

Možnosti objektově-orientované klasifikace pro určování vybraných biotopů nad horní hranicí lesa v Krkonošském národním parku

Lucie JAKEŠOVÁ¹, Lucie ČERVENÁ¹, Lucie KUPKOVÁ¹,
Renáta SUCHÁ¹, Martina ANDRŠTOVÁ¹

*Univerzita Karlova v Praze, Přírodovědecká fakulta, Katedra aplikované geoinformatiky
a kartografie, Praha, Česká republika;*

*jakesova-lucie@seznam.cz, lucie.cervena@natur.cuni.cz, lucie.kupkova@gmail.com,
renata.sucha@natur.cuni.cz, martina.andrstova@natur.cuni.cz*

Abstrakt.

Projekt je zaměřen na klasifikaci vegetace nad horní hranicí lesa v Krkonošském národním parku (KRNAP) s využitím dat a metod dálkového průzkumu Země. Cílem je zhodnotit vypovídací schopnost různých typů multispektrálních a hyperspektrálních dat (ortofota, WorldView-2, APEX a AISA Dual) a využitelnost různých metod klasifikace. Prezentovaná část projektu je zaměřena na objektově-orientovanou klasifikaci vegetace nad horní hranicí lesa s využitím ortofota s blízkým infračerveným pásmem a prostorovým rozlišením 12,5 cm. Snímky byly pořízeny v červnu roku 2012. Legenda vegetace byla vytvořena ve spolupráci s botanikem z KRNAP a obsahuje devět kategorií, některých dále dělených i do několika podkategorií. Byly vyzkoušeny a porovnány dva přístupy objektově orientované klasifikace dostupné v softwaru ENVI 5.1 – Example-based a Rule-based. Jako lepší přístup pro danou problematiku se jeví Example-based. Nejlepší výsledek klasifikace dosáhl celkové přesnosti 75,97 % pro 14 tříd. Poděkování: GAUK č. 938214.

Klíčová slova: objektová klasifikace, KRNAP, vegetace nad horní hranicí lesa, optický letecký skener.

1. Úvod

Vegetace nad horní hranicí lesa (nad 1 300 m n. m.) je jedinečný ekosystém, který se vyznačuje mozaikou podhorských luk. Mezi jedny z nejrozšířenějších typů vegetace patří klečové porosty a smilkové trávníky. Dominujícími druhy jsou borovice horská (kleč, kosodřevina), která je původní krkonošskou dřevinou, a smilka tuhá. Smilkové louky, obrazně nazývány jako „hercynská poušť“, jsou převážně přirozeného původu, ale místy druhotně pokrývají plochy po vysekané nebo vypálené kleči. Dalším velmi významným typem jsou subalpínská rašeliniště, skály a v nejvyšších polohách krkonošské tundry nalezneme mnoho druhů lišejníků. Některé druhy rostlin jsou endemické. Na relativně malé ploše 47 km², což je pouze 7,4 % z celkové rozlohy Krkonoš (32 km² na české a 15 km² na polské straně hor), zde dochází k prolínání severské a alpské tundry (Soukupová et al., 1995).

Dálkový průzkum Země je často využíván pro klasifikace rozlehlejších či méně dostupných území. Objektovou klasifikaci pro účely rozlišení vegetace použil např. Laliberte et al. (2007). Co se týče klasifikací vegetace nad horní hranicí lesa, zabýval se jí např. Král (2009), který použil ortofota o prostorovém rozlišení 0,9 m a metodu klasifikace maximum likelihood v Jeseníkách. Zaga-jewski et al. (2005) klasifikoval horskou vegetaci subalpínského, alpínského a subniválního pásma ve východní části Tatranského národního parku v Polsku pomocí hyperspektrálních dat a metod

maximum likelihood a neuronových sítí. V oblasti Krkonoš pracovala již Müllerová (2005), které se na základě multispektrálních leteckých dat a metody řízené i neřízené klasifikace podařilo oddělit sedm resp. šest tříd.

Hlavním cílem této práce bylo zhodnotit využitelnost objektové klasifikace ortofot s infračerveným pásmem při klasifikaci vegetace nad horní hranicí lesa. Dále také porovnat dva přístupy objektové klasifikace v softwaru ENVI 5.1 – Example-based (s využitím algoritmu Support vector machine) a Rule-based.

2. Metody

2.1. Legenda vegetace nad horní hranicí lesa

Klíčovou částí práce je definice legendy, která byla vytvořena ve spolupráci s botanikem Krkonošského národního parku RNDr. Stanislavem Březinou, Ph.D. Celkem obsahuje 9 kategorií, přičemž některé z nich jsou děleny i dále do podkategorií. Třídy jsou následující:

1. Kosodřevina
2. Mokřad
 - 2a. Rašeliniště
 - 2b. Mokřad – ostatní
3. Vodní plochy
4. Alpínská vřesoviště
5. Subalpínská brusnicová vegetace
6. Alpínské trávníky zapojené
 - 6a. Smilka
 - 6b. Metlička
 - 6c. Druhově bohaté porosty s velkým zastoupením dvouděložných
7. Subalpínské vysokostébelné trávníky
 - 7a. Třtina
 - 7b. Bezkolenec
 - 7c. Metlice
8. Subalpínské vysokobylinné trávníky
9. Smrk

Pro lepší představu o jednotlivých třídách jsou v obrázku 1 vloženy typičtí zástupci jednotlivých kategorií.



3. Vodní plochy	4. Alpínská vřesoviště	5. Subalpínská brusnicová vegetace
		
6a. Smilka	6b. Metlička	6c. Druhově bohaté porosty s velkým zastoupením dvouděložných
		
7a. Třtina	7b. Bezkoleneček	7c. Metlice
		
8. Subalpínské vysokobylinné trávníky	9. Smrk	
		

Obr. 1: Fotografie jednotlivých kategorií legendy (zdroj: archiv autorů)

2.2. Data

Využity byly tři hlavní datové zdroje: ortofota obsahující infračervené pásmo, digitální model terénu (DEM) s digitálním modelem povrchu (DSM) a GPS data získaná v terénu.

Ortofota byla pořízena 18. června 2012. Data se skládají ze dvou sad ortofot po třech pásmech. Jedna sada obsahuje pásma viditelného spektra (červené, zelené a modré) a druhá blízké infračervené, červené a zelené pásmo. Prostorové rozlišení dat je 12,5 cm a radiometrické rozlišení je 8-bit. Předzpracování dat provedla společnost Geodis Brno.

Digitální modely terénu a povrchu vznikly zpracováním laserových dat pořízených na území KRNAP spolu s ortofoty v roce 2012. Jejich prostorové rozlišení je 1 m. Modely byly využity ke zjištění výšky vegetačního pokryvu (odečtením DEM a DSM) a získaná výška vegetace byla následně použita při klasifikaci smrku a kosodřeviny.

V terénu bylo nasbíráno 59 polygonů odpovídajících jednotlivým kategoriím legendy. Sběr dat proběhl v období 23. – 25. června 2014 za účasti botanika Krkonošského národního parku RNDr. Stanislava Březiny, Ph.D. a botanika Mgr. Jana Šturmy.

Polygony byly nasbírány pomocí přístroje GPS Trimble Geoexplorer 3000 Geo XT a následně botanikem zařazeny do jednotlivých kategorií legendy. V softwaru ArcGIS 10.2 byly polygony upraveny, aby neobsahovaly stíny od stromů či staveb příp. jiné nepřesnosti. Na základě ortofot byly také dodatečně vytvořeny polygony kategorií kosodřevina, smrk a vodní plochy. Poté byly všechny polygony rozděleny na trénovací a validační tak, aby validačních bylo přibližně dvakrát více než trénovacích.

2.3. Metodika zpracování dat

2.3.1. Segmentace

Prvním krokem jakékoli objektové klasifikace je segmentace. V nabídce ENVI jsou pouze dva segmentační algoritmy – Edge a Intensity. V této práci byl vybrán algoritmus Edge, který rozděluje snímek na základě Sobelovy metody detekce hran. Poté se nastavuje Scale Level, který nabývá hodnot 0-100. Čím vyšší je hodnota, tím více jsou identifikovány pouze objekty s výraznějšími hranami (např. střechy, silnice apod.) – tj. větší objekty. Pro spojení malých segmentů do větších je zde parametr Merge (Exelis VIS, 2014b).

Nevýhodou procesů segmentace v ENVI je, že segmentace musí proběhnout vždy při každém spuštění, čili nelze použít jednou "rozsegmentovaný" snímek do dalších klasifikací.

2.3.2. Maska vegetace

Jelikož zájmové území obsahuje i jiné prvky krajinného pokryvu než vegetaci (cesty, střechy, atd.) a zároveň se ve snímku nacházejí nežádoucí stíny (od stromů, budov apod.), bylo potřeba vytvořit masku, pod kterou se bude klasifikovat vegetace tundry. Na základě vizuální interpretace byly stanoveny 3 klasifikační kategorie: střechy a holá půda (kamenná moře, cesty, atd.), stíny, vodní plochy (kategorie legendy číslo 3). Samotná maska byla vytvořena pomocí objektové klasifikace v softwaru ENVI 5.1 na základě pravidel (přístup Rule-based) v tabulce 1.

Tab. 1: Použitá pravidla a atributy masky vegetace nad horní hranicí lesa

Kategorie	Atributy	Pravidla
střechy a holá půda	Spectral Mean	$G/NIR > 1,28$
stíny	Spectral Mean	$NIR < 62$
(3) vodní plochy	Spectral Mean	$NDVI < 85$
	Spectral Mean	$G/NIR > 1,7$

Pozn. mezi atributy kategorie 3 platí logika "a zároveň"

2.3.3. Objektová klasifikace Example-based

Klasifikaci Example-based jsou jednotlivé segmenty zařazovány do předem stanovených kategorií pomocí trénovacích ploch (segmentů), vybraných atributů a klasifikačního algoritmu.

Pro segmentaci byly zvoleny následující parametry: Scale Level 25, Merge Level 90. Texture Kernel Size pro výpočet texturních parametrů byla 5×5 pixelů. Dále byly vybrány následující spektrální a texturní atributy, na základě kterých byl snímek klasifikován – Spectral Mean, Spectral Max, Spectral Min, Spectral STD, Texture Mean a Texture Variance. Jednotlivé atributy byly vypočítány pro všechna čtyři spektrální pásma a pro Normalizovaný diferenční vegetační index (NDVI).

2.3.4. Objektová klasifikace Rule-based

Každá třída, do které jsou jednotlivé segmenty zařazovány, obsahuje jedno nebo více klasifikačních pravidel a atributů vytvořených uživatelem.

Klasifikace proběhla ve dvou krocích. Nejprve byly klasifikovány na základě ortofot s pomocí digitálního modelu terénu a digitálního modelu povrchu kategorie (1) kosodřevina a (9) smrk a pod touto maskou všechny ostatní.

Pro segmentaci klasifikace kategorií 1 a 9 byly zvoleny tyto parametry: Scale Level 50 a Merge Level 80. Pro klasifikaci zbylých kategorií byly parametry stejné jako v předchozím případě. Použitá pravidla jsou v tabulce 2 a 3.

Tab. 2: Použitá pravidla a atributy pro Rule-based klasifikaci kategorií 1 a 9

Kategorie	Atributy	Pravidla
1	Spectral Mean	$0,15 < \text{rozdíl DEM a DSM} < 0,5$
	Spectral Mean	$\text{NDVI} < 230$
9	Spectral Mean	$\text{DM} > 0,43$

Pozn. mezi atributy kategorie 1 platí logika "a zároveň"

Tab. 3: Použitá pravidla a atributy zbylých kategorií legendy

Kategorie	Atributy	Pravidla
4	Texture Mean	$185 < \text{NDVI} < 220$
5	Spectral Mean	$190 < \text{NDVI} < 255$
6a	Spectral Mean	$335 < \text{GRDI} < 413$
	Texture Mean	$\text{NDVI} > 282$
7b	Spectral Mean	$\text{GRDI} > 413$
2a, 2b, 6b, 6c, 7a, 7c, 8	Spectral Mean	$1,12 < \text{SR} < 1,8$
	Spectral Mean	$220 < \text{GRDI} < 335$

Pozn. mezi atributy kategorie 6a a spojené kategorie platí logika "a zároveň"

3. Výsledky

Hodnocení přesnosti klasifikací vegetace nad horní hranicí lesa v modelovém území KRNAP bylo provedeno pomocí chybových matic počítaných na základě validačních dat z terénu. Klasifikace Example-based (tabulka 4) dosáhla celkové přesnosti 75,97 % s kappa koeficientem 0,73. Rule-based klasifikace dosáhla téměř stejné celkové přesnosti (75,45 %), ale nepodařilo se touto metodou od sebe oddělit všechny kategorie legendy. Kappa koeficient byl v tomto případě nižší – 0,68.

Mezi jednotlivými kategoriemi vegetace dosáhla nejlepších výsledků v obou klasifikacích kategorie (1) kosodřevina, která je velmi dobře rozeznatelná i při vizuální interpretaci snímku. V klasifikaci Example-based byla její zpracovatelská přesnost 99,5 % a uživatelská 99,57 %. V klasifikaci Rule-based byla zpracovatelská a uživatelská přesnost třídy (1) kosodřevina o něco nižší, ale stále velmi vysoká (97,61 % a 93,51 %).

U kategorie (9) smrk dosáhla lepších výsledků klasifikace Rule-based, ve které byly pro stanovení pravidel použity rozdíly modelů DEM a DSM. Zpracovatelská přesnost byla v tomto případě 84,42 % a uživatelská 75,62 %. Použití kombinace multispektrálního snímku s DEM a DSM se ukázala jako vhodná metoda pro klasifikaci stromů.

Po zkušenostech z terénního průzkumu se předpokládalo, že nejvíce se mezi sebou budou zaměňovat podkategorie z kategorie (7) subalpínské vysokostébelné trávníky. Především pak kategorie (7a) třtina a (7b) bezkolenec, které jsou si v terénu velice podobné, nakonec tomu tak však nebylo. Z kategorií travin dosáhl nejlepších výsledků právě bezkolenec, který se jako jediný podařil oddělit i v klasifikaci Rule-based. Zpracovatelská a uživatelská přesnost Example-based klasifikace byla 89,06 % a 58,15 % a klasifikace Rule-based 68,41 % a 60,82 %.

Největší rozdíly v uživatelské a zpracovatelské přesnosti byly v kategoriích (6b) metlička a (7c) metlice. Na základě poměru správně zařazených pixelů a celkových pixelů v kategorii byla přesnost klasifikace metličky velmi vysoká – 90,96 %, na druhou stranu byly do této kategorie zařazeny s více než tisíci pixely kategorie 2a (rašeliniště), 5 (subalpínská brusnicová vegetace), 6c (druhově bohaté porosty s velkým zastoupením dvouděložných), 7a (třtina) a 7c (metlice) a uživatelská přesnost tak byla pouhých 40,37 %. Je tedy zřejmé, že kategorie metličky byla trénovacími plochami definována velmi široce a bude potřeba znovu zkontrolovat jednotlivé lokality.


U kategorie 7c (metlice) se více než polovina validačních pixelů zařadila do kategorie 8 (subalpínské vysokobylinné trávníky) a zpracovatelská přesnost tak byla pouhých 32 %. Uživatelská přesnost naopak dosáhla hodnoty 77,29 %.

Na obrázku 2 a 3 jsou zobrazeny výsledky obou klasifikací.


Tab. 4: Přesnosti a kappa koeficient klasifikace Example-based (vlevo) a Rule-based (vpravo)

Kategorie	Zpracovatelská přesnost [%]	Uživatelská přesnost [%]
1 kosodřevina	99,50	99,57
2a rašeliniště	72,43	88,97
2b ostatní mokřad	56,94	71,11
4 alpínská vřesoviště	69,17	95,89
5 brusnicová vegetace	84,10	90,03
6a smilka	66,49	61,19
6b metlička	90,96	40,37
6c druhově bohaté porosty	56,35	70,19
7a třtina	40,98	41,57
7b bezkolenec	89,06	58,15
7c metlice	32,00	77,29
8 vysokobylinné trávníky	70,74	50,49
9 smrk	62,79	87,75
Celková přesnost [%]		75,97%
Celkový kappa koeficient		0,73

Kategorie	Zpracovatelská přesnost [%]	Uživatelská přesnost [%]
1	97,61	93,51
4	59,26	72,03
5	64,36	55,92
6a	62,51	62,11
7b	68,41	60,82
9	84,42	75,62
2a, 2b, 6b, 6c, 7a, 7c, 8	73,01	78,36
Celková přesnost [%]		75,45
Celkový kappa koeficient		0,68



Obr. 2: Výsledek objektové klasifikace pomocí přístupu Example-based



Obr. 3: Výsledek objektové klasifikace pomocí přístupu Rule-based

4. Závěr

Krkonošská tundra je velice heterogenní a druhově velmi bohatá. Především u jednotlivých druhů trav dochází k jejich prolínání a neexistují mezi nimi jasné hranice. Proto je těžké jednotlivé druhy rozlišit a klasifikovat.

Cílem práce bylo zhodnotit možnosti využití objektově-orientované klasifikace v kombinaci s ortofoty s vysokým prostorovým rozlišením při klasifikaci krkonošské tundry v modelovém území Krkonošského národního parku. Objektová klasifikace byla provedena v softwaru ENVI 5.1, který nabízí dva přístupy klasifikace – Example-based a Rule-based. Na základě celkové přesnosti klasifikace dopadly oba přístupy téměř stejně (cca 75 %), avšak klasifikací Example-based s využitím algoritmu SVM se podařilo klasifikovat všechny kategorie stanovené legendy a ve většině případů také s uspokojivými výsledky. Nejlepších výsledků dosáhly kategorie (1) kosodřevina (99,5 % a 99,57 %), (2a) rašeliniště (72,43 % a 88,97 %) a (5) subalpínská brusnicová vegetace (84,1 % a 90,03 %), naopak nejhorších výsledků dosáhly kategorie (7a) třtina (40,98 % a 41,57 %), (7c) metlice (32 % a 77,29 %) a také (6b) metlička (90,96 % a 40,37 %). Přístup klasifikace Rule-based se ukázal jako velmi vhodný při použití kombinace multispektrálního snímku a rastru, který obsahuje výšku vegetace, pro přesnější klasifikaci kategorie smrk.

V porovnání s předchozí prací Müllerové (2005) v Krkonoších byla celková přesnost klasifikací sice o něco nižší, ale na druhou stranu se podařilo od sebe oddělit dvojnásobný počet kategorií, především pomocí algoritmu SVM v klasifikaci *Example-based*. Kategorie kosodřevina a rašeliniště dosáhly v této práci dokonce lepší zpracovatelské a uživatelské přesnosti. V kategorii kosodřevina to bylo 99,5 % a 99,57 % oproti 88,4 % a 86,6 %. V kategorii rašeliniště 72,43 % a 88,97 % oproti 69,7 % a 62,2 %.

Poděkování

Poděkování patří Grantové agentuře Univerzity Karlovy v Praze: GAUK č. 938214. Díky také patří Stanislavu Březinovi a Janu Šturmovi za výpomoc s botanickým průzkumem a vytvořením legendy.

Reference

- EXELIS VIS (2014b): *Extract Features (Using ENVI)* [online]. [cit. 2014-08-03]. Dostupné z: <http://www.exelisvis.fr/docs/ExtractFeatures.html>.
- KRÁL, K. (2009): Classification of Current Vegetation Cover and Alpine Treeline Ecotone in the Praděd Reserve (Czech Republic), Using Remote Sensing. *Mountain Research and Development*, 29, č. 2, s. 177–183.
- LALIBERTE, A. S. et al. (2007): An object-based image analysis approach for determining fractional cover of senescent and green vegetation with digital plot photography. *Journal of Arid Environments*, 69, č. 1, s. 1–14.
- MÜLLEROVÁ, J. (2005): Use of digital aerial photography for sub-alpine vegetation mapping: A case study from the Krkonoše Mts., Czech Republic. *Plant Ecology*, 175, č. 2, s. 259–272.
- SOUKUPOVÁ, L. et al. (1995): Arctic-alpine tundra in the Krkonoše, the Sudetes. *Opera corcontica*, 32, s. 5–88.
- ZAGAJEWSKI, B. et al. (2005): Mapping high mountain vegetation using hyperspectral data. *EARSeL eProceedings*, 4, č. 1, s. 70–78.