci využili leteckých snímků. Podobné třídy ve své práci rozlišil Meddens et al. (2013), který použil snímek Landsat ke klasifikaci tříd nepoškozeného lesa a lesa ve fázi red attack. O jednu třídu více pak rozlišil Meddens, Jeffrey a Vierling (2011) za pomoci leteckých snímků. Jeho studie klasifikuje třídy zdravý les, poškozený les ve fázi red attack a mrtvý les bez jehlic. Stejně třídy klasifikují Dennison, Brunelle a Carter (2010), kteří využili snímek s vysokým prostorovým rozlišením GeoEye-1. Použití družicových dat s vysokým prostorovým rozlišením, jako je např. použitý snímek WorldView-2, je v literatuře poměrně aktuální. Právě dle snímků WV2 a RapidEye rozlišili Adamczyk a Osberger (2015) pět kategorií lesa postiženého disturbancí. Autoři třídy zdravý les, napadený les ve třech stupních rozpadu (c1 - 3) a mrtvý les klasifikovali za pomoci série vegetačních indexů na územích NP Šumava v Česku a NP Kalkalpen v Rakousku. Nevýhodou VHR dat je bohužel jejich obecně horší dostupnost, než je např. u volně stažitelných snímků Landsat.

Jak většina těchto studií dokazuje, je možné poměrně kvalitně oddělit více stádií rozpadu lesa. Nejdůležitějším aspektem u definování a stanovení tříd však zůstává účel využití dané klasifikace, ze kterého vyplyne, jak by se měla legenda orientovat. V případě předložené diplomové práce bylo při tvorbě legendy uvažováno její využití zejména pro monitoring lesního porostu po zásahu disturbačními událostmi. Z tohoto důvodu byl zařazen listnatý i jehličnatý les do kategorie A1, která představuje zdravou vysokou lesní vegetaci.

Specifickou kategorií pro území NP Šumava jsou slat'ové porosty a vrchoviště (třída B). Jak se ukázalo v rámci testování jednotlivých metod klasifikace,

spektrální projev této třídy velmi závisí na aktuálních fyzickogeografických podmínkách. Vzhledem k suchému létu 2015 bylo podloží pod klečovým porostem vysušené tak, že se třída jevila zejména u objektové klasifikace jako vysoký jehličnatý les. Zde by jistě bylo namístě uvažovat o použití dat LLS, která by umožnila oddělit tyto dvě kategorie. Tuto myšlenku ve své práci rozvinula Lihanová (2013), která s pomocí dat LLS oddělila vysoký zdravý les od nižšího vzrůstajícího lesa. Autorka však upozorňuje na potřebu vyšší hustoty mračna bodů pro dosažení optimálních výsledků.

6.3 Postup a výsledky

Za důležitou část klasifikace lze jistě označit tvorbu trénovací množiny. Je nezbytné, aby byly trénovací body pro jednotlivé třídy legendy početně i územně rovnoměrně rozložené. Zároveň je také nutné, aby byla trénovací množina vstupující do klasifikace naměřená ve stejném období jako je pořízení snímku (Carle, Sasser, Twilley, 2011). Pokud má zpracovatel studie k dispozici data z terénního šetření, je zde možné jejich použití jako trénovacích bodů. V případě této práce byly body naměřené v terénu testovány za pomoci separability, která však nedosahovala dostatečných hodnot, a ani pokrytí všech kategorií naměřenými body nebylo dostatečné. Díky těmto důvodům byly trénovací body nasbírány nad ortofotem v celkovém počtu 168 bodů a body naměřené v terénu byly použity jako kontrolní body. Dalším variantám tvorby trénovací množiny se ve své diplomové práci věnuje Hromádková (2015), která testovala možnosti náhodného generování bodů.

S vhodnou trénovací množinou již bylo možné snímky klasifikovat za použití algoritmů SVM a NN. Volba parametrů u těchto klasifikátorů vycházela především z vyzkoušených kombinací již realizovaných studií. Zejména zpracování klasifikace NN dle Oubrechtové (2012) bylo velmi přínosné. Autorka ve své práci porovnává až 77 variant nastavení parametrů Neural Network v programu ENVI a diskutuje jejich využití na snímku SPOT. Některé výsledky, které Oubrechtová (2012) uvádí ve své studii, se potvrdily i v případě této diplomové práce. Zejména pak fakt, že urychlení procesu trénování sítě NN nevede ke kvalitnějším výsledkům. Dále pak bylo třeba některé kombinace nastavení parametrů vícekrát opakovat, aby bylo dosaženo optimálních výsledků. Autorka se zamýšlí i nad zpřesněním výsledků za použití snímku s lepším prostorovým rozlišením či více spektrálními pásy, tento předpoklad se u dat WV2 nepotvrdil. I přes velmi podobné zájmové území a klasifikované třídy vycházela celková přesnost snímku WV2 o cca 5 % méně než na snímku SPOT.

U algoritmu SVM byl výběr hodnot pro nabízené parametry ovlivněn především zvolenou Kernelovou funkcí. Pro otestování byly vybrány funkce RBF a polynomální, které dle literatury (např. Kavzoglu, Colkesen (2009)) poskytovaly nejlepší výsledky.

U daných funkcí se hodnoty zvolených parametrů pohybovaly spíše v rámci jejich přednastavených hodnot, které, jak dokazují výsledky práce, podávaly nejpřesnější výsledky.

I přes nejnižší celkovou přesnost klasifikace lze říci, že je metoda objektové klasifikace vhodná pro hodnocení lesního porostu postiženého disturbancemi. Výhody jsou zde viděny zejména v eliminaci efektu „pepře a soli“. Dalším pozitivem je pak také řazení ploch stínů k určenému vegetačnímu pokryvu. U objektové klasifikace je však důležité dokonale se orientovat v zákonitostech hodnoceného území. Výsledná přesnost objektové klasifikace je limitována více faktory počínaje segmentací, která je velmi důležitým prvkem celé klasifikace. Tématu segmentace obrazu v rámci OBIA se ve svojí práci věnuje např. Dey (2011), který jí pokládá za nejdůležitější část celé klasifikace. Předmětu tvorby objektů se věnuje mnoho autorů, např. Hájek a Svoboda (2007), Hay et al. (2003), Blaschke, Burnett a Pekkarinen (2006) či Zhang et al. (2010), kde naprostá většina vyzdvihuje použití Multiresolution segmentation (multiměřítkovou segmentaci). Daný algoritmus umožňuje provádět segmentaci obrazu nezávisle na jeho rozlišení a je schopný se velmi dobře vypořádat s lokálními kontrasty v obraze. Tyto vlastnosti potvrdila i tato diplomová práce, kde bylo za pomoci multiměřítkové segmentace dosaženo jednoznačně nejlepších výsledků při porovnání s jinými segmentačními algoritmy.

Tvorba klasifikační báze velmi závisela na vhodném výběru vegetačních indexů. Na snímku WorldView-2 byly testovány i vegetační indexy s použitím nových spektrálních pásem (zejména red-edge). Nejlépe však klasifikované kategorie oddělovaly vegetační indexy s použitím klasických vstupních pásem. Více se tématu použití nového spektrálního pásma věnují Adamczyk a Osberger (2015), kteří testují vegetační indexy s použitím pásma red-edge na snímku WV2 a RapidEye. Pro finální klasifikační bázi byly použity indexy EVI, SAVI, NDVI a RGI. Vegetační indexy NDVI a RGI použila i Lihanová (2013), která s jejich pomocí klasifikovala 5 kategorií lesních porostů v NP Šumava. Na vhodnost těchto indexů pro odlišení napadeného lesa poukazuje i Hicke a Logan (2009) či Solberg et al. (2007). Výběru vhodných indexů a definování jejich prahových hodnot při tvorbě klasifikační báze bylo třeba věnovat mnoho hodin testování. Každé vytvořené pravidlo bylo nutné ověřit výpočtem přesnosti pro jednotlivé třídy a vybrat tak variantu nastavení prahování, která vykazuje nejlepší výsledky. Zejména pak u kategorií lesních porostů A1 – 4, bylo testováno více vegetačních indexů i jiných příznaků. Nejlepších výsledků však bylo vždy dosaženo za pomoci indexů NDVI a RGI, u kterých se celková přesnost pohybovala nad 70 %.

Výsledky objektové klasifikace jsou silně ovlivněny přístupem autora, který tvoří klasifikační bázi. Zásadní je i například pořadí, ve kterém probíhala klasifikace jednotlivých tříd. Změna pořadí pravidel v rozhodovacím stromu by způsobila rozdílné

řazení segmentů a klasifikace by se pak mohla stát nepoužitelnou. Tento fakt poukazuje na to, že metoda rozhodovacího stromu je značně subjektivní a její tvorba vyžaduje hlubší prozkoumání dat. Názorně lze rozdíl vidět u OBIA klasifikace snímku Landsat 8, kde bylo velmi obtížné najít pravidla, dle kterých by bylo možné klasifikovat větší množství tříd. Zde by jistě bylo na místě vytvořit masku vegetace a soustředit se pouze na lesní porosty.

Zajímavé poznání přineslo porovnání klasifikací z dat WV2 a L8. Jak již bylo zmíněno ve výsledcích práce, největší rozdíly mezi těmito snímky vykazovaly třídy A4, B a C1. Ve větší míře jsou tyto rozdíly způsobeny nižším prostorovým rozlišením snímku L8, kde v sobě pixely nosí informaci více typů vegetačních pokryvů. Nutno však říci, že odlišnosti mezi klasifikacemi obou snímků nejsou výlučně negativy. Zejména pro účely klasifikace, kdy uživatel nepotřebuje detailní přehled o zkoumaném území ale spíše hrubý přehled o poškození lesa je namístě vyzdvihnout data L8. Například kategorie napadeného lesa (A2), která dosahovala při klasifikaci SVM a NN na snímku L8 velmi kvalitních hodnot uživatelské i zpracovatelské přesnosti, jistě pro tyto účely postačí. Naopak použití klasifikace snímku WV2 by bylo možné doporučit spíše na indikaci prvních fází napadení lesa kůrovcem, kde je třeba detailní klasifikace, které lze dosáhnout právě s VHR družicovými snímky.

Jak vyplynulo z výsledků diplomové práce, zvolený metodický postup je vhodný pro zkoumání vegetace narušené disturbancemi. Jak však dokazují výstupy klasifikací z obou zkoumaných snímků, je obtížné přenést celý postup na jiná družicová data. To samé lze konstatovat i o zpracovávaném území. Vzhledem k aplikaci klasifikačních metod pouze na zájmové území NP Šumava nelze s určitostí říci, zda by bylo stejných výsledků dosaženo i na jiných územích. K tomu, abychom mohli předkládané závěry zobecnit, by bylo třeba celý postup testovat, jak na jiných typech dat, tak i na více zájmových územích. To však sebou nese vysoké časové nároky, neboť aplikované algoritmy se vyznačují poměrně dlouhou dobou zpracování.

Za nejlépe přenositelnou metodu bychom mohli označit algoritmus SVM, který vyžaduje při vstupu pouze vhodnou trénovací množinu a relativně snadno definovatelné vstupní parametry. Metody NN a OBIA pak vyžadují více zkušeností zpracovatele především ve smyslu detailního poznání dat a území. Například průběh samotné Neural Network klasifikace je velmi náchylný na počet pixelů u jednotlivých trénovacích množin, a to zejména u dat s menším prostorovým rozlišením. Pokud se například u jedné kategorie počet pixelů řádově liší, má klasifikátor tendenci přiřadit celý obraz k jedné třídě.

Pozitivní hodnocení algoritmu SVM dokazují i výsledné hodnoty celkové přesnosti, které u snímku WV2 dosahují 86 % a u snímku L8 71 %. Stejně tak stěžejní třídy

lesního porostu A1 - 4 dosáhly za použití SVM nejlepších výsledků uživatelské i zpracovatelské přesnosti. Algoritmus Neural Network snímku WV2 přinesl také velmi kvalitní výsledky, celková přesnost vyšla průměrně přes 80 %. U snímku L8 je pak patrný vliv menšího prostorového rozlišení na špatné klasifikaci třídy B i třídy F, což můžeme vidět v Příloze 12. Důvodem těchto nedostatků může být i nevhodné nastavení parametrů NN. Nevýhodou pixelových klasifikací je tzv. efekt pepře a soli neboli vznik osamocených pixelů. Pro určité potlačení tohoto efektu byl použit na klasifikaci SVM a NN snímku WV2 mediánový filtr s mřížkou 5x5. Toto opatření však neodstranilo všechny osamocené plošky. Zde je možné spatřovat jednu z velkých výhod objektové klasifikace, kde díky tvorbě segmentů není nutné problém osamocených pixelů řešit.

Výpočet přesnosti klasifikací vychází z kontrolních bodů, které byly naměřeny v zájmové oblasti NP Šumava za pomoci přístroje GPS. Vzhledem k časovým i prostorovým možnostem bylo naměřeno 80 bodů vystihujících vegetaci v této oblasti. Tyto body byly doplněny o vzorky zástavby a vodních ploch, jelikož terénní šetření bylo zaměřené na napadené lesní porosty. Výsledný počet kontrolních bodů činil 109 bodů. Nasbírané vzorky pokrývaly zvolené území poměrně rovnoměrně a jejich počet se ukázal jako dostatečný pro výpočet celkové přesnosti a dalších ukazatelů. Drobné rozdíly mezi testovanými kombinacemi parametrů už však nižší počet bodů nemohl odhalit. Z tohoto důvodu by při budoucí implementaci podobné metodiky mělo být uvažováno nad použitím více kontrolních bodů.

7 ZÁVĚR

Hlavním cílem diplomové práce bylo zhodnotit možnosti klasifikace lesních porostů postižených disturbancemi v NP Šumava. K tomuto účelu byly zvoleny družicové snímky WorldView-2 a Landsat 8. Na základě tvorby legendy měl být rozlišen dostatečný počet kategorií charakterizující poškozené lesní porosty v zájmovém území NP Šumava. Dalším cílem práce pak mělo být zhodnocení vstupních dat a porovnání jejich vlivu na prováděnou klasifikaci.

Diplomová práce v první části uvádí čtenáře do dané problematiky literární rešerší, která popisuje jak obecný projev vegetace v DPZ, tak i problematiku lesních porostů při jejich zásahu disturbancemi. Dále jsou zde představeny metody klasifikace obrazových dat a jejich použití v rámci lesních porostů. Hlavní část diplomové práce se věnuje zpracování multispektrálních snímků, tvorbě vhodné legendy a následné implementace vybraných algoritmů na zpracovávané družicové snímky.

Výsledná klasifikace vychází z legendy, která byla sestavená primárně pro účely rozlišení sledovaných stádií rozpadu a obnovy lesa po napadení lýkožroutem smrkovým. Kategorie legendy zahrnují i ostatní třídy land cover, jako je zástavba, vodní plochy a trvalé travní porosty. Třídy klasifikace tak odráží stav vegetace v NP Šumava k roku 2015 a jejich definice vychází z poznatků z terénního šetření i z dostupné literatury. Lesní porosty byly děleny do stěžejních kategorií: zdravý les, napadený les, mrtvý les a regenerující les. Na základě předchozích studií zabývajících se klasifikací lesních porostů byly pro klasifikaci vybrány metody Support Vector Machine, Neural Network a Objektová analýza obrazu. Tyto metody byly aplikovány na vybrané snímky WorldView-2 a Landsat 8. Důležitým krokem se stal jak výběr vhodných parametrů vstupujících do klasifikace pro algoritmy SVM a NN, tak tvorba segmentů a postup při tvoření pravidel klasifikační báze pro klasifikaci OBIA.

Výsledná celková přesnost vychází pro snímek WorldView-2 od 73 % do 86 % dle zvolené metody a nastavených parametrů. U snímku Landsat 8 již přesnost klesá na 40 % až 71 %. I přes nižší prostorové rozlišení snímku Landsat 8 se podařilo relativně úspěšně vyklasifikovat třídy napadeného a obnovujícího se lesa. Dle výstupů z klasifikací lze říci, že cíl práce rozlišit více stádií lesních porostů poškozených disturbancemi byl splněn. Rozmístění klasifikačních tříd, zejména na snímku WorldView-2, odpovídá ve velké míře podkladům z terénního výzkumu a s dosaženými výsledky by tak bylo možné dále pracovat.

Výsledky práce prokázaly, že pro klasifikaci lesních porostů narušených disturbancemi je vhodné použití testovaných klasifikátorů na datech vysokého prostorového rozlišení WorldView-2. U snímku s nižším prostorovým rozlišením, který přináší větší míru generalizace, je třeba myslet zejména na budoucí využití výsledků

a na základě toho volit metodu klasifikace. Nejlepších výsledků u obou snímků dosahovala klasifikace SVM, která je ze zvolených metod i nejlépe přenositelná na jiné datové zdroje. V tomto faktu je viděn silný potenciál při tvorbě klasifikace lesních porostů do budoucna. Vytvořené klasifikace by mohly být použitelné v mnoha oblastech vědy, zejména v lesním managementu, ochraně přírody a krajiny, ale i v hydrologii či krajinné ekologii.

POUŽITÉ ZDROJE INFORMACÍ

Literární zdroje:

- ADAMCZYK, A., OSBERGER, A. (2015): Red-edge vegetation indices for detecting and assessing disturbances in Norway spruce dominated mountain forests. *International Journal of Applied Earth Observation and Geoinformation*. 2015, č. 37, s. 90–99.
- ADDINK, E. A., DE JONG, S. M., PEBESMA, E. J. (2007): The importance of scale in object based mapping of vegetation parameters with hyperspectral imagery. *Photogrammetric Engineering & Remote Sensing*. č. 73(8), s. 905-912.
- BAATZ, M., SCHÄPE, A. (2000): Multiresolution Segmentation – an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informationsverarbeitung XII*, Karlsruhe. 2000, s.12–23.
- BLASCHKE, T., BURNETT, C., PEKKARINEN, A. (2006): Image segmentation methods for object based analysis and classification. *Remote Sensing Image Analysis: Including the Spatial Domain*, Springer-Verlag, Dordrecht, The Netherlands. 2006, s. 211-236 912.
- BRODSKÝ, L., KOLOMAZNIK, J., BARTALOŠ, T. (2009): Object-based image analysis for very high resolution land cover classification in security and emergency. *GISAT Ostrava 2010*.
- BROMOVÁ, B. P. (2012): Analýza hustoty lesních porostů s využitím texturálních příznaků snímků vysokého prostorového rozlišení a dat leteckého laserového skenování. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta.
- CAMPBELL, J. B. (2002): *Introduction to remote sensing*. New York: The Guilford Press. 2002, 625 s. ISBN 1-57230-640-8.
- CAMPBELL, J. B., WYNNE, R. H. (2011): *Introduction to remote sensing*, 5th edition, The Guildford press. 2011, ISBN 978-1-60918-176-5
- CAMPS-VALLS et al. (2004): Robust support vector method for hyperspectral data classification and knowledge discovery. *IEEE Transactions on geoscience and remote sensing*. 2004, č. 20, s. 1-13.
- CARLE, M. V.; SASSER, CH.; TWILLEY, R. (2011): *Mapping deltaic wetland vegetation at the species-level using WorldView-2 multispectral imagery*. Baton Rouge: Louisiana State University, 2011.
- COOPS, N. C., WULDER, A. WHITE (2006): Assessment of QuickBird high spatial resolution imagery to detect red attack damage due to mountain pine beetle infestation [online]. *Remote Sensing of Environment*. 2006, 33 s.

- DEERING, D. W., ROUSE, J. W. (1975): Measuring 'forage production' of grazing units from Landsat MSS data. International Symposium on Remote Sensing of Environment, 10 th, s. 1169-1178.
- DENNISON, P. E.; BRUNELLE, A. R.; CARTER, V. A. (2010): Assessing canopy mortality during a mountain pine beetle outbreak using GeoEye-1 high spatial resolution satellite data. Remote Sensing of Environment. 2010, č. 114, s. 2431-2435.
- DEROSE, R. J., LONG, J. N., RAMSEY, R. D. (2011): Combining dendrochronological data and the disturbance index to assess Engelmann spruce mortality caused by a spruce beetle outbreak in southern Utah. Remote Sensing of Environment. 2011, č. 115(9), s. 2342-2349.
- DEY, V. (2011): A supervised approach for the estimation of parameters of multiresolution segmentation and its application in building feature extraction from VHR imagery. Diploma Thesis, The University of New Brunswick, Janpur, India.
- DOBROVOLNÝ, P. (1998): Dálkový průzkum Země: digitální zpracování obrazu. 1. vyd. Brno: Masarykova univerzita, 1998. 208 s. ISBN: 80-210-1812-7.
- DORIČ, R. (2013): Možnosti objektovo orientovanej klasifikácie při monitoringu lúčnej vegetácie a manažmentových zásahov v Krkonošskom národnom parku. Diplomová práca. Univerzita Karlova v Praze, Přírodovědecká fakulta. 78 s.
- FRANKLIN, J. F. et al. (2002): Disturbances and structural development of natural forest ecosystems with silvicultural implications, using Douglas-fir forests as an example. Forest Ecology and Management. 2002, č. 155, s. 399 – 423.
- FRELICH, L. E. (2002): Forest dynamics and disturbance regimes: studies from temperate evergreen-deciduous forests. Cambridge University Press. ISBN 0 521 65082 8
- GARČÁR, M. et al. (2010): Hodnotenie stavu a rozpadu smrekových porastov v roku 2009 zo satelitných snímok . Aktuálne problémy v ochrane lesa. 2010, s. 77.
- GIDUDU, A., HULLEY, G., MARWALA, T. (2007): Classification of Images Using Support Vector Machines. Department of Electrical and Information Engineering, University of the Witwatersrand, Johannesburg. 6 s.
- Gisat (200-?): Družicová data [online]. 200-? [cit. 2016-03-22]. Dostupné z URL: <<http://www.gisat.cz/content/cz/druzicova-data>>.
- Gisat (200-?): Klasifikace [online]. 200-? [cit. 2016-03-22]. Dostupné z URL: <<http://www.gisat.cz/content/cz/dpz/zpracovani-dat/klasifikace>>.
- HAIS, M. (2009): Využití dálkového průzkumu země pro monitoring lesů na Šumavě. Životní prostředí. 2009, roč. 43, č. 4, s. 216-219.
- HÁJEK, F. (2006): Object-oriented classification of Ikonos satellite data for the identification of tree species composition. Journal of Forest Science. 2006, roč. 52, č. 4, s. 181-187.

- HÁJEK, F., SVOBODA, M. (2007): Vyhodnocení odumírání horského smrkového lesa na Trojmezí (NP Šumava) metodou automatizované klasifikace leteckých snímků. *Silva Gabreta*. 2007, roč. 13, č. 1, s. 69-81.
- HALOUNOVÁ, L. (2003): Zkušenosti s programem eCognition pro klasifikaci urbanizovaného území z leteckých černobílých snímků a snímků [online]. Fakulta stavební ČVUT Praha. 2002, [cit. 2016-03-22]. Dostupné z URL: <http://gisak.vsb.cz/gis_ostrava/GIS_Ova_2002/Sbornik/Referaty/halounova3r.htm>.
- HART, S. J., VELEN, T. T. (2015): Detection of spruce beetle-induced tree mortality using high-and medium-resolution remotely sensed imagery. *Remote Sensing of Environment*. 2015, č. 168, s. 134-145.
- HAY, G. J. et al. (2003): A comparison of three image-object methods for the multiscale analysis of landscape structure. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2003, č. 57(5-6), s. 327-345.
- HESSLEROVÁ, P., KUČERA, T. (2006): Krajina - známá neznámá. 2. Procesy v krajině. *Ochrana přírody*. 2006, č. 7, s. 195-198.
- HICKE, J. A., LOGAN, J. (2009): Mapping whitebark pine mortality caused by a mountain pine beetle outbreak with high spatial resolution satellite imagery. *International Journal of Remote Sensing*. 2009, roč. 30, č. 70, s. 4427-4441.
- HRDINA, P. (2006): Analýza sezónních změn vegetace kvantifikováním vegetačního charakteru krajiny. Ostrava: VŠB Technická univerzita Ostrava. 2006, 9 s.
- HROMÁDKOVÁ, L. (2015): Classification of meadow vegetation in the Krkonoše Mts. using aerial hyperspectral data and support vector machines classifier. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta. 137 s.
- IMMITZER, M., ATZBERGER, C. (2014): Early Detection of Bark Beetle Infestation in Norway Spruce (*Picea abies*, L.) using WorldView-2 Data. *ISPRS*. 2014, č. 5, s. 0351–0367.
- JIN, S., SADER, S. A. (2005): Comparison of time series tasseled cap wetness and the normalized difference moisture index in detecting forest disturbances. *Remote Sensing of Environment*, č. 94, s. 364-372.
- JONES H. G., VAUGHAN R. A. (2010): Remote sensing of vegetation: Principles, techniques and applications. Oxford: Oxford university press, ISBN 978-0-19-920779-4
- JOSHI, P. CH. (2011): Performance evaluation of vegetation indices using remotely sensed data. *International Journal of Geomatics and Geosciences*. 2011, roč. 2, č. 1, 10 s.
- KAVZOGLU, T., COLKESEN, L. (2009): A kernel functions analysis for support vector machines for land cover classification. *International journal of applied earth observation and geoinformation*. 2009, č. 11(5), s. 352-359.

- KE, Y., QUACKENBUSH, L. J., IM, J. (2010): Synergistic use of QuickBird multispectral imagery and LIDAR data for object-based forest species classification. *Remote Sensing of Environment*. 2010, roč. 114, s. 1141-1154.
- KOLÁŘ, J.; HALOUNOVÁ, L.; PAVELKA, K. (1997): *Dálkový průzkum Země 10*. 1. vyd. Praha: Vydavatelství ČVUT. 1997, 164 s. ISBN: 80-01-01567-X.
- KOŠULIC, M. (2009): Disturbance neboli narušení. Přírodě blízké lesnictví: alternativní internetový lesnický časopis. [online]. 2009, [cit. 2016-03-22]. Dostupné z URL: <<http://prirozealesy.cz/node/26>>.
- KULAKOWSKI, D., BEBI, P. (2004): Range of variability of unmanaged subalpine forests. *Forum für Wissen*, roč. 2004, s. 47-54.
- LANTORA, J., VAŠKOVÁ, Z. (2006): Neuronové sítě v DPZ. *Fakulta životního prostředí, Univerzita J. E. Purkyně, Ústí nad Labem*. 8 s.
- LATIFI, H. et al. (2014): Object-based extraction of bark beetle (*Ips typographus* L.) infestations using multi-date LANDSAT and SPOT satellite imagery. *Progress in Physical Geography*. 2014, 31 s.
- LIHANOVÁ, K. (2013): Hodnocení poškození lesních porostů s využitím družicových a lidarových dat. *Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta*. 79 s.
- LOBO, L. C., ERSOY, O. K., MILES, G. E. (2000): *Multispectral Imaging, Image-Processing and classification for Agriculture*. ECE Technical Reports. 2000, č. 20, 220 s.
- MATSUSHITA, B. et al. (2007): Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest. *Sensors*. 2007, č. 7(11), s. 2636-2651.
- MEDDENS, A. J. H. et al. (2013): Evaluating methods to detect bark beetle-caused tree mortality using single-date and multi-date Landsat imagery. *Remote Sensing of Environment*. 2013, č. 132, s. 49-58.
- MEDDENS, A. J. H., JEFFREY, A. H., VIERLING, L. A. (2011): Evaluating the potential of multispectral imagery to map multiple stages of tree mortality. *Remote Sensing of Environment*. 2011, č. 115, s. 1632-1642.
- MOSKAL, L. M., FRANKLIN, S. E. (2002): Multi-layer Forest Stand Discrimination with Spatial Co-occurrence Texture Analysis of High Spatial Detail Airborne Imagery. *Geocarto International*. 2002, roč. 17, č. 4, s. 55-67.
- OUBRECHTOVÁ, V. (2012): Využití Umělých Neuronových Sítí v klasifikaci Land Cover. *Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta*. 70 s.

- OZDEMIR, I. et al. (2005): Comparison of QuickBird-2 and Landsat-7 ETM+ data for mapping of vegetation cover in Fethiye-Kumluova coastal dune in the Mediterranean region of Turkey. *Fresenius Environmental Bulletin*. 2005, roč. 14, č. 9, s. 823-831.
- RICHARDSON, A. J., WIEGAND, C. L. (1977): Distinguishing vegetation from soil background information by gray mapping of Landsat MSS data. *Photogrammetric engineering and remote sensing*. 1977, č. 43(12), s. 1541.
- ROUSE, J. W. et al. (1974): Monitoring vegetation systems in the great plains with ERTS-1. *Proceedings 3rd Earth Resources Technology Satellite Symposium 1*, s. 309–317.
- SARKER, L. R., NICHOL, J. E. (2011): Improved forest biomass estimates using ALOS AVNITR-2 texture indices. *Remote Sensing of Environment*. 2011, roč. 115, s. 968-977.
- SOLBERG, S. et al. (2007): Testing remote sensing techniques for monitoring large scale insect defoliation. *Norwegian forest and landscape institute, Norway*. 5s.
- ŠÍMA, J., NERUDA, R. (1996): *Teoretické otázky neuronových sítí*. 1. vyd., MATFYZPRESS, Praha, 1996. 390 s. ISBN 80-85863-18-9.
- TOMPPO, E. et al. (2008): Combining national forest inventory field plots and remote sensing data for forest databases. *Remote Sensing of Environment*. 1995, roč. 112, s. 1982-1999.
- Trimble (2012): *eCognition User Guide*.
- VAPNIK, V. (1995): *The Nature of Statistical Learning Theory*. Springer Verlag, New York, 1995.
- VERAVERBEKE, S. et al. (2012): Assessing post-fire vegetation recovery using red – near infrared vegetation indices: Accounting for background and vegetation variability. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2012, č. 68, s. 28-39.
- WANG, W. (2009): *Satellite Remote Sensing of forest disturbances caused by Hurricanes and Wildland fires*. PhD Thesis. George Mason University. 2009, 151 s.
- WERMELINGER, B. (2004): Ecology and management of the spruce bark beetle *Ips typographus* - a review of recent research. *Forest Ecology and Management*. 2004, č. 202, s. 67-82.
- WHITE, J. C. et al. (2005): Detection of red attack stage mountain pine beetle infestation with high spatial resolution satellite imagery. *Remote Sensing of Environment*. 2005, č. 96, s. 340-351.
- WOLTER, H. H. et al. (1995): Density dependent hadron field theory. *Physical Review C*, č. 52(6), s. 3043.
- WULDER, M. A. et al. (2006): Surveying mountain pine beetle damage of forests: A review of remote sensing opportunities. *Forest Ecology and Management*. 2006, č. 221, s. 27-41.

- ZEMEK, F. et al. (2003): Semi-natural Forested Landscape under a Bark Beetle Outbreak: A case study of the Bohemian Forest (Czech Republic). *Landscape Research*. 2003, č. 28(3), s. 279-292.
- ZEMEK, F., HEŘMAN, M., KLOUDA, Z. (1999): Bark beetle calamity assessment from remotely sensed data. *Silva Gabreta*. 1999, č. 3, s. 161-172.
- ZHANG, Y. et al. (2010): Development of a supervised software tool for automated determination of optimal segmentation parameters for eCognition. *Proceedings of ISPRS TC VII Symposium- 100 Years ISPRS, 5-7 July, Vienna, Austria*, s. 690-696.
- ZHU, G., BLUMBERG, D. G. (2002): Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel. *Remote sensing of Environment*. 2002, č. 80(2), s. 233-240.

Webové zdroje:

ArcČR 500 digitální geografická databáze Arcdata Praha, s. r. o.

URL 1: <http://www.netcam.cz/encyklopedie-ip-zabezpeceni/img/svetelne-spektrum.jpg>

URL 2: <http://www.eumetrain.org/data/3/36/flash/31.jpg>

URL 3: <https://www.e-education.psu.edu/natureofgeoinfo/sites/>

URL 4: <http://opticalengineering.spiedigitallibrary.org/data/Journals/>

URL 5: <http://portal.matematickabiologie.cz/res/image/Umela%20inteligence/>

URL 6: <https://earth.esa.int/documents/10174/2363867/WorldView-2-bands/>

URL 7: <https://mapy.cz/>

SEZNAM PŘÍLOH

- Příloha 1: Mapa zájmového území - snímek WorldView-2
- Příloha 2: Přehled trénovacích a kontrolních bodů na snímku WorldView-2
- Příloha 3: Klasifikační báze OBIA pro snímek WorldView-2
- Příloha 4: Klasifikační báze OBIA pro snímek Landsat 8
- Příloha 5: Chybová matice klasifikace SVM – Kombinace 5
- Příloha 6: Chybová matice klasifikace NN – Kombinace 3
- Příloha 7: Chybová matice klasifikace OBIA
- Příloha 8: Výsledek klasifikace SVM družicového snímku WorldView-2
- Příloha 9: Výsledek klasifikace NN družicového snímku WorldView-2
- Příloha 10: Výsledek klasifikace OBIA družicového snímku WorldView-2
- Příloha 11: Výsledek klasifikace SVM družicového snímku Landsat 8
- Příloha 12: Výsledek klasifikace NN družicového snímku Landsat 8
- Příloha 13: Výsledek klasifikace OBIA družicového snímku Landsat 8
- Příloha 14: CD s elektronickou verzí diplomové práce