

Univerzita Karlova
Přírodovědecká fakulta

Studijní program: Geografie
Studijní obor: Geografie a kartografie



Petra Pajmová

Analýza vývoje vegetace krkonošské tundry s využitím časové řady ortofot

**Analysis of tundra vegetation development using a time series of ortoimages in
the Krkonoše Mountains**

Bakalářská práce

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

Praha, 2022

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

Fakulta: Přírodovědecká
Školní rok: 2021/2022

Zadání bakalářské práce

pro Petru Pajmovou
obor Geografie a kartografie

Název tématu

Analýza vývoje vegetace krkonošské tundry s využitím časové řady ortofot

Zásady pro vypracování

Bakalářská práce se bude zabývat analýzou vývoje vegetace krkonošské tundry s využitím časové řady ortofot z roku 2004 a 2020, případně z dalších let. Cílem práce bude testovat různé metody klasifikace (pixelové, objektová) a zjistit, s jakou přesností je možné klasifikovat z ortofot vegetaci sledovaného území v úrovni společenstev/druhů (především travních druhů bezkolence modrého, metlice trsnaté, smilky tuhé a třtiny chloupkaté, u nichž se ve sledovaném období předpokládají změny v rozšíření). Pro trénování a validaci budou využita data nasbíraná v terénu botaniky (prostorově lokalizované polygony výskytu jednotlivých společenstev/druhů). Protože jsou k dispozici trénovací a validační data z roku 2020, ale nejsou dostupná tato data pro rok 2004, budou testovány také metody neřízené klasifikace a srovnány s výsledky klasifikací řízených. Výstupem práce budou vegetační mapy, případně změnové mapy, pokud bude potvrzeno, že z uvedených dat lze spolehlivě určit změny vegetace.

Rozsah grafických prací: cca 10 stran

Rozsah původní zprávy: cca 50 stran

Seznam odborné literatury:

KUPKOVÁ, L.; ČERVENÁ, L.; SUCHÁ, R.; JAKEŠOVÁ, L.; ZAGAJEWSKI, B.; BŘEZINA, S.; ALBRECHTOVÁ, J. (2017): Classification of Tundra Vegetation in the Krkonoše Mts. National Park Using APEX, AISA Dual and Sentinel-2A Data. *European Journal of Remote Sensing*, 50, 1, 29-46.

KUPKOVÁ, L., ČERVENÁ, L., POTŮČKOVÁ M., LYSÁK, J., ŠAŠKOVÁ, M., ŠROLLERŮ, A., KLINEROVÁ, T., BOBEK, P., MÜLLEROVÁ, J. (2022): Annual Report 2021, Vegetation of the tundra in the Krkonoše Mts. – past, present and future.

MARCINKOWSKA-OCHTYRA, A., ZAGAJEWSKI, B., RACZKO, E., OCHTYRA, A., JAROCINSKA, A. (2018): Classification of High-Mountain Vegetation Communities within a Diverse Giant Mountains Ecosystem Using Airborne APEX Hyperspectral Imagery. *Remote Sensing*, 10, 4, 570.

POTŮČKOVÁ, M., KUPKOVÁ, L., ČERVENÁ, L., LYSÁK, J., KRAUSE, D., HRÁZSKÝ, Z., BŘEZINA, S., MÜLLEROVÁ, J. (2021): Towards resolving conservation issues through historical aerial imagery: vegetation cover changes in the Central European tundra. *Biodiversity and Conservation* 30, 3.

Vedoucí bakalářské práce: doc. RNDr. Lucie Kupková, Ph.D.

Konzultant bakalářské práce: ×

Datum zadání bakalářské práce: 12. 11. 2022

Termín odevzdání bakalářské práce: červenec 2022

Platnost tohoto zadání je po dobu jednoho akademického roku.

.....
Vedoucí bakalářské práce

.....
Vedoucí katedry

V Praze dne:

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracovala samostatně a s použitím uvedené literatury a pramenů.

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 Praze dne 28.7.2022

.....

Petra Pajmová

Poděkování

Ráda bych tímto poděkovala všem, kteří mi poskytli cenné rady a byli mi oporou po celou dobu studia. Zejména pak vedoucí mé bakalářské práce doc. RNDr. Lucii Kupkové, Ph.D. za velkou dávku trpělivosti, věnovaný čas a především užitečné rady, které mi dopomohly k úspěšnému dokončení této práce. Dále BÚ AV ČR za pořízení botanických dat pro trénování a validaci klasifikací.

Analýza vývoje vegetace krkonošské tundry s využitím časové řady ortofot

Abstrakt

Cílem této studie je analyzovat změny vegetace arкто-alpínské tundry v Krkonoších s využitím archivních a současných leteckých snímků s červeným, zeleným a modrým pásmem a prostorovým rozlišením 0,5 m. Byly zkoumány tři malé zájmové plochy (cca 100 × 100 m) s rozdílnými typy vegetace a dále širší území východní tundry. Pro získání co nejlepších výsledků klasifikace bylo testováno několik klasifikačních metod (klasifikace Maximum likelihood, Random forest a objektově orientovaná klasifikace). Pro podrobnější analýzu vývoje travních druhů byla pro oblast Bílé louky použita neřízená klasifikace a rozšířená časová řada ortofot (5 časových horizontů). Klasifikace byly provedeny v softwaru ENVI 5.5 a R 4.2.1. Nejvyšší celková přesnost klasifikací ortofota z roku 2020 byla ve všech studovaných oblastech přes 70 %, v některých případech přes 80 %. S výjimkou Luční hory (58 %), byly pro rok 2004 nejlepší celkové přesnosti vyšší než 65 %. Po porovnání výsledků klasifikací mezi lety 2004 a 2020 se ukázal možný trend vývoje, ale z důvodu malé přesnosti klasifikací dat z roku 2004 ho nelze spolehlivě doložit.

Klíčová slova: klasifikace, ortofoto, vegetace, tundra, dálkový průzkum Země, Krkonošský národní park

Analysis of tundra vegetation development using a time series of orthoimages in the Krkonoše Mountains

Abstract

The aim of this study is to analyse changes in arctic-alpine tundra vegetation in the Krkonoše Mountains using archival and current aerial imagery with red, green and blue bands and spatial resolution of 0.5 m. Three small areas of interest (cca 100 × 100 m) with different types of vegetation and a one larger area of the eastern tundra were studied. Several classification methods (Maximum likelihood classification, Random forest and object-based classification) were tested to obtain the best classification results. For more detailed analysis of grass species development, unsupervised classification and extended time series (5 orthoimages) were used for the area of Bílá louka. Classification were executed in softwares ENVI 5.5 and R 4.2.1. The highest overall accuracy of the 2020

image classifications were over 70% in all study areas, in some cases over 80%. With the exception of the Luční hora area (58%), the best overall accuracies for 2004 image were above 65%. After comparing classification results between years 2004 and 2020, a possible development trend was revealed. But due to low accuracy of the 2004 data classifications, this cannot be reliably demonstrated.

Key words: classification, orthoimages, vegetation, tundra, Remote sensing, The Krkonoše Mountains

Obsah

1. Úvod a cíle práce	12
2. Literární rešerše a úvod do problematiky	14
2.1. Dálkový průzkum Země	14
2.2. Klasifikace obrazu	15
2.3. Metody klasifikace.....	17
2.3.1. Klasifikátor maximální pravděpodobnosti.....	17
2.3.2. Klasifikátor Random forest.....	17
2.3.3. Objektově orientovaná klasifikace.....	18
2.4. Klasifikace vegetace nad horní hranicí lesa.....	18
2.5. Klasifikace v krkonošské tundře.....	20
3. Zájmové území	23
3.1. Definice tundry	23
3.2. Krkonošská arкто–alpínská tundra	24
3.3. Hodnocené třídy vegetačního pokryvu	27
3.4. Klimatické podmínky ve sledovaných letech	34
4. Data a metodika	37
4.1. Vstupní data	37
4.2. Terénní data	37
4.3. Klasifikační legenda	38
4.4. Klasifikace	41
4.5. Hodnocení přesnosti klasifikací.....	41
5. Výsledky	42
5.1. Hodnocení přesnosti klasifikací.....	42
5.1.1. Bílá louka	43
5.1.2. Luční hora	47

5.1.3. Úpské rašeliniště	49
5.1.4. Širší území tundry	51
5.2. Analýza vývoje vegetace	54
5.2.1. Řízené klasifikace	54
5.2.2. Neřízené klasifikace pro Bílou louku	55
6. Diskuze	57
7. Závěr	64
8. Zdroje.....	67

Seznam obrázků, tabulek a grafů

Obrázky

Obrázek 1: Proces sběru dat v DPZ	15
Obrázek 2: Vztah sledovaného objektu a prostorového rozlišení	16
Obrázek 3: Rozšíření biomu tundra na Zemi	24
Obrázek 4: Mapa vymezení zájmových území	26
Obrázek 5: Borovice kleč (<i>Pinus mugo</i>)	27
Obrázek 6: Smilka tuhá (<i>Nardus stricta</i>)	28
Obrázek 7: Metlice trsnatá (<i>Deschampsia cespitosa</i>)	29
Obrázek 8: Třtina chloupkatá (<i>Calamagrostis villosa</i>)	29
Obrázek 9: Bezkoleneček modrý (<i>Molinia caerulea</i>)	30
Obrázek 10: Subalpínská brusnicová vegetace se zastoupením brusnice borůvky (<i>Vaccinium myrtillus</i>)	31
Obrázek 11: Alpínská vřesoviště s největším zastoupením vřesu obecného (<i>Calluna vulgaris</i>)	31
Obrázek 12: Mokřady a rašeliniště	32
Obrázek 13: Vyfoukávavý alpínský trávník se zastoupením metličky křivolaké (<i>Avenella flexuosa</i>)	33
Obrázek 14: Smrk ztepilý (<i>Picea abies</i>)	33
Obrázek 15: Kamenná moře	34
Obrázek 16: Bílá louka – porovnání klasifikací OBIA a RF pro rok 2004 a 2020	44
Obrázek 17: Bílá louka – porovnání neřízené klasifikace ISODATA s řízenou klasifikací MLC pro rok 2004 a 2020	46
Obrázek 19: Luční hora – porovnání klasifikací MLC a RF pro rok 2004 a 2020	48
Obrázek 20: Úpské rašeliniště – porovnání klasifikací OBIA a RF pro rok 2004 a 2020	50
Obrázek 21: Širší území tundry – porovnání klasifikací OBIA a RF pro rok 2004 a 2020	53

Tabulky

Tabulka 1: Použitá klasifikační legenda (klasifikované kategorie) a dílčí druhy/povrchy zahrnuté do jednotlivých tříd	39
Tabulka 2: Legenda a vstupní trénovací a validační data jednotlivých tříd pro Bílou louku	39
Tabulka 3: Legenda a vstupní trénovací a validační data jednotlivých tříd pro Luční horu	40
Tabulka 4: Legenda a vstupní trénovací a validační data jednotlivých tříd pro Úpské rašeliniště	40
Tabulka 5: Legenda a vstupní trénovací a validační data jednotlivých tříd pro širší území tundry	41
Tabulka 6: Bílá louka – celkové přesnosti klasifikací	44
Tabulka 7: Bílá louka – zpracovatelská a uživatelská přesnost jednotlivých tříd při klasifikaci OBIA a RF pro roky 2004 a 2020	44
Tabulka 8: Porovnání rozloh sledovaných tříd při klasifikaci ISODATA a MLC pro roky 2004 a 2020	47
Tabulka 9: Luční hora – celkové přesnosti klasifikací	48
Tabulka 10: Úpské rašeliniště – celkové přesnosti klasifikací	50
Tabulka 11: Širší území tundry – celkové přesnosti klasifikací	52
Tabulka 12: Bílá louka – změna rozlohy vybraných vegetačních druhů při použití různých klasifikačních metod mezi lety 2004 a 2020	54
Tabulka 13: Úpské rašeliniště – změna rozlohy vybraných vegetačních druhů při použití různých klasifikačních metod mezi lety 2004 a 2020	55

<i>Tabulka 14: Luční hora – změna rozlohy vybraných vegetačních druhů při použití různých klasifikačních metod mezi lety 2004 a 2020.....</i>	<i>55</i>
<i>Tabulka 15: Širší území tundry – změna rozlohy vybraných vegetačních druhů při použití různých klasifikačních metod mezi lety 2004 a 2020.....</i>	<i>55</i>
<i>Tabulka 16: Porovnání celkových přesností této práce se studií Kupková a kol. (2022).....</i>	<i>59</i>
<i>Tabulka 17: Bílá louka – porovnání zpracovatelských a uživatelských přesností této práce se studií Kupková a kol. (2022).....</i>	<i>60</i>
<i>Tabulka 18: Úpské rašeliniště – porovnání zpracovatelských a uživatelských přesností této práce se studií Kupková a kol. (2022).....</i>	<i>61</i>
<i>Tabulka 19: Luční hora – porovnání zpracovatelských a uživatelských přesností této práce se studií Kupková a kol. (2022).....</i>	<i>61</i>

Grafy

<i>Graf 1: Průměrná měsíční teplota vzduchu naměřená na stanici Labská bouda v letech 2004 a 2020.....</i>	<i>35</i>
<i>Graf 2: Průměrný měsíční úhrn srážek naměřený na stanici Labská bouda v letech 2004 a 2020.....</i>	<i>36</i>
<i>Graf 3: Nejvyšší výška sněhové pokrývky naměřená na stanici Labská bouda v letech 2004 a 2020.....</i>	<i>36</i>
<i>Graf 4: Vývoj podílu rozlohy jednotlivých sledovaných druhů na celkové ploše Bílé louky s využitím klasifikátoru MLC mezi lety 2004–2020.....</i>	<i>56</i>
<i>Graf 5: Vývoj podílu rozlohy jednotlivých sledovaných druhů na celkové ploše Bílé louky s využitím.....</i>	<i>57</i>

1. Úvod a cíle práce

Práce se zabývá analýzou vývoje vegetace na území východní krkonošské tundry s využitím metod dálkového průzkumu Země. Tento unikátní ekosystém, který se nachází nad horní hranicí lesa, je domovem mnoha rostlinných i živočišných druhů. Zároveň s jeho jedinečností je ale také velmi citlivý na různé změny a rušivé faktory. I proto krkonošská tundra, podobně jako další ekosystémy, nezůstává beze změny. Hlavním cílem této práce je zmapovat aktuální stav vegetace, ale také její dlouhodobý vývoj s využitím současného (rok 2020) a archivního (rok 2004) barevného ortofota se třemi spektrálními pásmy (red, green, blue) s prostorovým rozlišením 50 cm (data z roku 2020 byla převzorkována z rozlišení 10 cm/pix kvůli srovnatelnosti), prostřednictvím klasifikace vegetačního pokryvu v úrovni druhů/společenstev.

Archivní ortofota (barevná) jsou jediným zdrojem dat DPZ, který zachycuje v relativně podrobném prostorovém rozlišení (řád desítek centimetrů) stav vegetace v minulosti (v případě tundry právě od roku 2004) v relativně dlouhém časovém období (cca 15 let). Dílčími cíli práce bylo zjistit, zda jsou tato ortofota pro podrobnou klasifikaci vegetace vhodná, jak přesných výsledků je možné v úrovni druhů dosáhnout a zda je tato data možné použít pro hodnocení změn zejména vybraných travních druhů (třtina chloupkatá – *Calamagrostis vilosa*, bezkoleneček modrý – *Molinia Caerulea* a metlice trsnatá – *Deschampsia cespitosa*) u nichž se předpokládá, že by v průběhu sledovaného období mohly zvětšovat rozlohu na úkor ekologicky vhodnějšího druhu smilky tuhé (*Nardus stricta*). Hypotézou této práce je, že jmenované druhy se rozšiřují na úkor smilky tuhé, která tak v zájmovém území postupně ubývá. Jednou z výzkumných otázek tedy je, zda lze tento předpoklad potvrdit pomocí metod dálkového průzkumu Země, které se při mapování vegetace v poslední době velmi osvědčily.

Analyzovány jsou ale i další druhy vegetace, a to jednak v úrovni širšího území centrální části východní tundry (plocha cca 2 km² v okolí Luční boudy), a dále ve třech územích 100 × 100 m s odlišnými typy vegetace (Luční hora, Bílá louka, Úpské rašeliniště), pro něž je k dispozici hustší síť trénovacích a validačních dat. Ke klasifikacím a validaci je využit rozsáhlý a přesný soubor (v terénu sbírán s přesností na centimetry) referenčních botanických dat (polygony vymežující lokalizaci výskytu všech klasifikovaných druhů) pořízený v průběhu let 2019–2020 spolupracovníky

z Botanického ústavu AV ČR v Průhoncích v rámci projektu s názvem „Vývoj metod pro sledování změn krkonošské vegetace analýzou dat z multispektrálních, hyperspektrálních a LiDAR senzorů UAV“ řešeného na základě objednávky Správy KRNAP, jehož hlavním řešitelem je tým TILSPEC z katedry Aplikované geoinformatiky a kartografie PřF UK v Praze (www.tilspec.cz). Základní otázkou je, zda je možné s využitím tohoto botanického datasetu i přes velmi nízké spektrální rozlišení, a ne zcela dostatečné prostorové rozlišení ortofot dosáhnout dobré přesnosti klasifikace zejména uvedených travních druhů (celková přesnost klasifikace alespoň 70% a uživatelské a zpracovatelské přesnosti travních druhů též alespoň cca 70%).

Volba správné klasifikační metody je pro tento výzkum klíčová, a proto byly použity a porovnány tři různé metody – klasifikátor Maximum likelihood (MLC), klasifikátor Random forest (RF) a objektově orientovaná klasifikace (OBIA). Důležitým cílem této práce je tedy otestovat různé přístupy ke klasifikaci a docílit tak co možná nejlepších výsledků.

Jako jedno z úskalí práce je nutné zmínit, že nebyla dostupná trénovací a validační data pro rok 2004. Jsme si vědomi toho, že použití trénovacích a validačních dat z roku 2019–2020 může být vzhledem k možným změnám ve výskytu jednotlivých tříd v případě řízených klasifikací do určité míry zavádějící. Proto byla využita i neřízená klasifikace, která pracuje pouze s informací, která je skutečně obsažena v obrazových datech. Výsledky neřízené klasifikace byly v případě jedné malé plochy – Bílá louka – porovnány s výsledky řízených klasifikací. Pro podrobnější analýzu vývoje vegetace byly použity dvě časové řady ortofot (2004, 2020 a 2010, 2012, 2018). Tato analýza byla možná pouze pro Bílou louku, protože se zde vyskytují dominantně právě 4 sledované travní druhy, a i v případě neřízené klasifikace je možné relativně dobře přiřadit výslednému tematickému výstupu konkrétní třídy. V případě širšího území a dalších ploch bylo problematické přesné určení jednotlivých kategorií ve výstupu neřízené klasifikace, a tudíž porovnání řízených a neřízených klasifikací nebylo možné.


2. Literární rešerše a úvod do problematiky

2.1. Dálkový průzkum Země

Definice dálkového průzkumu existuje mnoho, jak z českého, tak světového prostředí. Dobrovolný (1998) popisuje dálkový průzkum jako „metodu, kterou lze získávat informace o objektech a jevech na dálku, tedy bez přímého kontaktu s danými objekty a jevy. Celý proces přitom stojí na dvou základních principech – člověk získává kvalitativní i kvantitativní informace o věcech a jevech, které ho obklopují, pomocí různých přístrojů nebo svými silami; každá tato věc nebo jev charakteristickým způsobem ovlivňuje své okolí“. Velmi podobně definují dálkový průzkum také Halounová a Pavelka (2008), kteří navíc podrobně zabývali elektromagnetickým zářením během procesu přenosu informací. Podle Campbell (1996) je dálkový průzkum Země způsob získávání informací o zemském povrchu, během něhož jsou využívány snímky pořízené z ptáčích perspektiv. Podstatou při snímání je elektromagnetické záření, které je odraženo nebo emitováno ze zemského povrchu, v jednom nebo více intervalech spektra.

Nositelem informací o objektech a jevech v dálkovém průzkumu Země (DPZ) je právě elektromagnetické záření, které je tvořené elektromagnetickými vlnami. Celý proces získávání dat v DPZ je popsán na obrázku 1. Podstatou je zmíněné elektromagnetické záření, které buď může vyzařovat aktivní zemský povrch nebo se může jednat o odražené záření Slunce či umělé družice. Záření je následně odraženo v různé míře podle toho, jaké vlastnosti má objekt, od kterého se odráží. Intenzitu vyzářeného nebo odraženého záření poté měří přístroje uchycené na nosičích. Nosičem může být například letadlo nebo družice. Naměřená data jsou následně poslána na zemský povrch, kde jsou různými metodami zpracována uživateli (Dobrovolný 1998; Halounová, Pavelka 2008; Kolář a kol. 2000).

Obrázek 1: Proces sběru dat v DPZ



Zdroj: CCRS (2022). A: zdroj záření, B: záření v atmosféře, C: interakce s objektem, D: změření záření přístrojem, E: přenos, příjem dat, F: zpracování dat, G: využití informace v aplikaci

2.2. Klasifikace obrazu

Klasifikace je jednou ze základních metod zpracování obrazu. Podstatou klasifikace je rozřazení jednotlivých obrazových prvků do homogenních tříd. Na základě původních naměřených hodnot radiometrických charakteristik obrazu jsou následně vytvořeny informační třídy, které nesou informaci o vlastnostech objektů a jevů náležících k dané třídě. Existují různé přístupy ke klasifikaci. Každý typ klasifikace je jednoznačně definován určitým rozhodovacím pravidlem (klasifikátorem), podle kterého je možné prvky rozřazovat do zmíněných informačních tříd (Dobrovolný, 1998). Podle Koláře (1990) tyto klasifikátory nemusí být založeny pouze na spektrálním chování objektů, ale také například na jejich prostorovém či časovém chování, textuře a tvaru.


Klasifikace můžeme dělit na řízené a neřízené. Dělení probíhá na základě způsobu a především momentu, ve kterém do procesu zasahuje uživatel (Dobrovolný, 1998). Při řízené klasifikaci uživatel předem volí třídy, do kterých mají být objekty rozřazeny, pomocí jasně definovaných trénovacích ploch (Kolář a kol. 2000). To jsou taková data, o kterých lze s jistotou tvrdit, že reprezentují danou třídu. Mohou být nasbírána přímo v terénu, nebo například nad obrazovými daty, jako jsou mapy a letecké snímky. S využitím zvoleného klasifikátoru jsou všechny obrazové prvky porovnávány s trénovacími plochami a následně jsou přiřazeny do jedné z definovaných tříd. Neřízená klasifikace pro vytvoření informačních tříd trénovací plochy nepotřebuje. Pomocí

shlukové analýzy vytváří spektrální třídy, které může uživatel libovolně sloučit a přiřadit jim informační obsah (Dobrovolný, 1998).

Klasifikace lze také dělit na pixelové a objektově orientované. Pixelové klasifikace jsou jedny z nejvíce používaných metod při zpracování obrazu. Díky menší citlivosti na nízké prostorové rozlišení snímku se velmi hodí pro časové analýzy. Základní jednotkou, se kterou se zde pracuje, je pixel. Pro každý jeden pixel jsou vypočítány hodnoty samostatně a neuvažuje se vztah k ostatním pixelům snímku. Naopak objektové klasifikace vyžadují vysoké prostorové rozlišení snímku. Pracuje se segmenty (malými homogenními shluky pixelů), které zde tvoří nejmenší základní jednotku pro vypočítání hodnot (Zhou, Troy, Grove 2008).

Podle studie Blatsche (2010), se při nízkém prostorovém rozlišení určitý prostorový prvek (např. budova) může zobrazovat jako jeden pixel. Naopak při vysokém prostorovém rozlišení se už se daná budova zobrazuje jako shluk více pixelů (viz obr. 2). Díky zlepšujícím se technologiím se objektově orientované klasifikace v posledních letech rychle získávají na popularitě a stávají se předmětem studií v různých vědních disciplínách (Zhou, Troy, Grove 2008).

Obrázek 2: Vztah sledovaného objektu a prostorového rozlišení



Zdroj: Blatsche (2010). a: nízké prostorové rozlišení – pixel je značně větší než objekty, b: střední prostorové rozlišení – pixely a objekty jsou stejně velké, c: vysoké prostorové rozlišení – pixely jsou značně menší než objekty

2.3. Metody klasifikace

2.3.1. Klasifikátor maximální pravděpodobnosti

Prvním použitým klasifikátorem v této práci je klasifikátor maximální pravděpodobnosti (Maximum likelihood, MLC). Podle Zagajewski a kol. (2005) je tento klasifikátor jednou z nejvíce používaných, ale také nejvíce spolehlivých metod řízené klasifikace. Jedná se o pixelovou klasifikaci, kdy pro každý jeden pixel obrazu je statisticky vypočítána hodnota pravděpodobnosti, s jakou daný pixel náleží ke každé předem definované třídě. Tyto hodnoty se následně mezi sebou porovnají a pixel se přiřadí do té třídy, pro kterou byla vypočítána nejvyšší pravděpodobnost (Harris Geospatial Solutions, 2022).

Nevýhodou této metody je podle studie Hagner a Reese (2007) citlivost na kvalitu trénovacích dat. Pokud plocha trénovacích dat každé třídy nedostatečně odráží skutečnou rozlohu tříd v obraze, může dojít k tomu, že některé z těchto tříd budou nadhodnoceny. Proto ve své studii autoři vytvořili upravenou verzi MLC, která je založená na opakování klasifikací. Z první klasifikace je získána informace o podílu zastoupení jednotlivých tříd na výsledném obraze a podle toho je následně upraven trénovací soubor, který vstupuje do finální klasifikace.

2.3.2. Klasifikátor Random forest

Random forest (RF) je jednou z metod strojového učení, která se používá pro klasifikaci a regresi (Gao a kol. 2015). Během procesu klasifikace se využívá velkého množství rozhodovacích stromů, do kterého vstupují náhodně vybrané podmnožiny trénovacích dat a proměnných (Fawadhech a kol. 2014). Během klasifikace Random forest jsou vyžadovány dva základní parametry, jejichž nastavení je velmi důležité pro úspěšnost a přesnost výsledné klasifikace. Těmito parametry jsou n_{Tree} (počet vytvořených stromů v lese) a M_{try} (počet náhodně vybraných proměnných pro rozdělení uzlu stromu) (Belgiua, Drągut 2016). Následně je pixel přiřazen do té třídy, do které ho rozhodovací stromy nejčastěji zařadily (Breinam, 2001). V posledních letech se klasifikátor Random forest na poli dálkového průzkumu Země používá stále častěji, a to především z důvodu přesných výsledků a celkové rychlosti procesu (Rodriguez–Galiano a kol. 2012).

2.3.3. Objektově orientovaná klasifikace

Jak již bylo zmíněno výše v odstavci 2.2, objektově orientovaná klasifikace (OBIA) je vhodná pro snímky s vysokým prostorovým rozlišením. U takových snímků jsou objekty často lépe vykresleny pomocí shluků tvořených jednotlivými pixely (Blaschke, 2010). Proces klasifikace je rozdělen do dvou fází. V první fázi dochází k segmentaci, kdy je celý obraz rozdělen do segmentů/objektů, které jsou tvořeny skupinou pixelů s podobným spektrálním projevem. Druhá fáze už poté segmenty tradičně klasifikuje pomocí zvolené klasifikační metody (Meneguzzo a kol. 2013).

2.4. Klasifikace v tundře

Klasifikací vegetace v pásmu alpské hranice lesa (alpine treeline ecotone) se ve své práci zabýval Král (2009). Cílem této studie bylo podat komplexní zprávu o současném stavu vegetačního pokryvu v Národní přírodní rezervaci Praděd. Výzkum se soustředil zejména na přechodnou zónu mezi subalpínskými lesy a alpínskou tundrou. Zaměřil se především na zmapování zavlečené borovice kleč a antropogenních útvarů. Jako vstupní data zde byla zvolena ortofotomapa se zeleným, červeným a blízkým infračerveným pásmem pořízená dne 21. 8. 2000. Celkem dvanáct různých scén bylo spojeno do jednoho výsledného obrazu, který byl posléze převzorkován na 0,9 m. Hlavní metodou zpracování byla řízená klasifikace s použitím klasifikátoru Maximum likelihood. Ovšem kvůli vysoké spektrální variabilitě reálného vegetačního pokryvu a zároveň nízkému spektrálnímu rozlišení snímku některé třídy nešlo jednoznačně odlišit. Proto byla následně provedena i analýza textury obrazu. Pomocí pohyblivého okna o velikosti 7×7 pixelů byla postupně vypočítána směrodatná odchylka pro všechna pásma. Touto analýzou autor oddělil plochy porostlé smrky a plochy bez smrku. Ovšem ani touto metodou nebylo možné identifikovat některé typy povrchu. Například nešlo odlišit komunikace a stavby od skal nebo suchých smrků. Nakonec tedy byla provedena také manuální klasifikace, po které se podařilo identifikovat 7 tříd krajinného pokryvu – antropogenní plochy, pastviny a holé plochy, kleč, listnaté stromy, smrkové kultury, stojící suché smrky a úlomky a skalní výchozy. Finální celková přesnost dosáhla 78 %.

Zagajewski a kol. (2015) se věnoval studiu horské vegetace ve východní části Tatranského národního parku v Polsku. Pro klasifikaci krajinného pokryvu zde byly použity hyperspektrální letecké snímky pořízené dvěma senzory. Data ze senzoru DAIS

obsahovala 79 spektrálních pásem v rozmezí vlnové délky 400–2600 nm s konečným prostorovým rozlišením 3 m. Druhým senzorem ROSIS bylo nasnímáno 115 spektrálních pásem v rozmezí 400–850 nm. Prostorové rozlišení bylo v tomto případě 1 m. Na těchto vstupních datech byla provedena řízená i neřízená klasifikace, jejichž výsledky byly následně porovnány s botanickými mapami, které vznikly na základě terénního výzkumu. Jako první proběhla neřízená klasifikace, která ovšem nepřinesla dobré výsledky a autor se o ní příliš nezmiňoval. Na základě této klasifikace ale byly definovány třídy, které budou tvořit legendu při řízených klasifikacích. Těmi byly kosodřevina, lesy, louky, skály, jezera, stíny a turistické trasy. Řízená klasifikace na snímku ze senzoru DAIS v kombinaci s klasifikátorem Maximum likelihood proběhla dvakrát. Nejprve se všemi spektrálními pásmy, kde bylo dosaženo celkové přesnosti 78 %. Poté pouze s vybranými pásmy, ale výsledky nepřinesly zlepšení (přesnost 71 %). Pro dosažení lepších výsledků autor navrhl použít také texturní analýzu, kterou nabízí klasifikátor Neural Network. Tuto metodu otestoval pouze na třídě kosodřeviny, kdy v porovnání s ostatními metodami měla třída nejlepší výsledky. Autor tedy došel k předpokladu, že ostatní třídy by také mohly dosahovat lepších výsledků při použití metody založené na analýze textury.

Klasifikací arktické tundry na Richardsově ostrově v Kanadě se zabývali Ullmann a kol. (2014). Pro zkoumání krajinného pokryvu byla použita multispektrální data TerraSAR-X, PolSAR, Rararsat-2 a Landsat 8. Jako referenční data byly použity letecké snímky s vysokým prostorovým rozlišením a data nasbíraná přímo v tundře. Na základě nasbíraných dat byly hodnoceny přesnosti klasifikací. Klasifikační legendu tvořilo 6 tříd – vodní plochy, holá půda, nízká travnatá tundra, smíšená středně vysoká tundra, vysoká keříčková tundra a mokřady. Testována byla řízená i neřízená klasifikace v kombinaci se všemi typy snímků. Nejlepší výsledky přinesla řízená klasifikace při použití snímku PolSAR, kdy celková přesnost dosáhla 87 %. Použití radarových dat jednoznačně zlepšilo rozlišení jednotlivých typů krajinného pokryvu na základě výšky vegetace.

Langford a kol. (2016) se zabývali klasifikací funkčních typů rostlin arktické tundry v oblasti arktické pobřežní nížiny na Aljašce. Používali multispektrální data senzoru WorldView-2 s prostorovým rozlišením přibližně 2 m v kombinaci s digitálním modelem terénu vytvořeného pomocí LiDARových dat. Výzkum byl založen na odhadu procentuální pokryvnosti jednotlivých funkčních typů (tj. mokré graminoidy, suché graminoidy, byliny, mechy, lišejníky a holá půda) na 4 vybraných modelových plochách

1 × 1 m. Autoři vytvořili statistické vztahy mezi spektrálními a topografickými charakteristikami (získanými pomocí dálkového průzkumu) a rozložením funkčních typů rostlin na sledovaných plochách. Odvozené vztahy následně aplikovali na celé zájmové území o rozloze 586 ha. Algoritmus, který byl vytvořen pro upscaling, se skládal ze shlukové analýzy k-means a IDW (inverse distance weighted) interpolace. Představeny byly dva typy map. První verze mapy byla vytvořena pomocí jediného snímku WorldView-2 pořízeného uprostřed vegetační sezóny. Druhá verze mapy byla složena z několika snímků v průběhu celé vegetační sezóny a umožnila tak prostřednictvím zachycení fenologických fází rostlin dosáhnout vyšší přesnosti. Studie tímto potvrdila předpoklad autorů, že fenologie rostlin je důležitou charakteristikou, kterou lze použít k oddělení jednotlivých funkčních typů rostlin.

2.5. Klasifikace v krkonošské tundře

Příkladem studie, která využívala ortofota pro účely klasifikace, je výzkum od autorů Potůčková a kol. (2021). Pomocí retrospektivní analýzy archivních leteckých ortofot zkoumali vývoj vegetace arktó–alpínské tundry v Krkonoších. Hlavním cílem práce bylo zhodnotit dynamiku vegetačního pokryvu krkonošské tundry za posledních 80 let (1963 až 2018). Archivní ortofota se tedy přímo nabízela. Jednalo se pravděpodobně o jediný zdroj dat, který mohl pokrýt takto dlouhý časový úsek. Tato studie představila hypotézu, že lidská činnost hrála v minulosti důležitou roli při rozvoji travních společenstev na úkor křovin a že současný bezzásahový režim může tento vzniklý balanc narušit. Proto se také autoři snažili poskytnout základní pokyny pro zachování biologické rozmanitosti. Pro účely klasifikace byla sestavena časová řada leteckých ortofot, která obsahovala snímky z let 1936, 1953, 1977, 2001 a 2018. Snímky z let 1936 a 1977 musely být nejprve ortorektifikovány. Snímek z roku 2018 měl prostorové rozlišení 0,10 m, zatímco ostatní snímky 0,5 m. Také spektrální rozlišení se mezi snímky měnilo. První 3 snímky časové řady byly černobílé a obsahovaly pouze jedno spektrální pásmo. Snímek, pořízený v roce 2001, měl 3 pásma (červené, zelené a modré). V roce 2018 už byl snímek pořízen digitálně s červeným, zeleným, modrým a infračerveným pásmem. Klasifikační legenda obsahovala 6 tříd – borovice kleč, travní společenstva, kamenná moře a suť, řídký les (zastoupený převážně smrkem ztepilým), antropogenní plochy, vodní plochy. Výsledky přinesly zjištění, že krkonošská tundra je poměrně stabilní krajinou. Na více než polovině zájmového nebyly zjištěny žádné změny ve složení vegetace. Největší změna byla

zaznamenána mezi kosodřevinou a travními společenstvy. Kosodřevina během sledovaných let zvětšila svou rozlohu z 30,6 % na 48,6 %, a to především na úkor travních druhů. Ty naopak na rozloze ubyly o 15,1 procentních bodů. Kromě snímku 2018 nebyla provedena žádná hodnocení přesnosti. Nebyly k dispozici žádné datové soubory, které by bylo možné použít pro validaci klasifikací. Autoři tedy provedli rozsáhlou manuální kontrolu chyb, které při procesu klasifikace vznikly, aby tak dosáhli co nejlepší přesnosti. Klasifikace snímku z roku 2018 už hodnocena byla. Na podkladu barevného ortofota vzniklo celkem 385 kontrolních bodů. Počty bodů odpovídající jednotlivým třídám byly rozděleny podle výsledné velikosti rozlohy s kritériem minimálního počtu 20 bodů pro každou třídu. Celková přesnost dosáhla 92,3 % s Kappa indexem 0,89.

Dalším příkladem studie, která pochází z prostředí krkonošské tundry, je výzkum od autorů Suchá a kol (2015). Autoři zde porovnávali různá multispektrální data, která se lišila prostorovým i spektrálním rozlišením. Zkoumali, jaký typ snímku je nejvíce vhodný pro klasifikaci vegetace nad horní hranicí lesa v krkonošském národním parku. Pro porovnání zvolili družicová data WorldView-2 s vysokým prostorovým rozlišením (2 m) a osmi spektrálními pásmy, dále data Landsat 8 s prostorovým rozlišením 30 m a sedmi spektrálními pásmy. Podobně jako v této práci bylo vybráno ortofoto, ovšem s jiným prostorovým rozlišením (12,5 cm) a čtyřmi spektrálními pásmy. Pro dosažení co možná nejpřesnějších výsledků byly také použity různé klasifikační metody. Pro ortofoto byla zvolena objektově orientovaná klasifikace, data Landsat 8 byla zkoumána s použitím pixelové klasifikace a pro data WorldView-2 byla provedena objektová i pixelová klasifikace. Pro pixelové klasifikace byl použit klasifikátor Maximální likelihood (MLC), Support Vector Machine (SVM) a Neural Net (NN). Objektová klasifikace poté probíhala pouze s využitím klasifikátoru SVM.

Velmi důležitou částí výzkumu bylo vytvoření legendy. Protože jednotlivé typy vegetačního pokryvu často utvářely shluky, které byly menší než jeden pixel snímku Landsat 8, bylo zapotřebí stanovit dvě verze. Detailní legenda s dvanácti třídami byla použita pro ortofoto a snímky WorldView-2. Vytvořena byla také zjednodušená legenda s osmi třídami, která byla použita pro všechny typy dat. Pro obě legendy bylo dosaženo nejvyšší celkové přesnosti u ortofota. U detailní legendy bylo dosaženo 83,56 % a 71,96 % u zjednodušené. Celkově výzkum jednoznačně potvrdil, že vysoké

prostorové rozlišení je zásadním kritériem pro dosažení dobré celkové přesnosti při detailní klasifikaci.

Klasifikací vegetace krkonošské tundry se zabývali také Kupková a kol. (2017). Jejich studie využívala družicová data Sentinel-2 s velikostí pixelu 10 a 20 m. Dále hyperspektrální letecká ortofota pořízená senzory ASIA Dual a APEX s podstatně vyšším prostorovým rozlišením (1–5 m). Porovnávány byly výsledky pixelové i objektové klasifikace. Ovšem kvůli velikosti pixelu dat Sentinel-2 byla nad tímto snímkem provedena pouze pixelová klasifikace. Podobně jako v Suchá a kol. (2015) byly vytvořeny dvě legendy, detailní a zjednodušená. Nejlepší celkové přesnosti (84,3 %) bylo dosaženo u dat AISA Dual v kombinaci s použitím klasifikátoru SVM. Podle očekávání přinesly obecně nejhorší výsledky družicové snímky Sentinel-2, které při použití klasifikátoru NN dosáhly celkové přesnosti pouze 58 %. Velmi dobře šlo odlišit kosodřevinu, kamenná moře a antropogenní plochy. Naopak problémový byl bezkoleneček modrý, který se často klasifikoval jako metlice trsnatá nebo smilka tuhá. Velikost pixelu vůbec neumožnila použít detailní legendu, proto bylo využito zjednodušené legendy, kde výsledky byly o 20 % lepší.

Müllerová (2005) se ve své práci věnuje klasifikaci subalpínské vegetace v okolí Labské boudy. Hlavními cíli této studie bylo zjistit, zda multispektrální letecká data mohou být použita pro klasifikaci subalpínské vegetace a do jaké úrovně je možné odlišit jednotlivé vegetační druhy. Dále také do jaké míry lze srovnávat výsledky této analýzy s výsledky, které byly získány v terénu, nebo jestli je možné odhalit temporální změny vegetace pomocí časové řady snímků. Pro mapování a analýzu změn krajinného pokryvu byly použity multispektrální letecké snímky z let 1984, 1989 a 1997. Snímky s prostorovým rozlišením 1 m obsahovaly červené, zelené, modré a infračervené pásmo. Analogové snímky byly před použitím nejprve oskenovány a digitálně upraveny.

Vegetace byla klasifikována na snímku z roku 1989 a to řízenou i neřízenou klasifikací. Pro zvýraznění vegetace byla provedena úprava histogramu, PCA (Principal Component Transformation) a NDVI (Normalised Difference Vegetation Index). Při neřízené klasifikaci byl použit klasifikátor ISODATA a podařilo se jím odlišit 6 tříd s výslednou celkovou přesností 63 %. Ovšem některé důležité typy krajinného pokryvu se oddělit nepodařilo, například smilkový trávník a silnici. Lepších výsledků dosáhla řízená klasifikace s klasifikátorem Maximum likelihood. Celkem bylo identifikováno

7 tříd, kterými byly kosodřevina, společenstva smilky, vysoké trávy a bylinná společenstva, vegetace podél silnic, silnice, vodní plochy a zamokřená území. Tato klasifikace dosáhla přesnosti 79 %.

Krkonošskou tundrou se ve svých studiích zabývali také autoři z Varšavské university. Marcinskowska–Ochytra a kol. (2018) se věnovali klasifikaci společenstev vysokohorské vegetace na polské straně Krkonošského národního parku. Pro účely klasifikace zde byla použita hyperspektrální data pořízená senzorem APEX, která obsahovala 288 spektrálních pásem. Pomocí klasifikátoru Support Vector Machine (SVM) bylo klasifikováno 22 tříd vegetačního pokryvu. Pro dosažení lepších výsledků byly na snímky aplikovány transformace MNF a PCA. Dalším krokem bylo hodnocení přesnosti klasifikací, které probíhalo na základě vegetačních map a polygonů, které byly nasbírány manuálně nad ortofotem. Nejvyšší celková přesnost dosažená v této práci byla 84 %. Z celkových 24 tříd se 14 vyklasifikovalo se zpracovatelskou přesností a 16 s uživatelskou přesností více než 80 %. Studie tak prokázala, že tento typ dat i použitý klasifikátor jsou vhodné pro klasifikaci horské vegetace.

3. Zájmové území

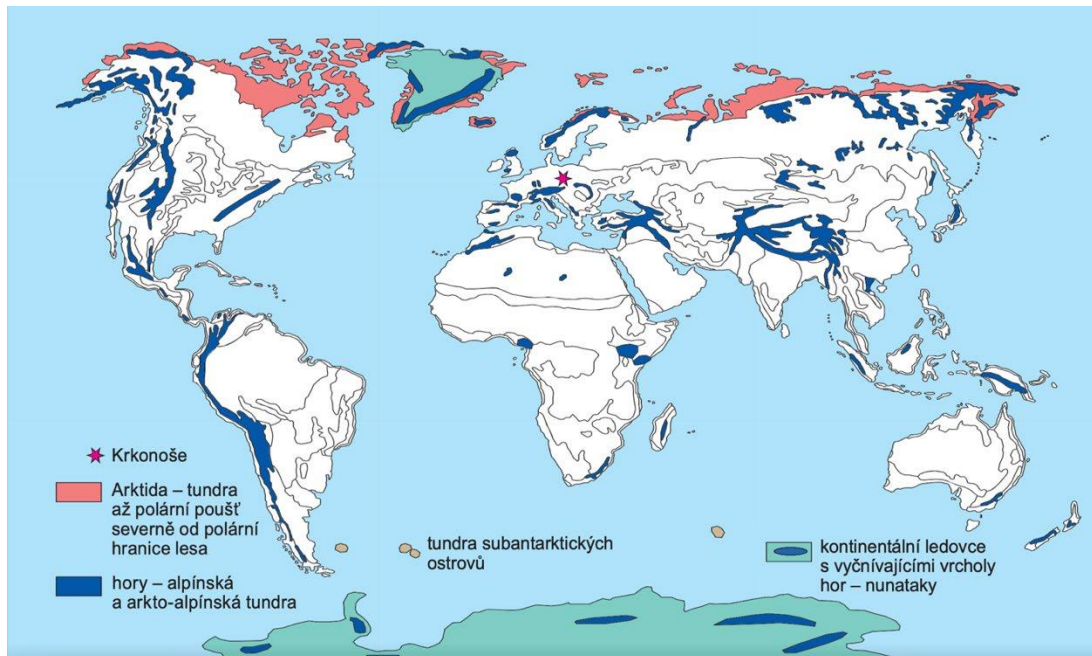
3.1. Definice tundry

Tundra je jedním ze suchozemských biotů Země, který pokrývá přibližně 2,3 % rozlohy souše. Typické pro ni jsou nepříznivé klimatické podmínky, které brání růstu stromovitých dřevin. Proto můžeme tundru definovat také jako trvale bezlesou krajinu (Kociánová, Štursa, Vaněk 2015).

Podle místa výskytu lze tundru členit na několik typů (viz obr. 3). Tundra, která se nachází v jižních polárních oblastech, je označována jako polární tundra. Rozléhá se ale pouze na malých nezaledněných plochách subarktických ostrovů, jako jsou Falklandy, Jižní Georgie, Jižní Sandwichovy ostrovy a Kerguelény. Malé nezaledněné části na okrajích Antarktidy jsou poté nazývány polární oázy. V severních polárních oblastech lze hovořit o arktické tundře, která se rozkládá převážně na území severní Ameriky, severu Eurasie, Grónska, Islandu a dalších arktických ostrovů. Tundra se ovšem nachází i mimo polární oblasti, a to na hřebenech vysokých pohoří obou polokoulí. V takovém případě je tundra označována jako alpská tundra. V místech, kde se oba typy tunder vzájemně prolínají, se nachází arko–alpská tundra. Právě k té lze přiřadit i krajinu nejvyšších

hřebenů a vrcholků Krkonoš neboli krkonošskou tundru (Kociánová, Štursa, Vaněk 2015).

Obrázek 3: Rozšíření biomu tundra na Zemi



Zdroj: KRNAP (2015)

3.2. Krkonošská arкто–alpská tundra

Pro lepší pochopení existence krkonošské tundry je zapotřebí nejprve porozumět jedinečné poloze Krkonoš, jež se nachází na rozhraní masivů střední, severní a západní Evropy. Právě Krkonoše se svou nadmořskou výškou, v porovnání s ostatními hercynskými středohořími (Vysoké Sudety, Harz, Schwarzwald, Vogézy a Francouzské středohoří), výrazně odlišují. Svými hřebeny nejvíce převyšují alpskou hranici lesa, která v těchto místech kolísá kolem 1 300 m n. m., a proto jsou zde k nalezení prvky vysokohorské přírody. Další masiv s podobnými rysy se nachází až stovky kilometrů daleko. Mezi takové lze řadit například pohoří ve Skandinávii nebo na Britských ostrovech. Krkonoše zároveň plní funkci spojovacího článku se severskou přírodou. I přesto, že mezi pohořími na severu Evropy a Krkonošemi leží rozsáhlé polské a severoněmecké nížiny, se pomocí skandinávského ledovcového štítu tamní příroda dostala až do českého pohraničí. Během pleistocenního ochlazení docházelo k opakovanému rozšiřování ledovce směrem na jih a právě při jeho okrajích se jižním směrem šířila také severská tundra. Ledovec ale nikdy nepřekonal krkonošské hřebeny,

ovšem přispěl k ochlazení podnebí ve střední Evropě. Naproti tomu alpský ledovec, který se v té době šířil na sever s sebou přinesl alpínskou tundru a horské trávníky. Tento mnohem mohutnější ledovec už se dokázal dostat až k české kotlině. Do té doby nikdy nezaledněné Krkonoše tak představovaly masu, která vyčnívala mezi severským ledovcovým štítem a zaledněným komplexem Alp. Po příchodu oteplení během holocénu začínaly nížiny, pahorkatiny a svahy opět zarůstat lesy. Výjimkou jsou ovšem Krkonoše, kde vznikla unikátní bezlesá horská krajina, která tvoří izolovaný ostrov uprostřed severní Evropy. Postupem času se zde stabilizovala nemalá populace reliktních severských i alpínských druhů. Díky dlouhodobé izolovanosti nejvyšších partií Krkonoš od ostatních pohoří se zde začaly projevovat také některé projevy fenoménu ostrovní biogeografie, které vedly ke vzniku nových endemických druhů a poddruhů rostlin i živočichů (Štursa, 2013).


Pojem arкто–alpínská tundra byl poprvé použit ve studii Soukupové a kol. (1995). Podle autorů se jedná o ekosystém přirozeného bezlesí utvářeného kryogenními, nivačními a eolickými procesy, který vznikl v periglaciálním období pleistocénu na začátku holocénu a je trvale udržovaný současnými podnebnými podmínkami. Průměrná roční teplota se pohybuje v rozmezí 0 °C až +1 °C a průměrná teplota nejteplejšího měsíce v roce nepřesahuje 10 °C. Doba sněhové pokrývky může trvat až 6 měsíců a roční úhrn srážek se pohybuje kolem 1 500 mm. Důležitá je také absence permafrostu a intenzivní eolická činnost v nejvyšších polohách. Na základě převládajících procesů je podle Soukupové a kol. (1995) možné krkonošskou tundru dále členit na kryo–eolickou zónu, kryo–vegetační zónu a niveo–glacigenní zónu.

Zdejší fauna a flóra tvoří unikátní mozaiku ekosystémů alpínských vrcholů, klečových porostů, trávníků a rašelinišť náhorních plošin. Mezi nejvíce dominantní typy patří jednoznačně borovice kleč a smilka tuhá. Společně se smrkem ztepilým je borovice kleč původní krkonošskou dřevinou, která zaznamenává v posledních letech velmi dynamický rozvoj (Vacek a kol. 2007). Smilkové trávníky jsou také převážně původní, ovšem na některých místech druhotně zarůstají plochy po zaniklé kleči. Další dominantou jsou severská rašeliniště, která se nachází na náhorních plošinách západních a východních Krkonoš. Svým uspořádáním a přírodními poměry se velmi podobají rašeliništím severní Evropy. Mezi ty nejznámější poté patří Úpské rašeliniště, kterému se mimo jiné tato práce také věnuje. Krkonošská rašeliniště jsou domovem mnoha glaciálních reliktních, jako jsou

například ostružiník moruška, všivec krkonošský a rašeliník Lindbergův. Na nejvyšších a vzájemně izolovaných vrcholcích Krkonoš (Sněžka, Studniční a Luční hora, Smogornia, Vysoké Kolo a Kotel) se vyvinula mozaika kamenitých sutí s řídkou vegetací mechorostů, lišejníků a travin. Závětrné svahy ledovcových karů díky specifickému mikroklimatu nabízí velké množství jeřábníků, z nichž některé jsou i krkonošskými endemity (KRNAP, 200?).

Tato práce se zabývá územím východní krkonošské tundry, která se nachází v okolí Luční Boudy. Předmětem výzkumu je tedy širší území tundry s rozlohou přibližně 2 km², která pokrývá značnou část východní tundry. Tato plocha byla zvolena s ohledem na to, že zahrnovala jeden radiometricky stejnorodý snímek z širšího ortofota dané oblasti. V rámci tohoto území jsou také zkoumány 3 malé čtvercové plochy 100 × 100 m, kterými jsou Bílá louka, Luční hora a Úpské rašeliníště. Mapu zájmového území s vymezením jednotlivých ploch představuje obr. 4.

Obrázek 4: Mapa vymezení zájmových území



3.3. Hodnocené třídy vegetačního pokryvu

V této kapitole jsou detailně charakterizovány všechny třídy vegetačního pokryvu, které byly předmětem klasifikací. Pro klasifikaci širšího území tundry byly využity všechny níže popisové třídy, ovšem pro malé plochy byly využity pouze ty třídy, které se v daném území nachází. Výsledná legenda pro každé území je rozepsána v kapitole 4.3.

Kosodřevina

Kosodřevina, jinými slovy také borovice kleč (*Pinus mugo*), je keř, který se typicky vyskytuje na střeoevropských pohořích. Je nadmíru světlomilná a je pro ni nemožné růst ve stínu. Proto se vyskytuje tam, kde ji ostatní dřeviny nemohou ohrozit, tedy nad hranicí lesa. Na území Česka jsou poté Krkonoše jediným pohořím, kde nad lesní hranicí tvoří souvislé formace (viz obr. 5). V ostatních případech je pouze uměle vysazena, například v Hrubém Jeseníku a Kralickém Sněžníku. Jedná se o dřevinu, která je velmi odolná vůči nepříznivým až extrémním klimatickým podmínkám (Úradníček a kol. 2001). Může dorůstat výšky 3–4 m a často v krajině tvoří mozaiku s dalšími typy subalpínské vegetace (Kočí, 2010a). Nejčastěji kvete v červnu až červenci, kdy letorosty mají světle zelenou barvu, která později přechází do hnědé (Randuška, 1983).

Obrázek 5: Borovice kleč (*Pinus mugo*)



Zdroj: TILSPEC, BOTANY.cz

Smilka tuhá

Další třídou, která je předmětem klasifikací, je smilkový trávník s dominancí smilky tuhé (*Nardus stricta*) a velmi malým procentem zastoupení ostatních druhů (do 10 %). Díky svému širokému spektru biologických vlastností je smilka (viz obr. 6) značně přizpůsobivým druhem a to jí dovoluje zarůstat nejrozmanitější stanoviště. V Evropě se vyskytuje od Alp, Pyrenejí, Balkánu a Karpat po Skandinávii. Nejvíce jí vyhovují vyšší nadmořské výšky, od horní hranice lesa až do poloh přes 3 000 m n. m. (Stursa, Wild 2014). Roste v hustých trsech. V místech, kde dochází k častým disturbancím (např. vodní nebo větrná eroze) ji nahrazují jiné druhy travin. Na stanovištích s vysokou sněhovou pokrývkou ji poté často střídá metlice trsnatá.

Obrázek 6: Smilka tuhá (*Nardus stricta*)



Zdroj: BOTANY.cz

Metlice trsnatá

V Česku se metlice trsnatá (*Deschampsia cespitosa*) vyskytuje hojně na celém území, ovšem více je zastoupena ve vyšších polohách. Je velmi nenáročným a značně přizpůsobivým druhem. Dobře zvládá sucho i vlhko, dokáže růst podél potoků i na sněhových výležiscích v horách. Jak lze vidět na obrázku 7, tvoří husté trsy, které mohou být vysoké až 150 cm (Mrázek, 2012).

Obrázek 7: Metlice trsnatá (*Deschampsia cespitosa*)



Zdroj: BOTANY.cz, Wikimedia commons

Třtina chloupkatá

Třtina chloupkatá (*Calamagrostis villosa*) je tráva vysoká přibližně 60–130 cm s dlouhými 3–8 mm širokými listy zbarvenými do tmavě zelené barvy (Grulich, 2011). V období květu, které je zhruba od června do července, mají stébla načervenalou barvu (viz obr. 8). Neroste v trsech, ale protože se množí podzemními výběžky, vytváří souvislé porosty (Davišek, Culek 2013). Její výskyt je vázán na výskyt původních smrčín a kyselých vlhkých půd. K nalezení je například na svazích ledovcových karů nebo v travnatých zónách krkonošské tundry. Náleží do třídy subalpínských vysokostébelných trávníků a patří mezi její hlavní zástupce.

Obrázek 8: Třtina chloupkatá (*Calamagrostis villosa*)



Zdroj: BOTANY.cz

Bezkolenec modrý

Bezkolenec modrý (*Molinia caerulea*) je bylina, která vytváří kompaktní zelené trsy (viz obr. 9). Vyskytuje se téměř v celé Evropě a je velmi nenáročný na vlastnosti prostředí. Dokáže růst v bažinách, na pastvinách, vřesovištích i horských svazích. Jedinou podmínkou jeho výskytu je ovšem dostatečné množství světla (Perenniculum, 2022).

Obrázek 9: Bezkolenec modrý (*Molinia caerulea*)



Zdroj: Wikimedia commons

Subalpínská brusnicová vegetace

Tato třída představuje nízkou keříčkovou vegetaci (10–30 cm), která je v daném zájmovém území zastoupena především brusnicí borůvkou (*Vaccinium myrtillus*). Brusnicové porosty se tradičně vyskytují na návětrných i závětrných svazích a to zejména v blízkosti horní hranice lesa (viz obr. 10). Tam poté tvoří přirozený lem horských smrčín. Jako v případě zájmového území této práce, se brusnice mohou vyskytovat také na vrcholových plošinách, kde společně s kosodřevinou v krajině utváří mozaiku. V současné době je brusnicová vegetace vystavována nadměrné expanzi trav, která probíhá právě na úkor brusnic (Krahulec, Kočí 2010a).

Obrázek 10: Subalpínská brusnicová vegetace se zastoupením brusnice borůvky (*Vaccinium myrtillus*)



Zdroj: Katalog biotopů ČR, BOTANY.cz

Alpínská vřesoviště

Alpínská vřesoviště se nachází především na větrných vrcholcích hor, vyvýšených vrcholových plošinách a izolovaných vrcholcích skal (viz obr. 11). Jedná se o nízké porosty keříčků (20–40 cm vysoké), kde dominantním druhem je jednoznačně vřes obecný (*Calluna vulgaris*). Doba květu je od července do září, ve které se korunní lístky zbarvují do charakteristické jasně růžově fialové, nebo bílé barvy (Kubát a kol. 2002). Podobně jako brusnicová vegetace také vřesoviště podléhají expanzi travních společenstev (Krahulec, Kočí 2010b).

Obrázek 11: Alpínská vřesoviště s největším zastoupením vřesu obecného (*Calluna vulgaris*)



Zdroj: Katalog biotopů ČR, Wikimedia commons

Mokřady a rašeliniště

Vysokohorské mokřady a rašeliniště se vyznačují velkým podílem vody (viz obr. 12), která pochází například z pramenišť řek, jakými v případě krkonošské tundry mohou být Bílé Labe a Úpa. Prostředí je velmi kyselé a může být obohacováno minerálně chudou podzemní vodou. Dominantními rostlinnými druhy jsou zde jednoznačně rašeliníky, například rašeliník hnědý (*Sphagnum fuscum*). Hojně jsou zastoupeny suchopýry – suchopýr pochvatý a úzkolistý (*Eriophorum vaginatum*, *Eriophorum angustifolium*) a také mechy (Hájek, Rybníček 2001).

Obrázek 12: Mokřady a rašeliniště



Zdroj: krkonose.eu

Vyfoukávaný alpínský trávník

Typickými stanovišti pro vyfoukávaný alpínský trávník jsou vrcholové plošiny, hřebeny a izolované vrcholy (viz obr. 13). Mezi takové patří právě i vrchol Luční hory v Krkonoších, která je předmětem této práce. Jak už název napovídá, jeho výskyt je podmíněn činností větru. Ten omezuje vývoj vegetace i stabilitu půdy. V krajině je vyfoukávaný alpínský trávník mozaikou holé půdy, suti, kamenů a trsů travin, jako jsou metlička křivolaká (*Avenella flexuosa*), lišejník islandský (*Cetraria islandica*), vranec jedlový (*Huperzia selago*) a porosty mechu (Kočí, 2010b).

Obrázek 13: Vyfoukáváný alpský trávník se zastoupením metličky křivolaké (*Avenella flexuosa*)



Zdroj: Katalog biotopů ČR, Wikimedia commons

Smrk ztepilý

Smrk ztepilý (*Picea abies*) je hojně zastoupenou dřevinou na téměř celém území Česka. Dorůstá výšky kolem 50 m s kmenem širokým v průměru až 1,5 m (viz obr. 14). V mládí velmi dobře snáší i stinná stanoviště a tak je často rozšířen do porostů jiných dřevin, kde následně postupně zaujímá jejich místo. Výskyt smrku je do jisté míry limitován půdní vlhkostí. Pro jeho dobrý růst je důležitý dostatek vláhy. Nesnášenlivý je pak k vysokým teplotám a silnému větru. Má poměrně mělký kořenový systém, a proto na větrných stanovištích může docházet k vývratům. Smrk byl v minulosti intenzivně vysazován a právě tyto smrkové monokultury jsou v současnosti velmi ekologicky nestabilní.

Obrázek 14: Smrk ztepilý (*Picea abies*)



Zdroj: Katalog biotopů ČR, Wikimedia commons

Kamenná moře

Kamenná moře se v zájmovém území nachází především na Luční hoře a v jejím okolí (viz obr. 15). Jedná se o akumulaci hrubých až slabě zaoblených úlomků, které většinou pokrývají svahy nebo vrcholové partie hor. Mohou vznikat mrazovým nebo chemickým zvětráváním (Whittow, 1984). K této třídě byly přiřazeny také objekty antropogenního původu, které měly velmi malou celkovou rozlohu. Mezi takové objekty patří například památník obětem hor.

Obrázek 15: Kamenná moře



Zdroj: KRNAP.cz

Cesta

Zájmovým územím prochází také štěrková cesta, která rozděluje širší území tundry na východní a západní část. Táhne se od jihu k severu a vede přímo k Luční boudě. Pro tuto cestu tedy bylo potřeba vytvořit samostatnou třídu, aby při klasifikaci nebyla přiřazena do třídy kamenná moře.

Stín


Poslední třídou, která je předmětem klasifikací, jsou stíny. Protože snímky pochází ze slunných dnů, bylo potřeba oddělit stíny od vegetace. Stíny vznikaly hlavně kvůli vysokému zastoupení smrku ztepilého a borovice kleč.

3.4. Klimatické podmínky ve sledovaných letech

Aby bylo možné porovnávat výsledky klasifikací, vegetace by se měla na obou snímcích nacházet ve stejné fenologické fázi. Fenologickou fází se rozumí vnější viditelná změna v průběhu životního cyklu. Spektrální projev jednotlivých vegetačních druhů se může vlivem klimatických podmínek během roku měnit. Proto se tato kapitola věnuje právě analýze počasí ve sledovaných letech. Bohužel meteorologická stanice Luční bouda zaznamenává data až od roku 2009. Následující data tedy pochází ze stanice Labská bouda, která se nachází přibližně 11,2 km od zájmového území této práce.

Průměrné měsíční teploty v letech 2004 a 2020 jsou v jarních a letních měsících téměř totožné (viz graf 1). Nástup vyšších teplot na jaře má ve sledovaných letech velmi podobný průběh. V nejteplejších měsících se hodnoty pohybují kolem 10 °C. Ovšem v lednu a únoru už se teploty lišily. Zima v roce 2020 byla mnohem chladnější. Zatímco v roce 2004 byla průměrná měsíční teplota v lednu -2 °C, v roce 2020 byla $-8,2$ °C.

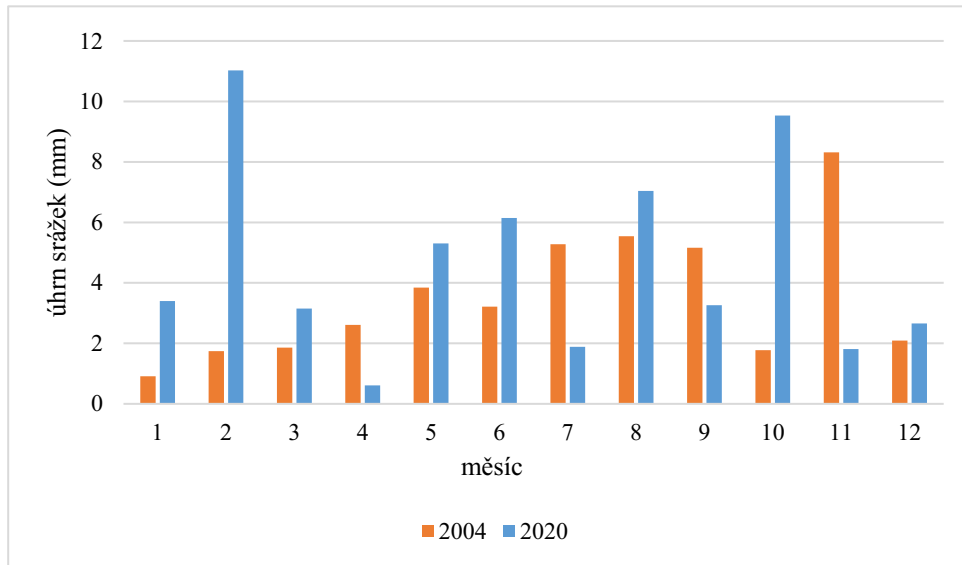
Graf 1: Průměrná měsíční teplota vzduchu naměřená na stanici Labská bouda v letech 2004 a 2020



Zdroj: vlastní zpracování na základě dat ČHMÚ

Graf 2 popisuje průběh srážek během sledovaných let. Zatímco průměrné měsíční teploty vzduchu spolu relativně korespondují, průměrné měsíční úhrny srážek se od sebe velmi liší. V roce 2004 mají srážky plynulý nárůst s letním maximem v srpnu. Rok 2020 má hodnoty velmi rozkolísané.

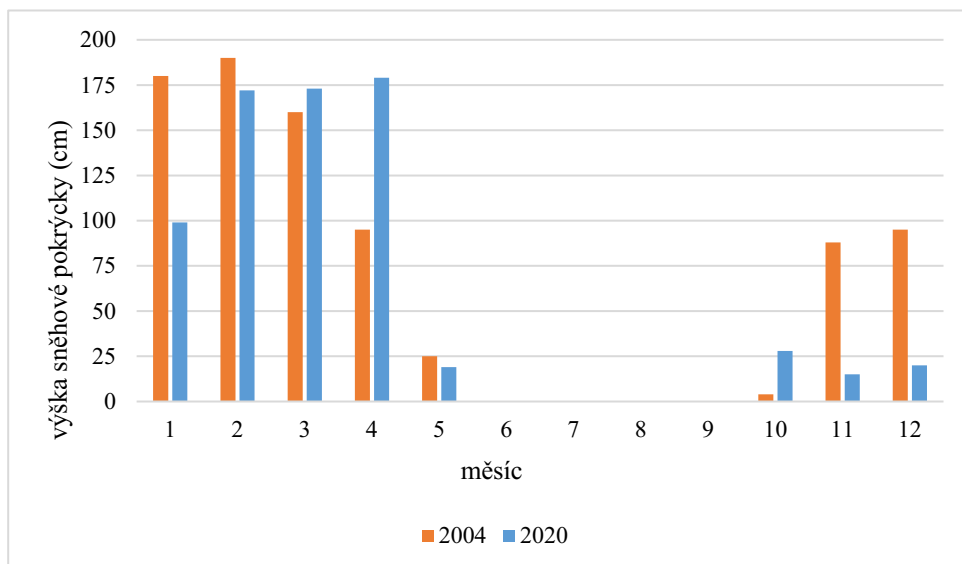
Graf 2: Průměrný měsíční úhrn srážek naměřený na stanici Labská bouda v letech 2004 a 2020



Zdroj: vlastní zpracování na základě dat ČHMÚ

Poslední obrázek se věnuje době trvání sněhové pokrývky. Přítomnost sněhové pokrývky by nedovolovala vegetaci se rozvíjet a nástup vegetační sezóny by se tak mohl opozdit. Jak lze vidět v grafu 3, v obou sledovaných letech byla sněhová pokrývka naposled přítomna v květnu a vegetační sezóna tedy začínala v obou sledovaných letech přibližně ve stejném čase.

Graf 3: Nejvyšší výška sněhové pokrývky naměřená na stanici Labská bouda v letech 2004 a 2020



Zdroj: vlastní zpracování na základě dat ČHMÚ

4. Data a metodika

4.1. Vstupní data

Pro klasifikace byla využita ortofota, která byla uspořádána do dvou časových řad. Snímky tvořící první časovou řadu (2004 a 2020) byly v obou letech pořízeny ve stejný den – 31. července. Druhá časová řada obsahovala snímky pořízené na začátku července v letech 2010, 2012 a 2018. Jedná se o georeferencované ortografické zobrazení zemského povrchu, jehož snímky jsou pořízeny tak, aby odpovídaly kladu mapových listů Státní mapy v měřítku 1 : 5 000. Jeden snímek tedy ve skutečnosti zobrazuje plochu zemského povrchu o velikosti 2 × 2,5 km. Ortofota jsou barevně vyrovnaná a obsahují 3 spektrální pásma – červené, zelené a modré. Prostorové rozlišení se v průběhu let několikrát změnilo. Do roku 2008 byly snímky pořizovány s velikostí pixelu 0,50 m, od roku 2009 do roku 2015 s velikostí 0,25 m, v letech 2016 až 2020 s velikostí 0,20 m. Od roku 2021 až po současnost jsou snímky pořizovány s pixelem 0,125 m. V roce 2010 se začalo snímkování provádět pomocí digitální kamery, která výrazně přispěla k zlepšení kvality snímků (Geoportál ČÚZK, 2022).

Protože se jedná o již výsledný produkt, předzpracování snímků před použitím tedy téměř nebylo nutné. Nebyly provedeny žádné atmosférické korekce. Jedinou úpravou bylo převzorkování snímků. Kvůli optimalizaci výsledků byl snímek z roku 2020 převzorkován na stejný pixel, jako v případě roku 2004, tedy na velikost pixelu 0,5 m. Snímky 2010, 2012 a 2018 byly převzorkovány na velikost 0,25 m.

4.2. Terénní data

Trénovací a validační data jednotlivých tříd krajinného pokryvu byla získána během letních měsíců let 2019 a 2020. Data byla nasbírána botaniky Botanického ústavu AV ČR v Průhonicích a legenda byla konzultována s botaniky ze Správy Krkonošského národního parku (<https://www.krnap.cz>).

Celkem bylo nasbíráno 3 444 polygonů pro 27 vegetačních kategorií. V rámci tohoto zájmového území se nachází i malé plochy (s rozlohou cca 1 ha), které byly v minulosti předmětem výzkumů předchozích studií krkonošské tundry. Jmenovitě jsou to Bílá louka, Luční hora, U Luční boudy, U zahrádky a Úpské rašeliniště. Trénovací a validační data pro tyto plochy tvoří velmi hustou síť rovnoměrně rozložených polygonů.

Tato data byla doplněna o polygony, které byly nasbírány napříč celým územím východní tundry, ovšem data pro širší území tundry nedosahují takové hustoty. Všechna data byla následně sloučena do jednoho výsledného datasetu, který celkem obsahoval 29 tříd krajinného pokryvu. Těmito třídami jsou – metlička křivolaká, metlička křivolaká s vysokým zastoupením dalších druhů, organozem, brusnice borůvka, puklěčka islandská, třtina chloupkatá, ostřice Bigelowova, ostřice bažinná s podílem organozemě, metlice trsnatá, suchopýr úzkolistý, suchopýr pochvatý, vranec jedlový, sítina niťovitá, borovice kleč, porost lišejníků s dominancí dutohlávky, bika bělavá, porost mechů, bezkolenec modrý, smilka tuhá, rašeliník, ostřice zobánkatá s podílem organozemě, smrk ztepilý, kamenná moře, suchopýrek trsnatý, mozaika suchopýrku trsnatého, suchopýru pochvatého a smilky tuhé, brusnice vlochyně, vřes obecný, vyfoukávaný alpínský trávník a vodní hladina. Data byla následně rozdělena na trénovací a validační polygony.

Rozloha trénovacích a validačních polygonů je v poměru 1 : 2 (stejně byla trénovací a validační data rozdělena i v rámci analýz výše zmíněného projektu). Jedna třetina rozlohy polygonů tedy tvoří trénovací soubor a dvě třetiny tvoří validační soubor. Tato metoda byla aplikována na všechny výše zmíněné třídy krajinného pokryvu.

Pro podrobnější analýzu trénovacích dat byl proveden test separability jednotlivých tříd. Pomocí testu je zjištěna míra separace, která je vyjádřena číselnými hodnotami. Mezi nejpoužívanější míry separability patří index separability a transformovaná divergence s Jeffriesovou–Matusitovou vzdáleností, které byly použity i v této práci. Na základě výsledků analýzy je možné do jisté míry trénovací data upravit a zlepšit tak výslednou přesnost klasifikace (Liu a kol. 2020; Thomas a kol. 1987).

4.3. Klasifikační legenda

Legenda pro klasifikaci vegetace byla vytvořena na základě nasbíraných terénních dat (viz kapitola 4.2.). Aby klasifikační legenda byla zcela kompletní a nedocházelo tak k chybám v klasifikacích, bylo nutné doplnit další 3 třídy – cesta, objekt (antropogenní) a stín. Zájmovým územím prochází šterková cesta vedoucí k Luční Boudě, která se původně klasifikovala jako kamenná moře. Samotná Luční Bouda se nachází až za hranicí zájmového území, ovšem vyskytuje se zde i několik malých objektů antropogenního původu. Poslední dodatečně vytvořenou třídou byly stíny, které bylo potřeba oddělit od samotné vegetace. Protože stíny v roce 2004 nebyly shodné se stíny v roce 2020, byly

vytvořeny dvě samostatné sady dat. Data pro tyto třídy byla získána nad použitým ortofotem, nikoliv přímo v terénu. Další úpravy legendy byly provedeny po výsledcích prvních klasifikací, kdy nejprve došlo ke sloučení některých tříd (viz tabulka 1). Po důsledném uvážení byla nakonec třída alpínských zapojených trávníků z klasifikačního procesu vypuštěna. Výsledná legenda všech zájmových ploch s přehledem rozdělení trénovacích a validačních ploch, které byla použita pro klasifikaci vegetace, je k nahlédnutí v tabulkách 2–5.

Tabulka 1: Použitá klasifikační legenda (klasifikované kategorie) a dílčí druhy/povrchy zahrnuté do jednotlivých tříd legendy

výsledná legenda	dílčí druhy/povrchy zahrnuté do jednotlivých tříd
alpínská vřesoviště	vřes obecný
bezkolenec modrý	bezkolenec modrý
kamenná moře	kamenná moře, antropogenní objekty
kosodřevina	borovice kleč
metlice trsnatá	metlice trsnatá
mokřady a rašeliniště	organozem, ostřice bažinná s podílem organozemě, suchopýr úzkolistý, suchopýr pochvatý, sítna nitřovitá, porost mechů, rašeliník, ostřice zobánkatá s podílem organozemě, suchopýrek trsnatý, mozaika suchopýrku trsnatého, suchopýru pochvatého a smilky tuhé
smrk ztepilý	smrk ztepilý
subalpínská brusnicová vegetace	brusnice borůvka, brusnice vlohyně
třtina chloupkatá	třtina chloupkatá
vodní plochy	vodní plochy
vyfoukávaný alpínský trávník	metlička křivolaká, metlička křivolaká s vysokým zastoupením dalších druhů, puklčrka islandská, vranec jedlový, porost lišejníků s dominancí dutohlávky, vyfoukávaný alpínský trávník

Tabulka 2: Legenda a vstupní trénovací a validační data jednotlivých tříd pro Bílou louku

	rozloha trénovacích polygonů (m ²)	rozloha validačních polygonů (m ²)	celková rozloha (m ²)	rozloha trénovacích polygonů (%)	rozloha validačních polygonů (%)
*vyfoukávaný alpínský trávník	13,49	26,18	39,67	34,01	65,99
bezkolenec modrý	106,19	220,50	326,69	32,50	67,50
metlice trsnatá	68,15	130,92	199,07	34,24	65,76
třtina chloupkatá	117,60	206,83	324,43	36,25	63,75
smilka tuhá	51,79	97,43	149,22	34,70	65,30

*pro neřízené klasifikace byla tato třída vypuštěna z klasifikačního procesu

Tabulka 3: Legenda a vstupní trénovací a validační data jednotlivých tříd pro Luční horu

	rozloha trénovacích polygonů (m²)	rozloha validačních polygonů (m²)	celková rozloha (m²)	rozloha trénovacích polygonů (%)	rozloha validačních polygonů (%)
alpínská vřesoviště	82,33	167,39	249,72	32,97	67,03
kamenná moře a antropogenní plochy	137,11	280,12	417,24	32,86	67,14
kosodřevina	12,61	24,74	37,35	33,77	66,23
metlice trsnatá	10,61	20,48	31,10	34,13	65,87
smilka tuhá	61,14	129,27	190,41	32,11	67,89
subalpínská brusnicová vegetace	54,98	101,43	156,41	35,15	64,85
vyfoukávaný alpínský trávník	45,01	96,97	141,98	31,70	68,30

Tabulka 4: Legenda a vstupní trénovací a validační data jednotlivých tříd pro Úpské rašeliniště

	rozloha trénovacích polygonů (m²)	rozloha validačních polygonů (m²)	celková rozloha (m²)	rozloha trénovacích polygonů (%)	rozloha validačních polygonů (%)
alpínská vřesoviště	4,11	4,69	8,80	46,74	53,26
bezkolenec modrý	2,63	5,22	7,85	33,53	66,47
kosodřevina	209,60	380,37	589,98	35,53	64,47
mokřady a rašeliniště	193,30	331,06	708,11	33,50	66,50
smilka tuhá	43,89	72,51	116,40	37,71	62,29
smrk ztepilý	2,58	2,65	5,22	49,36	50,64
subalpínská brusnicová vegetace	2,71	4,84	7,55	35,95	64,05
vodní plochy	3,01	5,52	8,53	35,25	64,75

Tabulka 5: Legenda a vstupní trénovací a validační data jednotlivých tříd pro širší území tundry

	rozloha trénovacích polygonů (m ²)	rozloha validačních polygonů (m ²)	celková rozloha (m ²)	rozloha trénovacích polygonů (%)	rozloha validačních polygonů (%)
alpínská vřesoviště	119,79	238,69	358,49	33,42	66,58
bezkoleneček modrý	237,23	470,88	708,11	33,50	66,50
cesta	58,17	115,75	173,93	33,45	66,55
kamenná moře	241,58	488,43	730,00	33,09	66,91
kosodřevina	1701,03	3346,68	5047,71	33,70	66,30
metlice trsnatá	386,66	785,77	1172,44	32,98	67,02
mokřady a rašeliniště	338,10	610,78	948,88	35,63	64,37
smrk ztepilý	50,40	98,12	148,52	33,94	66,06
subalpínská brusnicová vegetace	92,40	176,00	268,39	34,43	65,57
třtina chloupkatá	430,60	812,01	1242,61	34,65	65,35
vodní plochy	43,31	69,17	112,47	38,50	61,50
vyfoukávaný alpínský trávník	153,61	301,92	455,53	33,72	66,28
stín 2004	19,57	39,28	58,86	33,26	66,74
stín 2020	118,41	236,86	355,27	33,33	66,67

4.4. Klasifikace

Pro docílení co možná nepřesnějších výsledků byly testovány různé přístupy ke klasifikaci. Pro základní časovou řadu, která obsahuje snímky z dvou let – 2004 a 2020, byly provedeny pro všechna sledovaná území následující klasifikace. Z pixelových přístupů ke klasifikaci jsou to klasifikátor Maximum likelihood a metoda Random forest. Pro porovnání byla také provedena objektivě orientovaná klasifikace v kombinaci s klasifikátorem Support Vector Machine.

Podrobněji bylo dále analyzováno území Bílé louky. Kvůli testování možnosti přesněji detekovat změny/vývoj byla přidána další časová řada snímků, která vyplnila úsek mezi snímky první časové řady. Výsledná časová řada zahrnovala ortofota z let 2004, 2010, 2012, 2018 a 2020. Prostorové rozlišení ortofot bylo v tomto případě 25 cm, pouze ortofoto z roku 2004 mělo rozlišení 50 cm. Pro těchto pět snímků proběhla neřízená klasifikace prostřednictvím klasifikátoru ISODATA (bylo nastaveno 10 iterací a 4 třídy). Aby bylo možné porovnat rozdíly mezi řízenou a neřízenou klasifikací, byl použit také klasifikátor Maximum likelihood. V tomto případě klasifikační legenda obsahovala pouze 4 třídy – bezkoleneček modrý, metlice trsnatá, smilka tuhá a třtina chloupkatá. Třída

vyfoukávaný alpínský trávník zde byla kvůli malé celkové rozloze a výsledkům analýzy separability z klasifikačního procesu vynechána.

4.5. Hodnocení přesnosti klasifikací

Nedílnou součástí každé klasifikace je také hodnocení její přesnosti. Pro hodnocení přesnosti klasifikací vegetace krkonošské tundry bylo v této práci využito softwaru ENVI 5.5, pomocí kterého byly na základě validačních dat sestaveny chybové matice pro každou klasifikaci. Chybová matice má vždy čtvercový tvar, kdy řádky a sloupce odpovídají klasifikovaným třídám. Řádky chybové matice představují klasifikovaná data a sloupce skutečnost (nasbíraná validační data). Na hlavní diagonále matice, která spojuje levý horní a pravý dolní roh, se nachází hodnoty, které správně vyklasifikované pixely. Tyto hodnoty by zpravidla měly být nejvyšší. Hodnoty mimo hlavní diagonálu jsou chyby z opomenutí, nebo chyby z nesprávného zařazení. Z klasifikační chybové matice vychází také další ukazatele, podle kterých lze hodnotit přesnost. Těmi jsou uživatelská, zpracovatelská a celková přesnost. Uživatelská přesnost (user's accuracy, UA) udává, s jakou pravděpodobností pixel přiřazený do určité třídy tuto třídu skutečně reprezentuje. Zpracovatelská přesnost (producer's accuracy, PA) je poměr mezi správně klasifikovanými pixely a pixely použitými pro testování dané třídy. Celková přesnost (overall accuracy) je z těchto ukazatelů přesnosti jediná, která není vztažena na každou třídu zvlášť, ale na celou klasifikaci. Počítá se jakou podíl všech správně vyklasifikovaných pixelů a celkového počtu klasifikovaných pixelů. Dalším ukazatelem přesnosti je Kappa koeficient, který porovnává přesnost klasifikace s přesností dosaženou čistě náhodným zařazením pixelů do jednotlivých tříd (Lillesand a kol. 2008). Déle byly také porovnávány rozlohy kategorií z jednotlivých klasifikací, což je další možné hodnocení přesnosti – do jaké míry se rozlohy získané jinými typy klasifikátorů shodují.

5. Výsledky

5.1. Hodnocení přesnosti klasifikací

Přesnost všech klasifikací byla vypočtena pomocí funkce *Confusion Matrix Using Ground Truth ROIs* v prostředí ENVI 5.5 na základě validačních polygonů. Pro všechny zájmové plochy byly provedeny klasifikace Maximum likelihood, Random forest a objektivě orientovaná klasifikace. Na území Bílé louky byla provedena také neřízená klasifikace ISODATA pro obě časové řady. Obecně nejméně přesné výsledky přinesla

metoda Maximum likelihood, pro kterou byly celkové přesnosti nejnižší (s výjimkou Luční hory). Nejvyšší přesnosti bylo většinou dosaženo při použití objektivě orientované klasifikace s nastavením parametrů – scale level 10 a merge level 20. Ve všech případech byly celkové přesnosti vyšší pro rok 2020. Tato kapitola shrnuje výsledky hodnocení přesnosti jednotlivých klasifikačních metod. Obrázky 16 a 18–20 zachycují porovnání objektivě orientované klasifikace s nejlepší pixelovou klasifikací pro dané území.

5.1.1. Bílá louka

Území Bílé louky bylo podrobena detailnímu testování. Stejně jako pro ostatní plochy, zde byly použity klasifikátory Maximum likelihood, Random forest a objektivě orientovaná klasifikace. Pouze pro tuto plochu byla použita neřízená klasifikace ISODATA a byla přidána také druhá časová řada ortofot (roky 2010, 2012 a 2018).

Řízené klasifikace

Tabulka 6 shrnuje celkové přesnosti řízených klasifikací. Nejlepší výsledky přinesla v obou letech objektivě orientovaná klasifikace, která dosáhla 68,3 % v roce 2004 a 82,5 % v roce 2020. Nejlepší pixelovou klasifikací bylo v roce 2004 dosaženo metodou Maximum likelihood (63,4 %) a v roce 2020 metodou Random forest (80,4 %). Výsledky pro rok 2020 jsou celkově velmi vyrovnané a i další metody dosáhly dobré celkové přesnosti (nad 78 %). V případě roku 2004 dosáhly pixelové klasifikace výsledků pod 65 %. Výstupy klasifikací jsou na obrázku 16.

Tabulka 7 shrnuje uživatelské a zpracovatelské přesnosti, kterých dosáhly jednotlivé třídy při nejlepší pixelové a objektivě orientované klasifikaci během obou sledovaných let. Z tabulky je patrné, že třídou s nejhorsími výsledky je vyfoukávaný alpínský trávník, který v roce 2004 pro obě použité metody dosáhl nejvýše 6,1 %. Podle hodnot zanesených do tabulky je zřejmé, že nejlépe klasifikovanými třídami jsou (v obou letech i obou použitých metodách) bezkolonec modrý a třtina chloupkatá.

Provedeno bylo také hodnocení separability jednotlivých tříd, jejichž výsledky nejsou pro rok 2004 nejsou příliš dobré. Téměř jedinou dvojicí tříd, která vykazuje vysokou separabilitu, je bezkolonec modrý a smilka tuhá. Snímek z roku 2020 je o poznání lepší. Horší separabilitu má třída vyfoukávaný alpínský trávník, která má nízké

hodnoty v kombinaci s třtinou chloupkatou (0,3), smilkou tuhou (0,4) a metlicí trsnatou (0,5). Mírně nižší hodnoty má i dvojice třtina chloupkatá a smilka tuhá.

Tabulka 6: Bílá louka - celkové přesnosti klasifikací


klasifikační metoda	celková přesnost 2004 (%)	celková přesnost 2020 (%)
MLC	63,4	78,4
RF	62,7	80,4
OBIA	68,3	82,5

Tabulka 7: Bílá louka – zpracovatelská a uživatelská přesnost jednotlivých tříd při klasifikaci OBIA a RF pro roky 2004 a 2020


	2004				2020			
	OBIA		RF		OBIA		RF	
	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)
bezkoleneček modrý	88,2	83,2	83,6	74,7	95,8	94,4	95,5	91,5
metlice trsnatá	53	63,5	34,2	60,1	73,9	80,9	75,1	74,9
smilka tuhá	51	58,5	55,5	53,7	71,4	68,3	68	68
třtina chloupkatá	79,8	63,2	75,6	57,6	92,7	87,8	89,8	80,9
vyfoukávaný alpský trávník	1,6	6,1	0	0	20,4	25,1	4,5	44

Obrázek 16: Bílá louka – porovnání klasifikací OBIA a RF pro rok 2004 a 2020


objektově orientovaná klasifikace 2004




objektově orientovaná klasifikace 2020



klasifikace Random forest 2004



klasifikace Random forest 2020



- třtina chloupkatá
- smilka tuhá
- bezkoleneček modrý
- metlice trsnatá
- vyfoukávaný alpský trávník



0 25 50 m

Neřízená klasifikace

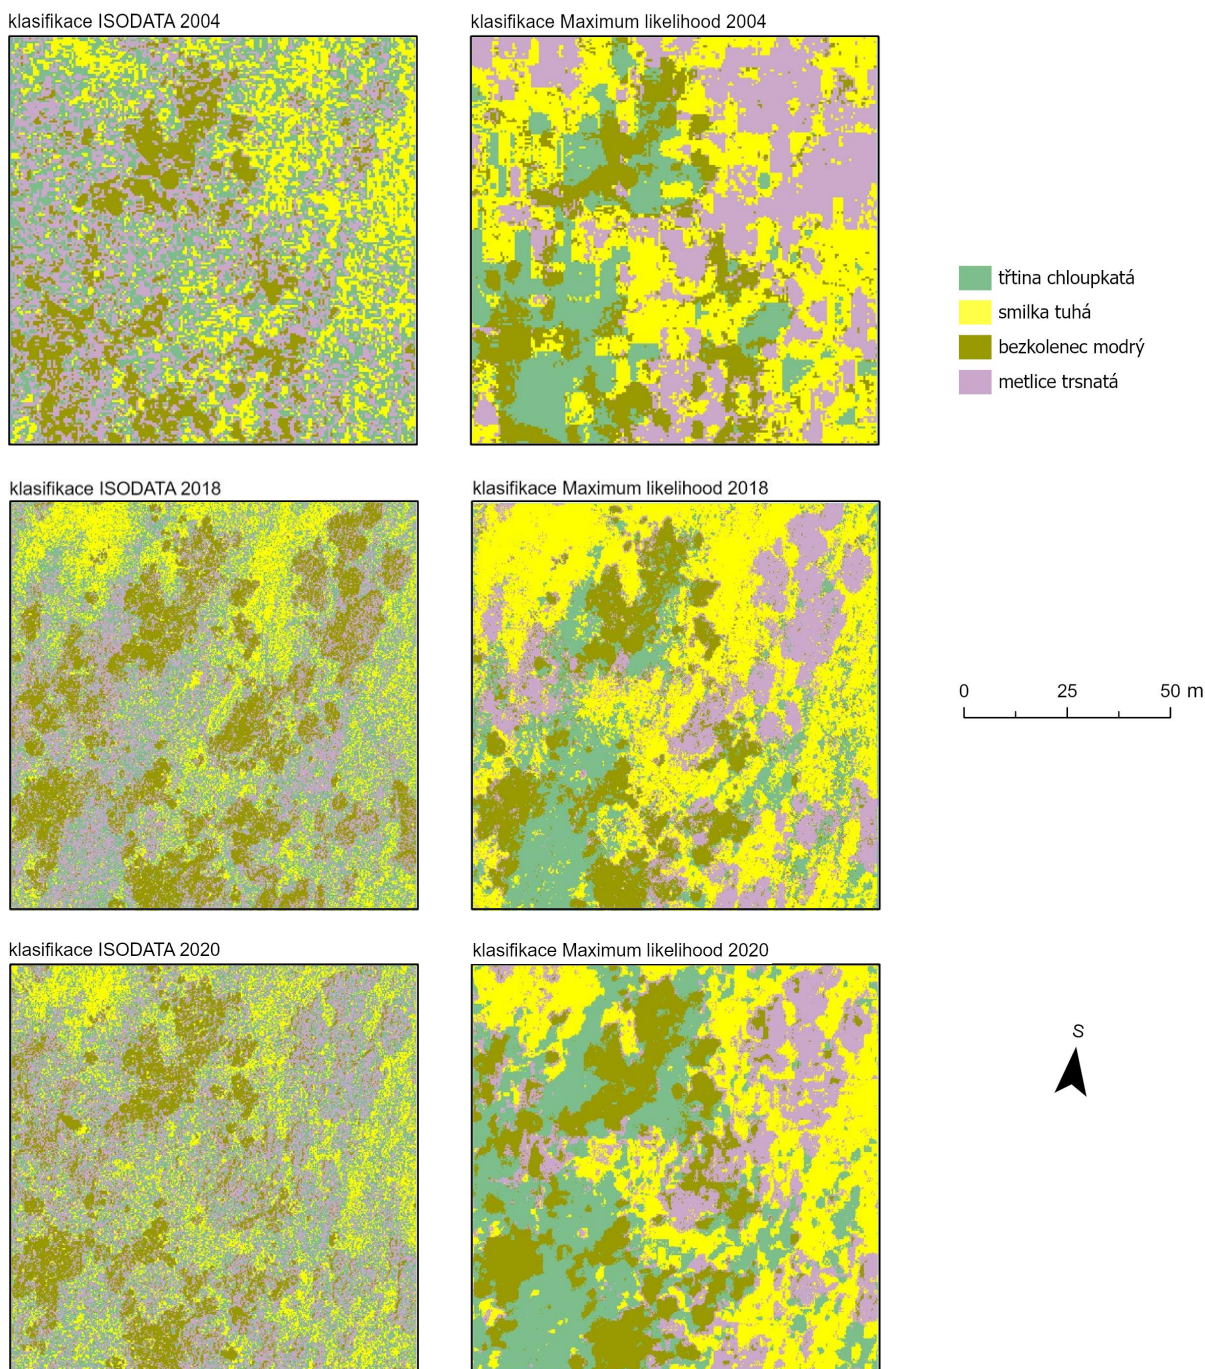
Území Bílé louky je mezi sledovanými plochami jedinečné. Jsou zde dominantně zastoupeny pouze 4 hlavní druhy travin, které jsou zároveň předmětem výzkumu a hlavního zájmu Správy KRNAP. Kromě těchto druhů se zde sice ještě vyskytují další druhy travin (například třída vyfoukávaný alpínský trávník), ty jsou ovšem svou rozlohou zcela marginální, a proto byly při neřízených klasifikacích zanedbány. V této části práce byly klasifikovány tedy pouze 4 dominantní kategorie (bezkoleneček modrý, metlice trsnatá, smilka tuhá a třtina chloupkatá) a neřízená klasifikace byla porovnána s klasifikací řízenou metodou Maximum likelihood. Celkem bylo provedeno 5 klasifikací pro data z let 2004, 2010, 2012, 2018 a 2020. Cílem bylo ověřit, do jaké míry je neřízená klasifikace spolehlivá/přesná a zda lze neřízenou klasifikaci použít pro dřívější časové horizonty, pro něž nejsou k dispozici trénovací a validační data z terénu. Dalším cílem bylo zjistit, jaký je rozdíl v klasifikaci neřízené ve srovnání s řízenou, pro níž používáme i v případě dřívějších časových horizontů trénovací a validační data ze současnosti. Neřízená klasifikace metodou ISODATA přinesla zajímavé výsledky. Vzniklým třídám bylo možné poměrně jednoduše přiřadit název druhu, který představují. Porovnání let 2004, 2018 a 2020 pro obě klasifikační metody ukazuje obrázek 17. Z obrázku je zřejmé, že výstupy řízené a neřízené klasifikace se dost liší. Řízené klasifikace působí dojem vyhlazení pomocí filtru, zatímco neřízené klasifikace vykazují více efekt „pepř a sůl“.

Z tabulky 8 je pak zřejmé, že rozlohy získané klasifikací ISODATA se mezi lety 2004 a 2020 změnily pouze mírně, přičemž rozloha smilky mírně poklesla. Rozlohy získané klasifikacemi ISODATA a MLC se pro některé kategorie ve stejných letech dosti liší – v případě třtiny chloupkaté a smilky tuhé v roce 2020 a v případě metlice trsnaté a smilky tuhé v roce 2004. Ani v roce 2020, pro něž jsou k dispozici trénovací a validační data, nebyly pro všechny kategorie získány srovnatelné výsledky oběma typy klasifikací.

Zatímco metodou ISODATA byly zjištěny v rámci sledovaného období pouze malé změny, metoda MLC přinesla významně větší rozdíly mezi lety 2004 a 2020 pro kategorie třtina chloupkatá a metlice trsnatá. Obě metody detekovaly v rámci tohoto časového úseku úbytek kategorie smilka tuhá a nárůst kategorie bezkoleneček modrý. Rozdílné trendy pak ukázaly v případě kategorií třtina chloupkatá a metlice trsnatá.

V případě klasifikací Maximum likelihood bylo nejvyšší přesnosti 87,5 % dosaženo v roce 2018 (viz obr. 17). Vysoké přesnosti bylo dosaženo i pro rok 2020 (81,1 %). Přesto jsou klasifikační výstupy dosti odlišné. Nedá se předpokládat, že by v průběhu dvou let došlo k takto významné změně (zejména rozdíly v kategoriích třtina chloupkatá a bezkolenec modrý). Rozdíl může být způsoben tím, že snímek pro rok 2018 byl ze začátku července, kdy ještě nebyly některé druhy tak rozrostlé jako na snímku z roku 2020, který je z konce července.

Obrázek 17: Bílá louka – porovnání neřízené klasifikace ISODATA s řízenou klasifikací MLC pro rok 2004 a 2020



Tabulka 8: Porovnání rozloh sledovaných tříd při klasifikaci ISODATA a MLC v roce 2004 a 2020

	2004		2020		změna rozlohy	
	ISODATA	MLC	ISODATA	MLC	ISODATA	MLC
třtina chloupkatá	30,0	29,3	31,0	19,7	1,0	-9,6
metlice trsnatá	32,5	18,0	31,9	29,3	-0,6	11,3
bezkolenec modrý	16,4	17,7	18,0	20,7	1,6	3,0
smilka tuhá	21,1	35,0	19,1	30,3	-2,0	-4,7

5.1.2. Luční hora

Luční hora, jako jediná ze zájmových území, dosáhla nejlepších výsledků při klasifikaci Maximum likelihood (pro rok 2004 57,7 a 73,8 % pro rok 2020), jejíž výstup je na obrázku 19. Objektová klasifikace dosáhla celkové přesnosti 54,2 % v roce 2004 a 69,0 % v roce 2020. V roce 2004 žádná z metod nepřekonalala celkovou přesnost 60 % (viz tabulka 9). Výsledky pro toto území jsou přibližně o 10 procentních bodů horší než pro Bílou louku a Úpské rašeliniště. Podle výsledků separability je zřejmé, že druhy přítomné na Luční hoře mají často podobný spektrální projev a tedy nižší míru separability.

Zpracovatelské a uživatelské přesnosti pro rok 2004 při klasifikaci Maximum likelihood byly nejnižší pro třídu metlice trsnatá (PA 7,86 %, UA 35,48) a vyfoukávaný alpínský trávník (PA 29,63 %, UA 28,87 %). Tomuto výsledku odpovídá i test separability, podle kterého se alpínský vyfoukávaný trávník často klasifikoval jako jiné třídy. Naopak nejlepších přesností dosahovaly třídy subalpínská brusnicová vegetace (PA 59,63 %, UA 35,19 %) a smilka tuhá (PA 57,44 %, UA 53,64 %). Nejlépe a nejhůře klasifikované třídy si ve sledovaných letech poměrně odpovídají, i když samotné hodnoty už se liší. V roce 2020 mezi nejhůře klasifikované třídy patří také metlice trsnatá (PA 48,57 %, UA 60,71 %). Mezi nejlépe klasifikované třídy lze zařadit třída alpínská vřesoviště (PA 70,01 %, UA 71,69 %).

Pro objektovou klasifikaci vycházely zpracovatelské a uživatelské přesnosti nižší. Nejnižších hodnot dosahovala opět metlice trsnatá v roce 2004 i 2020. Zpracovatelská přesnost přinesla hodnoty 7,86 % pro rok 2004 a 48,57 % pro rok 2020 a uživatelská přesnost dosáhla v roce 2004 35,48 % a 60,71 %. Taktéž v obou letech má vysokou přesnost třída alpínská vřesoviště (2004 – PA 54,50 % a UA 68,30 %; 2020 – PA 70,01 % a UA 71,69 %), která jindy takto vysoké hodnoty neměla.


Výsledky separability v roce 2004 ukázaly, že zaměňovány byly často třídy subalpínská brusnicová vegetace a smilka tuhá, nebo vyfoukávaný alpínský trávník. Další dvojicí, která měla podobný spektrální projev byla metlice trsnatá a smilka tuhá (míra separability 0,8). V roce 2020 jsou výsledky podobné. Dvojice tříd, u kterých docházelo k záměně, byly metlice trsnatá a smilka tuhá (míra separability 0,7) a také metlice trsnatá a subalpínská brusnicová vegetace, které mají taktéž míru separability 0,7.

Tabulka 9: Luční hora – celkové přesnosti klasifikací


klasifikační metoda	celková přesnost 2004 (%)	celková přesnost 2020 (%)
MLC	57.7	73.8
RF	58,0	70.5
OBIA	54.2	69,0

Obrázek 18: Luční hora – porovnání klasifikací MLC a RF pro rok 2004 a 2020


objektově orientovaná klasifikace 2004




objektově orientovaná klasifikace 2020



klasifikace maximum likelihood 2004



klasifikace maximum likelihood 2020



- kamenná moře
- metlice trsnatá
- smilka tuhá
- alpínská vřesoviště
- borovice kleč
- vyfoukávaný alpínský trávník
- subalpínská brusnicová vegetace



0 25 50 m

5.1.3. Úpské rašeliniště

S výjimkou klasifikace Maximum likelihood bylo dosaženo nejlepších výsledků pro Úpské rašeliniště. Random forest i objektová klasifikace mají nejvyšší hodnoty celkové přesnosti ze všech testovaných ploch. Objektově orientovaná klasifikace, která dopadla nejlépe, dosáhla přesnosti 84,4 v roce 2004 a 85,2 % v roce 2020, zatímco Random forest v roce 2004 80,1 % a 82,3 % v roce 2020. Všechny celkové přesnosti jsou přehledně vypsány v tabulce 10 a výsledek nejlepších klasifikací je na obrázku 20.

Mezi nejlépe klasifikované třídy metodou objektové klasifikace patří borovice kleč v roce 2004 (PA 93,8 %, UA 93,7 %) i 2020 (PA 96,1 %, UA 96,0 %) společně s mokřady a rašeliništi (2004 – PA 88,5 % a UA 82,4 %; 2020 – PA 95,5 % a UA 80,4 %). Naopak mezi třídy s nejnižšími hodnotami přesnosti v obou sledovaných letech patří alpínská vřesoviště a subalpínská brusnicová vegetace. Právě tyto dvě třídy byly podle testu separability vyhodnoceny jako kategorie, mezi kterými v obou letech dochází k největším záměnám. Alpínská vřesoviště v roce 2004 dosahovala vyšších hodnot (PA 12,7 %, UA 40,9 %) než v roce 2020 (PA 7,0 %, UA 16,1 %). Subalpínská brusnicová vegetace má taktéž vyšší hodnoty v roce 2004, kdy zpracovatelská přesnost byla 16,7 % (v roce 2020 11,9 %) a uživatelská přesnost 100 %, zatímco v roce 2020 byla 45,5 %. V roce 2004 má nízké hodnoty přesnosti také třída vodní plochy (PA 5,8 %, UA 31,3 %), která má podle testu separability podobný spektrální projev jako třída mokřady a rašeliniště.

Pixelová klasifikace Random forest dosahuje nižších hodnot přesnosti než objektová klasifikace. V roce 2004 jsou zpracovatelské hodnoty velmi nízké. Třídy bezkoleneček modrý a vodní plochy mají zpracovatelskou přesnost do 5 %, zatímco jejich uživatelská přesnost je 100 %. Jako v případě objektové klasifikace mají třídy subalpínská brusnicová vegetace a alpínská vřesoviště v obou sledovaných letech nízké hodnoty přesnosti, které odpovídají hodnotám míry separability. Vysoké zpracovatelské a uživatelské přesnosti dosahují mokřady a rašeliniště v roce 2004 (PA 78,9 %, UA 79,1 %) i 2020 (PA 90,1 %, UA 78,9 %).

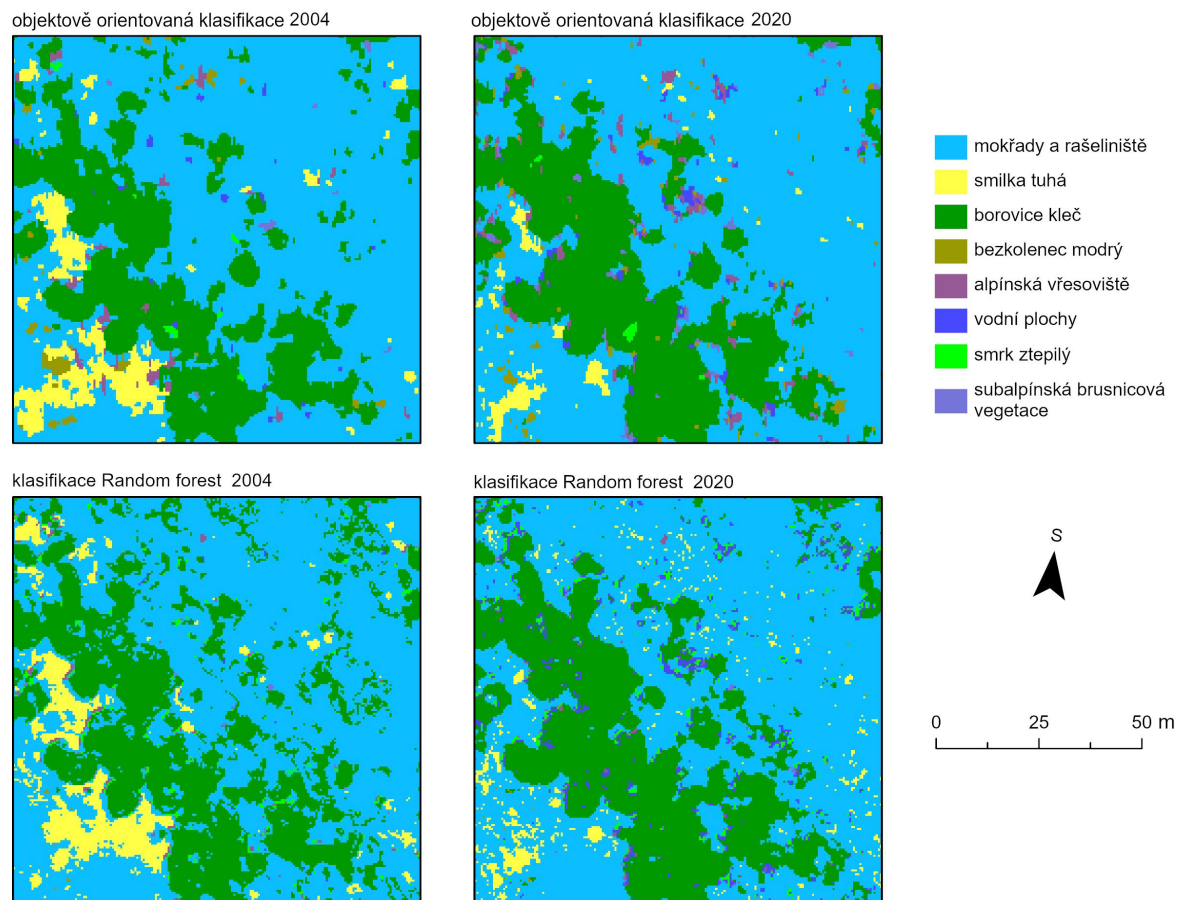
Výsledkům zpracovatelských a uživatelských přesností odpovídá také test separability, který má v jednotlivých letech velmi podobné výsledky. Nejčastějšími třídami, které mezi sebou byly zaměňovány, jsou alpínská vřesoviště s mokřady a rašeliništi, vodními plochami a subalpínskou brusnicovou vegetací. Často se prolínaly

také dvojice bezkolenec modrý se smilkou tuhou a bezkolenec modrý s alpskými vřesovišti. Míra separability těchto párů měla hodnoty kolem 0,5.

Tabulka 10: Úpské rašeliniště – celkové přesnosti klasifikací

klasifikační metoda	celková přesnost 2004 (%)	celková přesnost 2020 (%)
MLC	57,0	59.1
RF	80.1	82.3
OBIA	84.4	85.2

Obrázek 19: Úpské rašeliniště – porovnání klasifikací OBIA a RF pro rok 2004 a 2020



5.1.4. Širší území tundry

Také pro širší území tundry bylo dosaženo nejlepších výsledků v případě objektově orientované klasifikace (viz obr. 21), kdy celkové přesnosti dosáhly 65,4 % v roce 2004 a 73,4 % v roce 2020 (viz tabulka 11). I zde bylo nejprve potřeba provést test nejvhodnějšího nastavení parametrů. Ve výsledku bylo zvoleno následující nastavení – scale level 30, merge level 20. Z pixelových klasifikací nejlépe dopadla metoda Random forest, která pro rok 2004 dosáhla celkové přesnosti 64,9 % a pro rok 2020 70,6 %. V porovnání s výsledky ostatních zájmových území (především Bílé louky a Úpského rašeliniště) jsou hodnoty celkové přesnosti objektové klasifikace nižší přibližně o 10 %.

Zpracovatelské přesnosti objektové klasifikace v roce 2020 v několika případech překročily 90 %, konkrétně jsou to kamenná moře, borovice kleč a stíny. Travní druhy měly následující přesnosti – smilka tuhá PA 74,6 % a UA 53,4 %, třtina chloupkatá PA 69,6 % a UA 60,7 %, metlice trsnatá PA 62,6 % a UA 58,4 % a bezkolenec modrý PA 67,0 %, UA 73,2 %. Mezi třídy s nízkou přesností patří subalpínská brusnicová vegetace (PA 18,1 %, UA 57,3 %) a vyfoukávaný alpínský trávník (PA 20,5 %, UA 57,9 %). Zpracovatelské a uživatelské přesnosti v roce 2004 jsou celkově nižší než v roce 2020, ale do jisté míry hodnoty mezi jednotlivými roky korespondují. Vysokou přesnost mají opět třídy borovice kleč (PA 96,2 %, UA 86,7 %), kamenná moře (PA 83,2 %, UA 66,8 %), stíny (PA 76,6 %, UA 69,0 %) a vodní plochy (PA 72,6 %, UA 93,9 %). Podobně jako v roce 2020 byly v roce 2004 nejproblémovější subalpínská brusnicová vegetace se zpracovatelskou přesností 12,9 % a uživatelskou přesností 12,3 % a alpínský vyfoukávaný trávník s hodnotami PA 9,7 %, UA 34,7 %. Sledované travní druhy dopadly takto – smilka tuhá PA 52,2 % a UA 48,6 %, třtina chloupkatá PA 56,84 % a UA 43,9 %, metlice trsnatá PA 48,8 % a UA 66,4 % a bezkolenec modrý PA 48,8 %, UA 53,0 %.

Pixelové klasifikace metodou Random forest v roce 2004 i 2020 dosáhly vysokých hodnot přesnosti v obvyklých třídách – kamenná moře a borovice kleč. Nízké hodnoty přesnosti v obou sledovaných letech (jako v případě objektové klasifikace) vykazují třídy subalpínská brusnicová vegetace (2004 – PA 1,1 % a UA 8,8 %; 2020 – PA 30,3 % a UA 61,3 %) a vyfoukávaný alpínský trávník (2004 – PA 8,4 % a UA 35,3 %; 2020 – PA 24,1 % a UA 52,1 %), ke kterým se přidala alpínská vřesoviště (2004 – PA 19,2 % a UA 49,7 %; 2020 – PA 32,9 % a UA 55,7 %). Zpracovatelské a uživatelské přesnosti travních

druhů v roce 2004 byly následující – smilka tuhá PA 55,6 % a UA 47,4 %, třtina chloupkatá PA 59,4 % a UA 41,5 %, metlice trsnatá PA 50,2 % a UA 60,8 % a bezkoleneček modrý PA 41,5 %, UA 52,9 %. V roce 2020 byly hodnoty přesnosti sledovaných travních druhů vyšší – smilka tuhá PA 73,9 % a UA 54,6 %, třtina chloupkatá PA 63,8 % a UA 58,5 %, metlice trsnatá PA 65,2 % a UA 54,5 % a bezkoleneček modrý PA 45,6 %, UA 66,8 %.

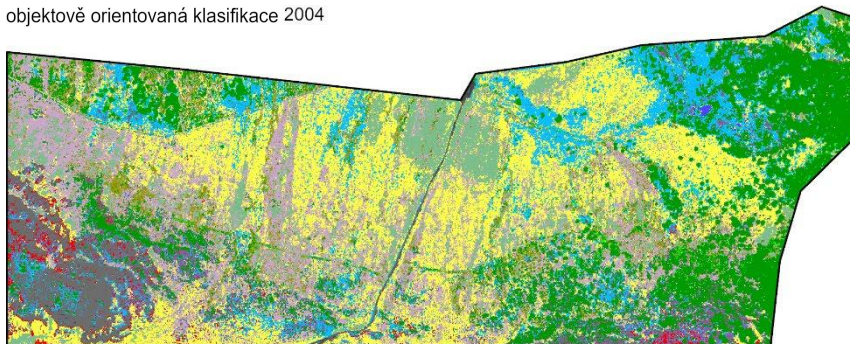
Podle výsledků míry separability v roce 2004 byly nejvíce zaměňovány dvojice tříd vyfoukávaný alpínský trávník a subalpínská brusnicová vegetace, třtina chloupkatá a bezkoleneček modrý, ale také smilka tuhá s třtinou chloupkatou a smilka tuhá s bezkolencem modrým. Míra separability těchto dvojic dosahuje hodnot 0,4–0,5. V roce 2020 jsou míry separability pro travní druhy výrazně vyšší. Problematická je zejména třída subalpínská brusnicová vegetace, která měla podobné spektrální vlastnosti jako metlice trsnatá a smrček ztepilý (míra separability 0,5–0,6). Také vyfoukávaný alpínský trávník měl nízkou míru separability zejména v kombinaci s mokřady a rašeliništi (0,7) a smilkou tuhou (0,7).

Tabulka 11: širší území tundry – celkové přesnosti klasifikací

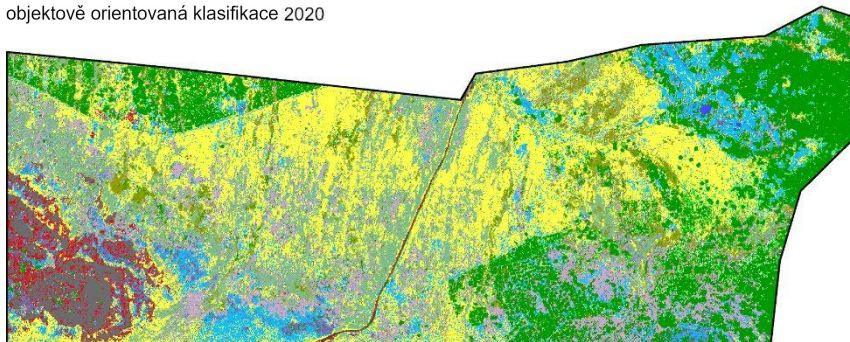
klasifikační metoda	celková přesnost 2004 (%)	celková přesnost 2020 (%)
MLC	58.4	64.8
RF	64.9	70.6
OBIA	65.4	73.4

Obrázek 20: Širší území tundry – porovnání klasifikací OBIA a RF pro rok 2004 a 2020


objektově orientovaná klasifikace 2004



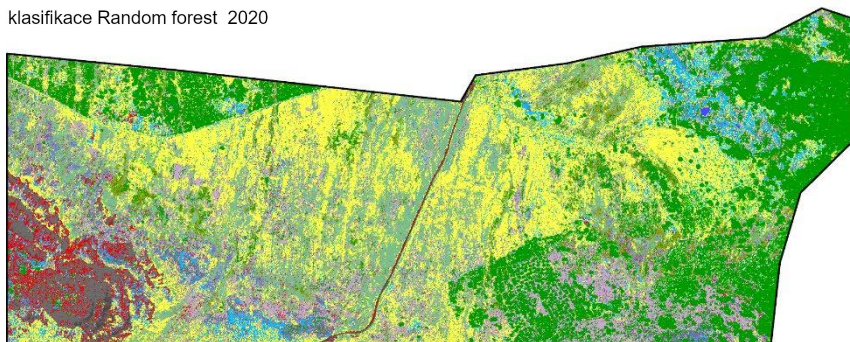
objektově orientovaná klasifikace 2020



klasifikace Random forest 2004



klasifikace Random forest 2020



- borovice kleč
- stíny
- mokřady a rašeliniště
- smilka tuhá
- alpská vřesoviště
- vodní plochy
- metlice trsnatá
- cesta
- bezkolnec modrý
- třtina chloupkatá
- kamenná moře
- smrk ztepilý
- vyfoukávaný alpský trávník
- subalpínská brusnicová vegetace

0 250 500 m



5.2. Analýza vývoje vegetace

5.2.1. Řízené klasifikace

Na základě výsledků klasifikací byla provedena analýza vývoje jednotlivých druhů vegetace. Z výsledků objektově orientované klasifikace a klasifikace Random forest byly vypočítány rozlohy tříd v roce 2004 i 2020. Tabulky 7–10 popisují, o kolik procent se celková rozloha tříd od roku 2004 zvětšila, nebo zmenšila. Je možné pozorovat rozdíly ve změně rozlohy mezi klasifikačními metodami.

Výsledky jsou shodné na Bílé louce a Úpském rašeliništi ve smyslu nárůst/úbytek. Samotné hodnoty už se v případech některých tříd liší (viz tabulka 12 a 13). Největší rozdíly lze zaznamenat u metlice trsnaté a smilky tuhé na Bílé louce, kde jsou hodnoty rozdílné o více než dvojnásobek mezi použitými klasifikačními metodami. Na Úpském rašeliništi je problémový bezkoleneček modrý, u kterého se hodnoty liší přibližně o polovinu rozlohy.

Změny rozlohy byly sledovány také na Luční hoře a širším území tundry (viz tabulky 14 a 15). Přesnost klasifikací právě pro tyto dvě plochy byla nižší a je tedy pravděpodobné, že právě to je důvodem, proč jsou zde výsledky značně rozdílné. Metlice trsnatá byla problémová také zde. Na Luční hoře podle klasifikace Random forest došlo k úbytku o 31,5 % své původní rozlohy, ovšem objektová klasifikace říká, že došlo k nárůstu 171,9 %. Velmi podobně je tomu také na širším území tundry, kde metlice při Random forest přibyla o 52,6 % a při objektové klasifikaci o 247,4 %.

Tabulka 12: Bílá louka – změna rozlohy vybraných vegetačních druhů při použití různých klasifikačních metod mezi lety 2004 a 2020

hodnocený druh	Bílá louka					
	Random forest			objektově orientovaná klasifikace		
	rozloha 2004 (m ²)	rozloha 2020 (m ²)	změna rozlohy (%)	rozloha 2004 (m ²)	rozloha 2020 (m ²)	změna rozlohy (%)
třtina chloupkatá	4197,0	2909,0	-30,7	4095,3	2516,3	-38,6
metlice trsnatá	973,5	1488,5	52,9	1170,5	1324,3	13,1
bezkoleneček modrý	1973,3	2157,8	9,4	1959,5	2077,5	6,0
smilka tuhá	2639,0	3159,8	19,7	2171,3	3360,0	54,7

Tabulka 13: Úpské rašeliniště – změna rozlohy vybraných vegetačních druhů při použití různých klasifikačních metod mezi lety 2004 a 2020

hodnocený druh	Úpské rašeliniště					
	Random forest			objektově orientovaná klasifikace		
	rozloha 2004 (m ²)	rozloha 2020 (m ²)	změna rozlohy (%)	rozloha 2004 (m ²)	rozloha 2020 (m ²)	změna rozlohy (%)
borovice kleč	2999,8	3067,3	2,3	2606,8	2859,3	9,7
bezkolnec modrý	3,3	5,5	69,2	92,0	125,5	36,4
smilka tuhá	693,5	291,5	-58,0	576,0	206,0	-64,2

Tabulka 14: Luční hora – změna rozlohy vybraných vegetačních druhů při použití různých klasifikačních metod mezi lety 2004 a 2020

hodnocený druh	Luční hora					
	Random forest			objektově orientovaná klasifikace		
	rozloha 2004 (m ²)	rozloha 2020 (m ²)	změna rozlohy (%)	rozloha 2004 (m ²)	rozloha 2020 (m ²)	změna rozlohy (%)
metlice trsnatá	94,5	64,8	-31,5	89,8	244,0	171,9
borovice kleč	101,3	169,0	66,9	84,8	154,5	82,3
smilka tuhá	1765,5	1372,5	-22,3	1557,3	1625,8	4,4
vřes obecný	1897,5	2381,5	25,5	1979,0	2347,8	18,6

Tabulka 15: Širší území tundry – změna rozlohy vybraných vegetačních druhů při použití různých klasifikačních metod mezi lety 2004 a 2020


hodnocený druh	širší území tundry					
	Random forest			objektově orientovaná klasifikace		
	rozloha 2004 (m ²)	rozloha 2020 (m ²)	změna rozlohy (%)	rozloha 2004 (m ²)	rozloha 2020 (m ²)	změna rozlohy (%)
třtina chloupkatá	382342,0	198801,5	-48,0	172363,2	146417,9	-15,1
metlice trsnatá	233114,1	355841,2	52,6	85714,2	297756,8	247,4
bezkolnec modrý	77303,3	88084,2	13,9	102983,2	107236,6	4,1
smilka tuhá	514127,2	551938,1	7,4	562400,3	580425,8	3,2
borovice kleč	453681,0	408727,7	-9,9	356111,6	367052,7	3,1

5.2.2. Neřízené klasifikace pro Bílou louku


Pro analýzu vývoje vegetace s použitím neřízené klasifikace pro 5 časových horizontů byla vytvořena tabulka, která udává podíl rozlohy jednotlivých tříd k celé ploše zájmového území. Z tabulkových dat byly vytvořeny 2 grafy. Jeden pro klasifikaci Maximum likelihood a druhý pro neřízenou klasifikaci ISODATA. Během sledovaných let lze pozorovat určité trendy ve vývoji druhů (viz graf 4 a 5).

Výsledky řízené a neřízené klasifikace se shodují v případě metlice trsnaté, která od roku 2010 vykazuje stálý přírůst. Nicméně u řízené klasifikace nárůst začíná na nižších hodnotách a má větší meziroční přírůstky. Vývoj metlice je v obou případech ukončen kolem stejné hodnoty (30 %). Další vzorec chování lze vidět u smilky tuhé. Zatímco při neřízené klasifikaci je patrný sice malý, ale konstantní pokles rozlohy, u řízené klasifikace je pokles rozdělen do dvou fází. První fáze je v letech 2004 až 2010, druhá mezi lety 2012 až 2020. Stejně jako v případě metlice jsou meziroční rozdíly v rozloze smilky větší u řízené klasifikace. V ostatních kategoriích nelze trendy ve vývoji pozorovat. Hodnoty pro třtinu chloupkatou a bezkoleneč modrý jsou napříč všemi lety i metodami klasifikace velmi rozkolísané. Je nutné dodat, že zatímco data z let 2004 a 2020 jsou z konce července, tak data z ostatních let jsou ze začátku července. Termíny mohly do značné míry způsobit rozdíly v klasifikacích. Proto je vhodnější data analyzovat v rámci dvou časových řad – první pro roky 2004 a 2020 a druhá pro zbylé tři roky. V rámci časové řady 2004 – 2020 vykazují srovnatelné tendence v řízené i neřízené klasifikaci druhy smilka (pokles) a bezkoleneč (nárůst). V rámci časové řady 2010–2012–2018 jen druh metlice (nárůst).

Graf 4: Vývoj podílu rozlohy jednotlivých sledovaných druhů na celkové ploše Bílé louky s využitím klasifikátoru MLC mezi lety 2004–2020



Graf 5: Vývoj podílu rozlohy jednotlivých sledovaných druhů na celkové ploše Bílé louky s využitím klasifikátoru ISODATA mezi lety 2004–2020



6. Diskuze

Klasifikací vegetace tundry se v posledních letech zabývá stále více studií, obzvláště s použitím metod dálkového průzkumu Země. S vývojem technologií se zlepšuje kvalita používaných snímků i terénních dat, ovšem i několik novodobých studií dává přednost ortofotu před snímky s velmi vysokým prostorovým i spektrálním rozlišením. Důvodem je především fakt, že ortofota mají dlouhý časový záběr a umožňují tedy pozorovat vývoj vegetace i tak jedinečných ekosystémů, jako je právě arko–alpínská tundra Krkonoš. Příkladem takové studie je práce autorů Potůčková a kol. (2021), kteří studovali vývoj vegetace v dlouhém časovém úseku let 1936–2018. Protože používali převážně archivní ortofota, nebylo možné klasifikovat vegetaci až do úrovně druhů. Aktuálnější ortofoto používali také autoři Suchá a kol. (2015) a Kupková a kol. (2017), kde snímky měly takové parametry (prostorové rozlišení atd.), že bylo možné vegetaci rozlišit až na druhovou úroveň.

Tato práce není prvním pokusem o studium vegetace Bílé louky, Luční hory a Úpského rašeliniště. Projekt *Vegetation of the tundra in the Krkonoše Mts. – past, present and the future* se již čtvrtým rokem zabývá monitoringem právě těchto ploch. V současné době projekt stále probíhá a nejsou známy všechny výsledky. Pro porovnání výsledků této práce je využita výroční zpráva projektu z analýzy dat roku 2021 (Kupková a kol. 2022). Největším rozdílem mezi výzkumy jsou použité vstupní snímky. Namísto

základního ortofota s prostorovým rozlišením 0,5 m a třemi spektrálními pásmy zde autoři využívají vysoce kvalitní multispektrální, hyperspektrální a LiDARová data (prostorové rozlišení 9 cm) získaná pomocí UAV (Unmanned Aerial Vehicle). Určité rozdíly jsou též v klasifikačních legendách. Zejména v případě Úpského rašeliniště byla legenda pro tuto práci zjednodušena. Třída mokřady a rašeliniště zahrnuje 10 samostatných vegetačních tříd, které byly pro účely této práce sdruženy v jednu. Horší prostorové rozlišení ortofota (0,5 m) nedovolilo použít detailnější legendu. Na rozdíl od studie Kupková a kol. (2022), kde nedošlo k tak rozsáhlému sloučení tříd, protože použitý snímek měl prostorové rozlišení 9 cm.

Tabulka 16 shrnuje celkové přesnosti testovaných klasifikačních metod pro každé zájmové území této práce pro rok 2004 i 2020 a srovnává je s výsledky ze studie Kupková a kol. (2022). Výsledky klasifikací pro rok 2004 je nutné vnímat v kontextu toho, že pro řízené klasifikaci byla využita trénovací a validační data z roku 2020, protože starší data nebyla k dispozici. To jistě do značné míry ovlivnilo celkové přesnosti klasifikací i zpracovatelské a uživatelské přesnosti jednotlivých tříd. Botanická data v roce 2020 byla sbírána ve středu větších ploch s výskytem jednotlivých druhů, tedy v místech, kde se dá předpokládat poměrně stabilní a dlouhodobý výskyt dané kategorie. Přesto se nedá ve všech případech předpokládat, že se stejné kategorie vyskytovaly v těchto místech i v roce 2004. V případě prostorového rozlišení dat z roku 2004 (pixel 50 × 50 cm) nebylo ale možné ani upravit trénovací/validační data na podkladu snímku. Jedinou možností proto bylo použít data z roku 2020, případně neřízené klasifikace.

Výsledky hodnocení celkové přesnosti řízených klasifikací jsou v roce 2004 i z těchto důvodů většinou významně horší než výsledky pro rok 2020. Nejvyšších přesností klasifikací dosahovala objektově orientovaná klasifikace jak v roce 2004, tak v roce 2020. Výjimkou byla Luční hora, kde překvapivě nejvyšší přesnosti dosáhla klasifikace Maximum likelihood v obou sledovaných letech.

Tabulka 16: Porovnání celkových přesností této práce se studií Kupková a kol. (2022)

klasifikační metoda	zájmové území	celková přesnost 2004 (%)	celková přesnost 2020 (%)	*celková přesnost v Kupková et al. 2022 (%)
MLC	širší území tundry	58.42	64.81	–
	Bílá louka	63.41	78.39	92,19/90,19
	Luční hora	57.70	73.84	85,94/88,15
	Úpské rašeliniště	56.92	59.14	82,88/80,58
RF	širší území tundry	64.90	70.61	–
	Bílá louka	62.70	80.39	85,76/90,89
	Luční hora	57.98	70.47	82,94/88,12
	Úpské rašeliniště	80.12	82.27	78,13/83,96
OBIA	širší území tundry	65.35	73.40	–
	Bílá louka	68.28	82.53	83,44/92,25
	Luční hora	54.17	68.97	83,94/88,95
	Úpské rašeliniště	84.38	85.24	70,56/87,77

*první číslo – multispektrální data, druhé číslo – hyperspektrální data

Pro Bílou louku bylo dosaženo nejvyšší celkové přesnosti při použití objektové klasifikace (2004 – 62,7 %, 2020 – 82,5 %). Hodnotu celkové přesnosti zde mohla snižovat třída vyfoukávaný alpínský trávník. Zpracovatelská a uživatelská přesnost pro tuto třídu byla výrazně nižší, než u ostatních tříd. Této skutečnosti napovídá také test separability, jehož výsledky pro tuto třídu nebyly dobré (míra separability cca 0,5). Řešením v tomto případě nemůže být dosbírání polygonů v terénu, protože tato třída se vyskytuje sporadicky, a navíc se mísí s dalšími druhy. Autoři výzkumné zprávy tuto třídu při klasifikaci odstranili z důvodu malého počtu vyklasifikovaných pixelů a dosáhli celkové přesnosti 92,3 % při kombinaci hyperspektrálních (HS) dat a OBIA a 83,4 % pro multitemporální multispektrální data. I v této práci byla tato kategorie vypuštěna v případě testování neřízených klasifikací (viz níže). Důležitým výsledkem této práce je, že pro ortofoto z roku 2020 bylo dosaženo s využitím OBIA zcela srovnatelné celkové přesnosti klasifikace (82, 53 %) s multispektrálními daty z Kupková a kol. (2022) a velice dobrého srovnatelného výsledku celkové přesnosti klasifikace bylo dosaženo i metodou RF.

Porovnání zpracovatelských a uživatelských přesností pro všechny klasifikované třídy shrnuje tabulka 17. Největší rozdíl mezi studii byl zaznamenán v případě třídy metlice trsnatá. Třída s nejhoršími výsledky je jednoznačně vyfoukávaný alpínský trávník, který je problémový napříč celou prací.

Tabulka 17: Bílá louka – porovnání zpracovatelských a uživatelských přesností této práce se studií Kupková a kol. (2022)

hodnocený druh	OBIA 2004		OBIA 2020		OBIA nebo MLC*	
	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)
bezkoleneč modrý	88,2	83,2	85,8	94,4	97,3	98,3
metlice trsnatá	53,0	63,5	73,9	80,9	95,1	89,3
smilka tuhá	81,0	58,5	71,4	68,3	82,7	86,9
třtina chloupkatá	79,8	63,2	92,7	87,8	99,2	98,2
vyfoukávaný alpínský trávník	1,6	6,1	20,4	25,1	-	-

*celkové přesnosti při použití multispektrálních dat

Nejvyšší celkové přesnosti ze všech malých ploch bylo v této práci dosaženo na území Úpského rašeliniště s použitím OBIA (2004 – 84,4 %, 2020 – 85,2 %) i přes to, že z malých ploch má právě toto území nejobsáhlejší klasifikační legendu (ta ale byla oproti studii Kupková a kol. (2022) v této práci zjednodušena, jak bylo uvedeno výše). Důvodem je nejspíš charakter klasifikovaných tříd. Na Úpském rašeliništi se vyskytují druhy, které se obecně dobře klasifikují, jako je například borovice kleč, která zde zabírá rozsáhlou část území (viz tabulka 16). Dobrou separabilitu zde mají také smrk ztepilý a smilka tuhá. Typicky zde pak byly zaměňovány mokřady a rašeliniště za vodní plochy. Podobně jako v případě Bílé louky s vyfoukávaným alpínským trávíkem je zde problém s bezkolencem modrým. Jeho rozloha je malá, a tudíž bylo těžké tuto třídu natrénovat. Míra separability je v případě této kategorie velmi malá, a tak často mohlo docházet k záměnám s mokřady a rašeliništi, vřesem obecným a smilkou tuhou. Zbylé potenciální problémové třídy byly ve velké míře sloučeny do třídy mokřady a rašeliniště. Výroční zpráva uvádí, že nejvyšší celkové přesnosti autoři dosáhli opět klasifikací HS dat pomocí OBIA, kdy hodnota dosáhla 87,8 %. Výsledná přesnost je ve srovnání s klasifikací ortofota z roku 2020 vyšší pouze o 2,6 procentního bodu a dokonce převyšuje přesnost získanou v Kupková a kol. (2022) pro multispektrální data. To může být do značné míry dáno i sloučením problémových kategorií legendy. Přehled zpracovatelských a uživatelských přesností je v tabulce 18, která potvrzuje, že vysoké prostorové a spektrální rozlišení přináší lepší výsledky.

Tabulka 18: Úpské rašeliniště – porovnání zpracovatelských a uživatelských přesností této práce se studií Kupková a kol. (2022)

hodnocený druh	OBIA 2004		OBIA 2020		OBIA nebo MLC*	
	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)
alpínská vřesoviště	12,7	40,9	7,0	16,1	58,0	52,0
bezkoleneček modrý	18,8	16,3	29,0	34,5	86,0	97,6
borovice kleč	93,8	93,7	96,1	96,0	99,5	99,0
mokřady a rašeliniště	88,5	82,4	95,5	80,4	-	-
smilka tuhá	68,9	68,4	25,5	67,6	94,5	87,1
smrk ztepilý	43,5	100,0	52,2	80,0	94,0	100,0
subalpínská brusnicová vegetace	16,7	100,0	11,9	45,5	-	-
vodní plochy	5,8	31,3	32,6	68,3	92,0	100,0

*celkové přesnosti při použití multispektrálních dat

Luční hora se od ostatních území velmi odlišuje. Jedná se o jedinou plochu, kde bylo dosaženo nejvyšší celkové přesnosti klasifikací MLC (2004 – 57,7 %, 2020 – 73,8 %). Na základě výsledků testu separability byly očekávány vyšší celkové přesnosti. Nižší hodnoty míry separability vykazuje v roce 2020 pouze dvojice metlice trsnatá a smilka tuhá (0,7) a metlice trsnatá a subalpínská brusnicová vegetace (0,8). Což je ovšem nežádoucí, protože v každé dvojici se vyskytuje alespoň jeden travní druh, kterým se tato práce primárně zabývá. Ve výroční zprávě se autoři také věnují území Luční hory, Celková přesnost dosáhla 89,0 % při použití HS dat a OBIA a 82 – 85 % pro MS data a různé klasifikátory. Zatímco ve výzkumné zprávě mají všechny třídy zpracovatelskou i uživatelskou přesnost nad hranicí 90 %, průměr přesností v této práci se pohybuje kolem hodnoty 50 % v roce 2004 a 70 % v roce 2020 (viz tabulka 19).

Tabulka 19: Luční hora – porovnání zpracovatelských a uživatelských přesností této práce se studií Kupková a kol. (2022)

hodnocený druh	MLC 2004		MLC 2020		OBIA nebo MLC*	
	PA (%)	UA (%)	PA (%)	UA (%)	PA (%)	UA (%)
alpínská vřesoviště	55,1	66,1	71,3	79,4	91,8	97,1
borovice kleč	39,3	21,9	84,8	64,1	99	100,0
kamenná moře	88,7	84,7	96,6	89,1	99,5	96,4
metlice trsnatá	75,7	35,6	78,6	54,2	91,9	87,2
smilka tuhá	38,8	51,5	53,2	63,3	95,8	97,6
subalpínská brusnicová vegetace	46,6	43,1	76,5	80,9	92,4	100
vyfoukávaný alpínský trávník	38,5	37,1	57,1	52,6	-	-

*celkové přesnosti při použití multispektrálních dat

Klasifikace širšího území tundry přinesly horší výsledky než malé plochy. Ovšem klasifikační legenda obsahuje 14 tříd a hustota trénovacích dat v rámci širšího území je mnohem menší než v případě malých ploch, takže tento výsledek se dal předpokládat. Nejvyšší celkovou přesnost opět přinesla OBIA (2004 – 63,4 %, 2020 – 85,2 %). V roce 2004 měly podle testu separability nízké hodnoty třídy vyfoukávaný alpínský trávník, subalpínská brusnicová vegetace, bezkolenec modrý, smilka tuhá a třtina chloupkatá. Pro data z roku 2020 to opět byly třídy vyfoukávaný alpínský trávník a subalpínská brusnicová vegetace, ke kterým se tentokrát přidala třída mokřady a rašeliniště.

Podrobněji se tato práce zabývala územím Bílé louky. Lokalita je pro tento výzkum zcela jedinečná v tom, že obsahuje přesně ty travní druhy, které jsou v této studii hlavním předmětem pozorování. Jmenovitě jsou to bezkolenec modrý, metlice trsnatá, smilka tuhá a třtina chloupkatá. Společně s těmito travními druhy byl na Bílé louce v první fázi práce klasifikován také vyfoukávaný alpínský trávník (jak je uvedeno výše). Vedle klasifikací, jejichž výsledky jsou popsány výše, byla provedena také analýza, která hodnotila změny rozlohy vybraných vegetačních druhů mezi lety 2004 a 2020. Výsledky ovšem nedosáhly potřebné přesnosti (zejména v roce 2004) a nedokázaly potvrdit předpoklad botaniků KRNAP, že na úkor smilky tuhé přibývají expanzivní druhy třtina chloupkatá, bezkolenec modrý a metlice trsnatá (Hejcman a kol. 2007; Hajcman, Češková, Pavlů 2010).

Pro hlubší prozkoumání vztahů mezi travními druhy byly na Bílé louce provedeny další klasifikace. Byla přidána druhá časová řada ortofot, která doplňovala časový úsek mezi roky 2004 a 2020. Tato časová řada obsahovala snímky z let 2010, 2012 a 2018, které byly pořízeny na začátku července (na rozdíl od snímků z let 2004 a 2020, které byly pořízeny na konci července). Protože nebyla k dispozici trénovací (a validační data) pro archivní ortofota, byla dále testována také neřízená klasifikace, která byla následně porovnána s řízenou klasifikací zastoupenou klasifikátorem Maximum likelihood. Cílem tohoto pokusu bylo odhalit případné trendy ve vývoji čtyř zmíněných travních druhů a také porovnat rozdíly mezi výstupy řízené a neřízené klasifikace. Dále také porovnat výsledky z obou časových řad pořízených v rozdílném období (začátek července vs. konec července) a zjistit tak, zda je vhodné/možné tato data kombinovat. Pro účely neřízené klasifikace byla z klasifikační legendy odstraněna třída vyfoukávaný alpínský trávník. Tento krok byl proveden kvůli malé celkové rozloze třídy a také výsledkům analýzy separability, která v případě vyfoukávaného alpínského trávníku nevycházela

dobře a často tak byla třída při klasifikaci zaměňována s jinými. Výsledky obou typů klasifikací byly poměrně rozdílné (jak obrazové výstupy, tak rozlohy jednotlivých kategorií). Protože se liší i výsledky řízené a neřízené klasifikace v roce 2020, nelze ani na základě srovnání těchto klasifikací potvrdit, že by neřízená klasifikace byla spolehlivá. Test ale potvrdil předpoklad, že není dobré pro hodnocení vývoje vegetace používat data z rozdílných termínů (začátek července vs. konec července). Pro roky 2018 a 2020 byly totiž pro řízené klasifikace použity snímky právě z rozdílných termínů a výsledné klasifikace se dosti lišily, přestože v rozmezí dvou let nedošlo v tomto území k zásadním změnám v rozšíření sledovaných druhů vegetace.

Výsledky klasifikací mohly být ovlivněny několika faktory. Jedním z nich jsou zajisté vstupní data, a to jak použité snímky, tak i terénní data, která byly použita pro natrénování modelů a následnou validaci klasifikací. Protože tato práce zkoumá vývoj vegetace v poměrně dlouhém časovém úseku (rok 2004 až 2020), volba typu snímku byla téměř jednoznačná. Archivní ortofota byla v podstatě jedinou možnou volbou. Jsou jednoduše dostupná a nabízí nejlepší dosažitelné prostorové rozlišení. K použití se také nabízela například družicová data Sentinel-2, ale jejich prostorové rozlišení není pro tuto úlohu vhodné. Jednou z hlavních výzkumných otázek této studie bylo, zda jsou parametry nejstaršího barevného dostupného archivního ortofota dostačující pro účely této práce. Jinými slovy, zda i přes relativně malé prostorové rozlišení 0,5 m/pixel a nízké spektrální rozlišení (pouze 3 pásma - červené, zelené a modré) je možné dosáhnout spolehlivých výsledků klasifikace (zejména pro 4 ochranně důležité traviny) až do úrovně druhů. Výsledky ukázaly, že v porovnání s daty, která jsou dostupná v současné době (prostorové rozlišení menší než 10 cm), jsou přesnosti klasifikace ortofota s uvedenými parametry znatelně horší (například v porovnání s výroční zprávou 2021 projektu *Vegetation of the tundra in the Krkonoše Mts. – past, present and future*). To, že vysoké prostorové rozlišení je zásadní pro přesnost klasifikace, prokázali již v roce 2015 Suchá a kol. (2015) a toto zjištění potvrzuje i tato práce.

Dalším faktorem, který mohl ovlivnit výsledky práce, je souhra klimatických podmínek v průběhu let, termínů pořizování snímků a fenologie vegetace. Všechny zmíněné faktory spolu souvisí a navzájem se ovlivňují. Fenologie vegetace hraje ve výsledné klasifikaci důležitou roli. V různých životních fázích může mít vegetace odlišné spektrální vlastnosti. Snahou tedy je, aby snímky jednotlivých časových řad pocházely ze

stejně fenologické fáze, případně aby byla použita data multitemporální. Na vývoj vegetace mají jednoznačně vliv klimatické podmínky během roku, speciálně v jarních měsících. Proto se práce zabývala také analýzou klimatických podmínek v letech 2004 a 2020, které tvořily základní časovou řadu pro klasifikaci všech malých ploch i širšího území. Bylo tedy nutné prověřit, zda i přesto, že oba snímky časové řady pochází ze stejného časového období (31. července), zachycují také stejnou fenologickou fázi vývoje vegetace. Zahájení vegetační sezóny je podmíněno teplotou vzduchu, úhrnem srážek a délkou trvání sněhové pokrývky. Pod sněhovou pokrývkou se vegetace nemůže rozvíjet a s jejím trváním se tak začátek vegetační sezóny oddaluje. V letech 2004 a 2020 byl klíčový měsíc květen, v obou letech byl ústup sněhové pokrývky téměř srovnatelný. Vývoj průměrných měsíčních teplot byl také velmi podobný, a to po celý rok. Průměrné měsíční úhrny srážek mírně nahrávaly rychlejšímu rozvoji vegetace na počátku sezóny v roce 2020. Následující průběh srážek ovšem napomáhal k vyrovnání vývojového stavu vegetace mezi jednotlivými lety (2004 a 2020) během června a července. Zvolené termíny snímků tedy byly vhodné pro vytvoření časové řady, pomocí které byla provedena analýza vývoje vegetace.

7. Závěr

Cílem práce bylo provést analýzu vývoje vegetace krkonošské tundry s využitím dat a metod dálkového průzkumu Země a zjistit, zda nedochází ke změnám v rozloze vybraných travních druhů, které by bylo možné doložit na základě srovnání archivních a současného ortofota. Tato domněnka stojí na předpokladu botaniků KRNAP, podle kterých byla stanovena základní hypotéza této práce. Ta říká, že druhy bezkoleneček modrý, metlice trsnatá a třtina chloupkatá se rozšiřují na úkor ekologicky vhodnějšího druhu, kterým je smilka tuhá. Tato práce nedokázala hypotézu jednoznačně potvrdit ani vyvrátit. Výsledky studie ale mírně tuto hypotézu podporují.

Aby bylo dosaženo co možná nepřesnějších výsledků, byly testovány různé klasifikační metody. Porovnávány byly jak pixelové přístupy ke klasifikaci, tak klasifikace objektová. Zvoleny byly klasifikátory maximum likelihood, Random forest a objektově orientovaná klasifikace s využitím klasifikátoru Support Vector Machine. Nejlepších výsledků bylo dosaženo s použitím objektové klasifikace, kdy v případě Bílé louky a Úpského rašeliniště dosáhly celkové přesnosti hodnot přes 80 % v obou sledovaných letech. Širší území tundry mělo rozsáhlejší klasifikační legendu, ale i tak

bylo dosaženo celkové přesnosti vyšší než 70 % při objektivě orientované klasifikaci v roce 2020. Území Luční boudy jako jediné dosáhlo nejlepších výsledků v kombinaci s pixelovou klasifikací Maximum likelihood.

Aby bylo možné vyhodnotit co nejdelší časový úsek, byla jako vstupní data zvolena barevná ortofota, která jsou dostupná už od roku 2004 a zároveň nabídla nejlepší dosažitelné prostorové rozlišení (v řádu desítek centimetrů). Snímky zahrnovaly 3 spektrální pásma (červené, zelené a modré) a prostorové rozlišení bylo 0,5 m. Jednou z výzkumných otázek bylo, zda i přes horší spektrální a prostorové rozlišení ortofot je možné dosáhnout dobré přesnosti klasifikace (minimálně 70 %). Práce prokázala, že současná ortofota (rok 2020) jsou pro analýzu vegetace vhodná a lze je použít pro klasifikaci vegetace až do druhové úrovně s velmi dobrou přesností (přestože byla převzorkována na velikost pixelu 50 cm). Ortofota z roku 2004 nedosahovala pro mnoho kategorií žádaných přesností a srovnání obou let proto nelze považovat za spolehlivé (to prokázaly zejména neshody v rozlohách jednotlivých kategorií, které byly vyklasifikovány rozdílnými klasifikátory). Hlavní příčinu spatřujeme v nedostupnosti terénních trénovacích a validačních dat pro rok 2004.

Terénní data použitá pro natrénování modelů a následnou validaci byla dle předpokladu zásadním faktorem ovlivňujícím výslednou přesnost klasifikací. K dispozici jsme měli velmi rozsáhlý a přesný soubor dat, který byl nasbírán spolupracovníky z Botanického ústavu AV ČR v Průhonicích v průběhu let 2019 a 2020. Jak bylo uvedeno, mezi hlavní úskalí této práce jednoznačně patří to, že nebyla dostupná terénní data, která by mohla být použita pro trénování a validaci snímku z roku 2004. Proto byla testována také neřízená klasifikace. Neřízená klasifikace metodou ISODATA byla porovnána s řízenou klasifikací Maximum likelihood a proběhla pouze na území Bílé louky, kde jsou hojně zastoupeny výše zmíněné travní druhy, které jsou předmětem zájmu této práce. Pro hlubší analýzu vztahů mezi zmíněnými travními druhy byla přidána druhá časová řada ortofot, která obsahovala snímky z let 2010, 2012 a 2018 s prostorovým rozlišením 0,25 cm. Z tohoto testu ovšem nebylo možné vyvodit přesné závěry. Hlavním důvodem je, že nelze zhodnotit přesnost neřízených klasifikací, ale také zjištění, že výstupy řízené a neřízené klasifikace se i v roce 2020 poměrně odlišují. Na základě těchto výsledků tedy nelze potvrdit, že by neřízená klasifikace byla spolehlivá.

Práce ale jednoznačně potvrdila, že není vhodné porovnávat výsledky klasifikací, které byly provedeny na snímcích z různých termínů. Zatímco snímky z roku 2004 a 2020 pochází z konce července, snímky z let 2010, 2012 a 2018 byly pořízeny na začátku července. Rozdíl jednoho měsíce v této práci značně ovlivňuje výsledek klasifikace. Při výběru snímků časové řady je nutné brát v potaz také klimatické podmínky v daném roce, které mohou oddálit, nebo urychlit nástup vegetační sezóny. Proto se tato práce zabývala analýzou klimatických podmínek během let 2004 a 2020, podle jejíž výsledků byla vegetace v době pořízení snímků ve stejné fenologické fázi a snímky tak mohly být použity do časové řady.

Do budoucna by bylo dobré podrobněji otestovat časové řady ortofot s lepším prostorovým rozlišením (alespoň 20 cm) ze stejných termínů, případně ještě více generalizovat legendu. Výsledky by nebyly k dispozici pro tak dlouhé časové období a v úrovni druhů, ale přinesly by pravděpodobně přesnější přehledové informace o vývoji vegetace v krkonošské reliktní tundře.

8. Zdroje:

BLATSCHKE, T. (2010): Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 1, 2–16.

BREIMAN, L. (2001): Random Forests. *Machine Learning*, 45, 5–32.

CAMPBELL, B., J., WYNNE, H., R. (2011): *Introduction to Remote Sensing: Fifth Edition*. New York, Guilford Press, 662.

CCRS (2022): Fundamentals of Remote Sensing, <https://www.nrcan.gc.ca/maps-tools-and-publications/satellite-imagery-and-air-photos/tutorial-fundamentals-remote-sensing/introduction/9363> (12. 4. 2022)

DAVÍŠEK, J., CULEK, M. (2013): *Biogeografie*. Masarykova univerzita, Brno.

DOBROVOLNÝ, P. (1998): *Dálkový průzkum Země: Digitální zpracování obrazu*. Brno. Masarykova Univerzita, 210.

DVOŘÁK J., ŠTURSA, J. (2009): *Atlas krkonošských rostlin*. Karmalášek, 328.

FAWAGREH, R., GABER, M., M., ELYAN, E. (2014): Random forests: from early developments to recent advancements. *Systems Science & Control Engineering: An Open Access Journal*, 2, 8.

GAO, T., ZHU, J., ZHENG, X., SHANG, G., HUANG, L., WU, S. (2015): Mapping spatial distribution of larch plantations from multi-seasonal landsat-8 OLI imagery and multi-scale textures using random forests. *Remote Sensing* 7, 1702–1720.

GEOPORTÁL ČÚZK (2022): Ortofoto České republiky – úvod, [https://geoportal.cuzk.cz/\(S\(r11o1ckfbuvo42kmgug25hcv\)\)/Default.aspx?mode=TextMeta&text=ortofoto_info&side=ortofoto&menu=23](https://geoportal.cuzk.cz/(S(r11o1ckfbuvo42kmgug25hcv))/Default.aspx?mode=TextMeta&text=ortofoto_info&side=ortofoto&menu=23) (11. 7. 2022)

GRULICH, V. (2011): *Calamagrostis villosa*, Biogeografické regiony, <https://botany.cz/cs/calamagrostis-villosa/> (28. 6. 2022).

HEJCMAN, M., KLAUDISOVÁ, M., HEJCMANOVÁ, P., PAVLŮ, V., JONES, M. (2009): Expansion of *Calamagrostis Villosa* in Sub-Alpine *Nardus Stricta* Grassland: Cessation of Cutting Management or High Nitrogen Deposition? *Agriculture, Ecosystems & Environment* 129, 1–3, 91–96.

HEJCMAN, M., ČEŠKOVÁ, M., PAVLŮ, V. (2010): Control of *Molinia Caerulea* by Cutting Management on Sub-Alpine Grassland. *Flora - Morphology, Distribution, Functional Ecology of Plants* 205, 9, 577–82.

HAGNER, O., REESE, H. (2007): A method for calibrated maximum likelihood classification of forest types. *Remote Sensing of Environment*. 110, 438–444, 7.

HALOUNOVÁ, L., PAVELKA, K. (2008): Dálkový průzkum Země. Praha, České vysoké učení technické, 192.

HARRIS GEOSPATIAL SOLUTIONS (2022): Maximum likelihood, <https://www.l3harrisgeospatial.com/docs/maximumlikelihood.html> (3. 7. 2022).

HÁJEK, M. a RYBNÍČEK, K. (2001): Vrchoviště. In: Katalog biotopů České republiky. Agentura ochrany přírody a krajiny ČR, Praha, 71–76.

KOČÍ, M. (2010a): Subalpínská vysokobylinná vegetace. In: Katalog biotopů České republiky. Ed. 2, Agentura ochrany přírody a krajiny ČR, Praha, 158–159.

KOČÍ, M. (2010d): Vyfoukávané alpínské trávníky. In: Katalog biotopů České republiky. Ed. 2, Agentura ochrany přírody a krajiny ČR, Praha, 134–135.

KOCIÁNOVÁ, M., ŠTURSA, J., VANĚK, J. (2015): Krkonošská tundra, Správa Krkonošského národního parku, https://www.krnep.cz/data/File/letaky_brozury/krkonoska_tundra_web.pdf (4. 7. 2022).

KOLÁŘ, J. (1990): Dálkový průzkum Země. Praha, SNTL – Nakladatelství technické literatury, 170.

KOLÁŘ, J., HALOUNOVÁ, L., PAVELKA, K. (2000): Dálkový průzkum Země. Skripta. ČVUT.

KRAHULEC, F., KOČÍ, M. (2010a): Subalpínská brusnicová vegetace. In: Katalog biotopů České republiky. Ed. 2, Agentura ochrany přírody a krajiny ČR, Praha, 141–142.

KRAHULEC, F., KOČÍ, M. (2010b): Alpínská vřesoviště. In: Katalog biotopů České republiky. Ed. 2, Agentura ochrany přírody a krajiny ČR, Praha, 139.

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, 2, 177–183.

KRNAP (200?): Krkonošská arkto-alpínská tundra, <http://www.krnep.cz/krkonoska-arkto-alpinska-tundra/> (9. 7. 2022)

KUBÁT, K., HROUDA, L., CHRTEK, J. JUN., KAPLAN, Z., KIRSCHNER, J., ŠTĚPÁNEK, J. (2002): Klíč ke květeně České republiky. Acedemia, Praha.

KUPKOVÁ, L.; ČERVENÁ, L.; SUCHÁ, R.; JAKEŠOVÁ, L.; ZAGAJEWSKI, B.; BŘEZINA, S.; ALBRECHTOVÁ, J. (2017): Classification of Tundra Vegetation in the Krkonoše Mts. National Park Using APEX, AISA Dual and Sentinel-2A Data. European Journal of Remote Sensing, 50, 29-46.

KUPKOVÁ, L., ČERVENÁ, L., POTŮČKOVÁ M., LYSÁK, J., ŠAŠKOVÁ, M., ŠROLLERŮ, A., KLINEROVÁ, T., BOBEK, P., MÜLLEROVÁ, J. (2022): Annual Report 2021, Vegetation of the tundra in the Krkonoše Mts. – past, present and future.

LANGFORD, Z., KUMAR, J., HOFFMAN, F. M., NORBY, R. J., WULLSCHLEGER, S. D., SLOAN, V. L., IVERSEN, C. M. (2016): Mapping Arctic Plant Functional Type Distributions in the Barrow Environmental Observatory Using WorldView-2 and LiDAR Datasets. *Remote Sensing*, 8, 9, 733.

LILLESAND, T.; KIEFER, R.; CHIPMAN, J. (2015): *Remote Sensing and Image Interpretation*. Wiley, USA.

LIU, H., ZHANG, F., ZHANG, L., LIN, Y., WANG, S., XIE, Y. (2020): UNVI-based time series for vegetation discrimination using separability analysis and random forest classification. *Remote Sensing*, 12, 3.

MARCINKOWSKA-OCHTYRA, A., ZAGAJEWSKI, B., RACZKO, E., OCHTYRA, A., JAROCINSKA, A. (2018): Classification of High-Mountain Vegetation Communities within a Diverse Giant Mountains Ecosystem Using Airborne APEX Hyperspectral Imagery. *Remote Sensing*, 10, 4, 570.

MENEGUZZO, D. M., LIKNES, G. C., NELSON, M. D. (2013): Mapping trees outside forests using high- resolution aerial imagery: A comparison of pixel- and object-based classification approaches. *Environmental Monitoring and Assessment*, 185, 8, 6261–6275.

MRÁZEK, T. (2012): *Deschampsia cespitosa* – metlice trsnatá, <https://botany.cz/cs/deschampsia-cespitosa/> (2. 6. 2022)

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, 2, 259–272.

PERENNICULUM (2022): *Molinia caerulea*. <https://www.perenniculum.cz/pereny/molinia-caerulea-kultivary/> (30. 6. 2022).

RANDUŠKA, D., Šomšák, L., Háberová, J. (1983): *Barevný atlas rostlin*. Profil, Ostrava, 640.

RODRIGUEZ-GALIANO, V. F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M., RIGOL-SANCHEZ, J.P. (2012): An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 1, 93–104.

SOUKUPOVÁ, L., KOCIÁNOVÁ, M., JENÍK, J., SEKYRA, J. (1995): Arctic-alpine tundra in the Krkonoše, the Sudetes. *Opera corcontica*, 32, 5–88.

STURSA, J., WILD, J. (2014): Kleč a smilka – klíčové hráči vývoje alpínského bezlesí Krkonoš (Vysoké Sudety, Česká republika). *Opera Corcontica*, 51, 12–14.

SUCHÁ, R.; JAKEŠOVÁ, L.; KUPKOVÁ, L.; ČERVENÁ, L. (2016): Classification of vegetation above the tree line in the Krkonoše Mts. National Park using remote sensing multispectral data. *AUC Geographica*, 51, 1, 113–129.

ŠTURSA, J. (2013): Arktoalpínská tundra Krkonoš. *Živa*, 4, 171–174.

THOMAS, I. L., CHING, N. P., BENNING, V. M., D'AGUANNO, J. A. (1987): A review of multi-channel indices of class separability. *International Journal of Remote Sensing*, 8, 331–350.

ULLMANN T., SCHMITT A., ROTH A., DUFFE J., DECH S., HUBBERTEN H–W., BAUMHAUER R. (2014): Land Cover Characterization and Classification of Arctic Tundra Environments by Means of Polarized Synthetic Aperture X- and C-Band Radar (PolSAR) and Landsat 8 Multispectral Imagery — Richards Island, Canada. *Remote Sensing*, 6, 9, 8565-8593.

ÚRADNÍČEK, L., MADĚRA, P., KOLIBÁČOVÁ, S., KOBLÍŽEK, J., ŠEFL, J. (2001): Dřeviny České republiky. *Matice lesnická, Písek*. 334.

VACEK, S., SIMON, J., MINX, T., PODRÁZSKÝ, V., BALCAR, Z. (2007): Struktura a vývoj lesních ekosystémů v Krkonoších. *Opera Corcontica*, 44, 415–424.

WHITTOW, J. (1984): *Dictionary of physical geography*, England, 608.

ZAGAJEWSKI, B., KOZŁOWSKA, A., KRÓWCZYŃSKA, M., SOBCZAK, M., ZWIJACZ-KOZICA, M. (2005): Mapping high mountain vegetation using hyperspectral data. *EARSel eProceedings* 4, 70–78.

ZHOU, W., TROY, A., GROVE, M. (2008): A Comparison of Object-Based with Pixel-Based Land Cover Change Detection in the Baltimore Metropolitan Area using Multitemporal High Resolution Remote Sensing Data. *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*, 2008

Seznam příloh

Příloha 1: Bílá louka – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím objektově orientované klasifikace mezi lety 2004 a 2020

Příloha 2: Bílá louka – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím klasifikace Random forest mezi lety 2004 a 2020

Příloha 3: Luční hora – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím objektově orientované klasifikace mezi lety 2004 a 2020

Příloha 4: Luční hora – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím klasifikace Random forest mezi lety 2004 a 2020

Příloha 5: Úpské rašeliniště – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím objektově orientované klasifikace mezi lety 2004 a 2020

Příloha 6: Úpské rašeliniště – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím klasifikace Random forest mezi lety 2004 a 2020

Příloha 7: širší území tundry – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím objektově orientované klasifikace mezi lety 2004 a 2020





Příloha 8: širší území tundry – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím klasifikace Random forest mezi lety 2004 a 2020

Příloha 9: Obsah přiloženého CD


MAPA VÝVOJE VYBRANÝCH KATEGORIÍ VEGETAČNÍHO POKRYVU

na území Bílé louky
mezi lety 2004 a 2020


objektově orientovaná klasifikace

-  hranice území Bílé louky
-  výskyt druhu v roce 2004
-  výskyt druhu v roce 2020
-  výskyt druhu v obou sledovaných letech


Deschampsia cespitosa



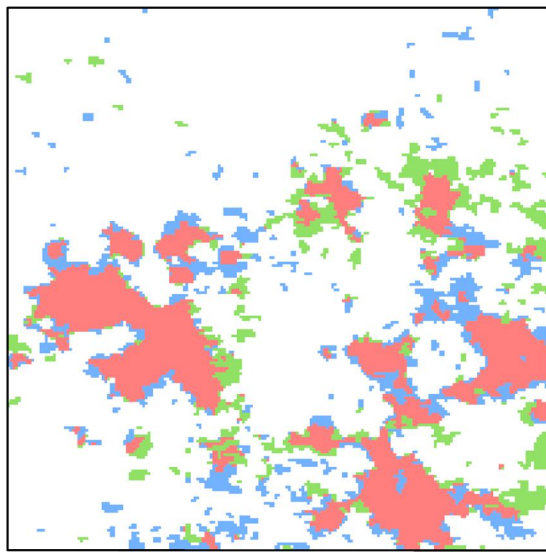
Nardus stricta



Calamagrostis villosa



Molinia caerulea




Petra PAJMOVÁ
Příbram 2022

MAPA VÝVOJE VYBRANÝCH KATEGORIÍ VEGETAČNÍHO POKRYVU


na území Bílé louky
mezi lety 2004 a 2020
klasifikace Random forest

- hranice území Bílé louky
- výskyt druhu v roce 2004
- výskyt druhu v roce 2020
- výskyt druhu v obou sledovaných letech


Deschampsia cespitosa




Nardus stricta



Calamagrostis villosa



Molinia caerulea



MAPA VÝVOJE VYBRANÝCH KATEGORIÍ VEGETAČNÍHO POKRYVU


na území Luční hory
mezi lety 2004 a 2020
objektově orientovaná klasifikace

- hranice území Luční hory
- výskyt druhu v roce 2004
- výskyt druhu v roce 2020
- výskyt druhu v obou sledovaných letech


S

0 25 50 m

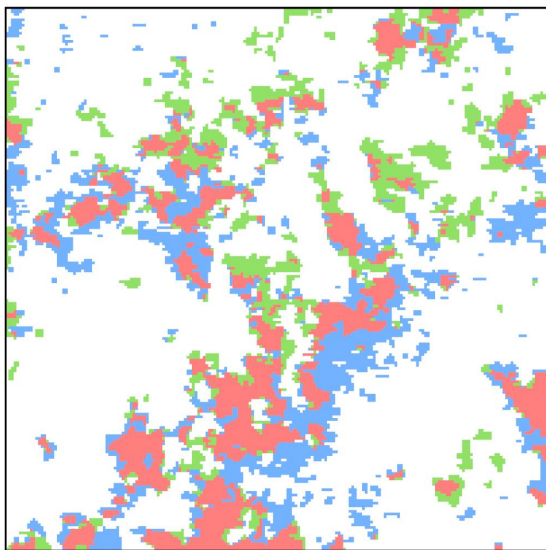
Deschampsia cespitosa




Pinus mugo



Calluna vulgaris



Nardus stricta



Příloha 3: Luční hora – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím objektově orientované klasifikace mezi lety 2004 a 2020


MAPA VÝVOJE VYBRANÝCH KATEGORIÍ VEGETAČNÍHO POKRYVU

na území Luční hory
mezi lety 2004 a 2020


klasifikace Random forest

- hranice území Luční hory
- výskyt druhu v roce 2004
- výskyt druhu v roce 2020
- výskyt druhu v obou sledovaných letech


Deschampsia cespitosa





Pinus mugo



Calluna vulgaris



Nardus stricta



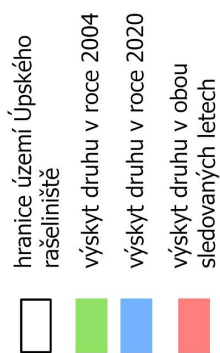
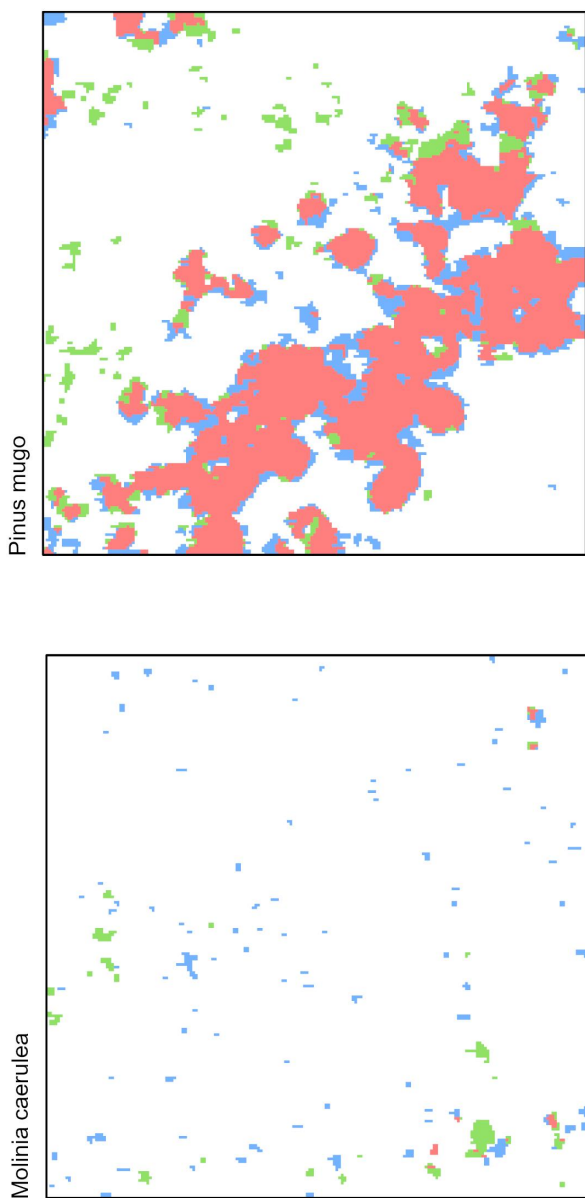


Petra PAJMOVÁ
Příbram 2022

MAPA VÝVOJE VYBRANÝCH KATEGORIÍ VEGETAČNÍHO POKRYVU

na území Úpského rašeliniště
mezi lety 2004 a 2020

objektově orientovaná klasifikace



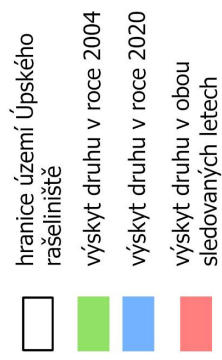
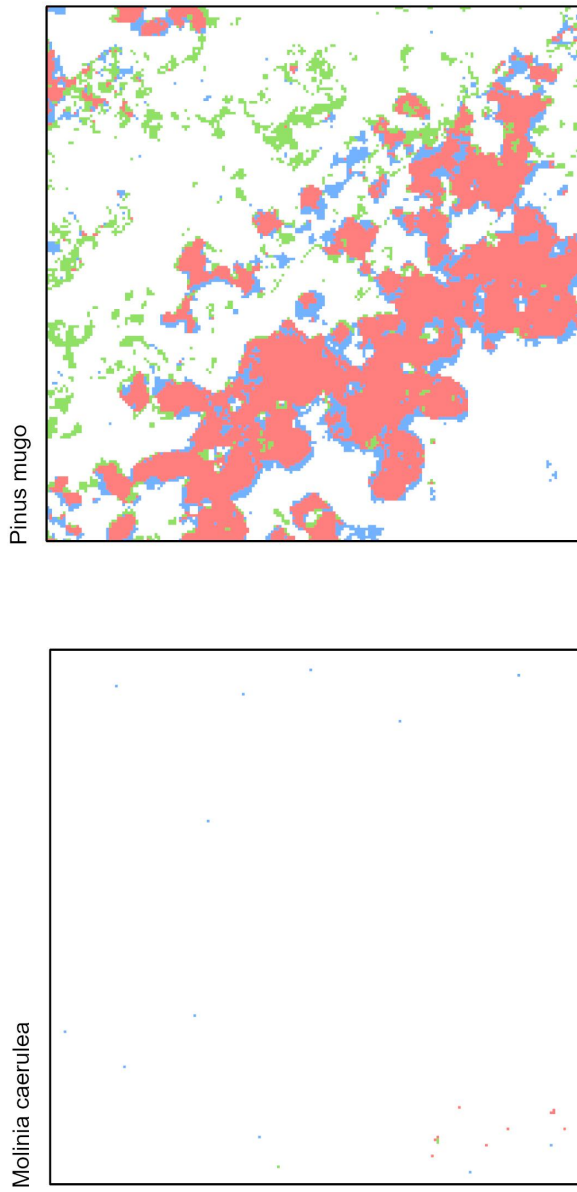


Příloha 5: Úpské rašeliniště – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím objektově orientované klasifikace mezi lety 2004 a 2020

MAPA VÝVOJE VYBRANÝCH KATEGORIÍ VEGETAČNÍHO POKRYVU

na území Úpského rašeliniště
mezi lety 2004 a 2020

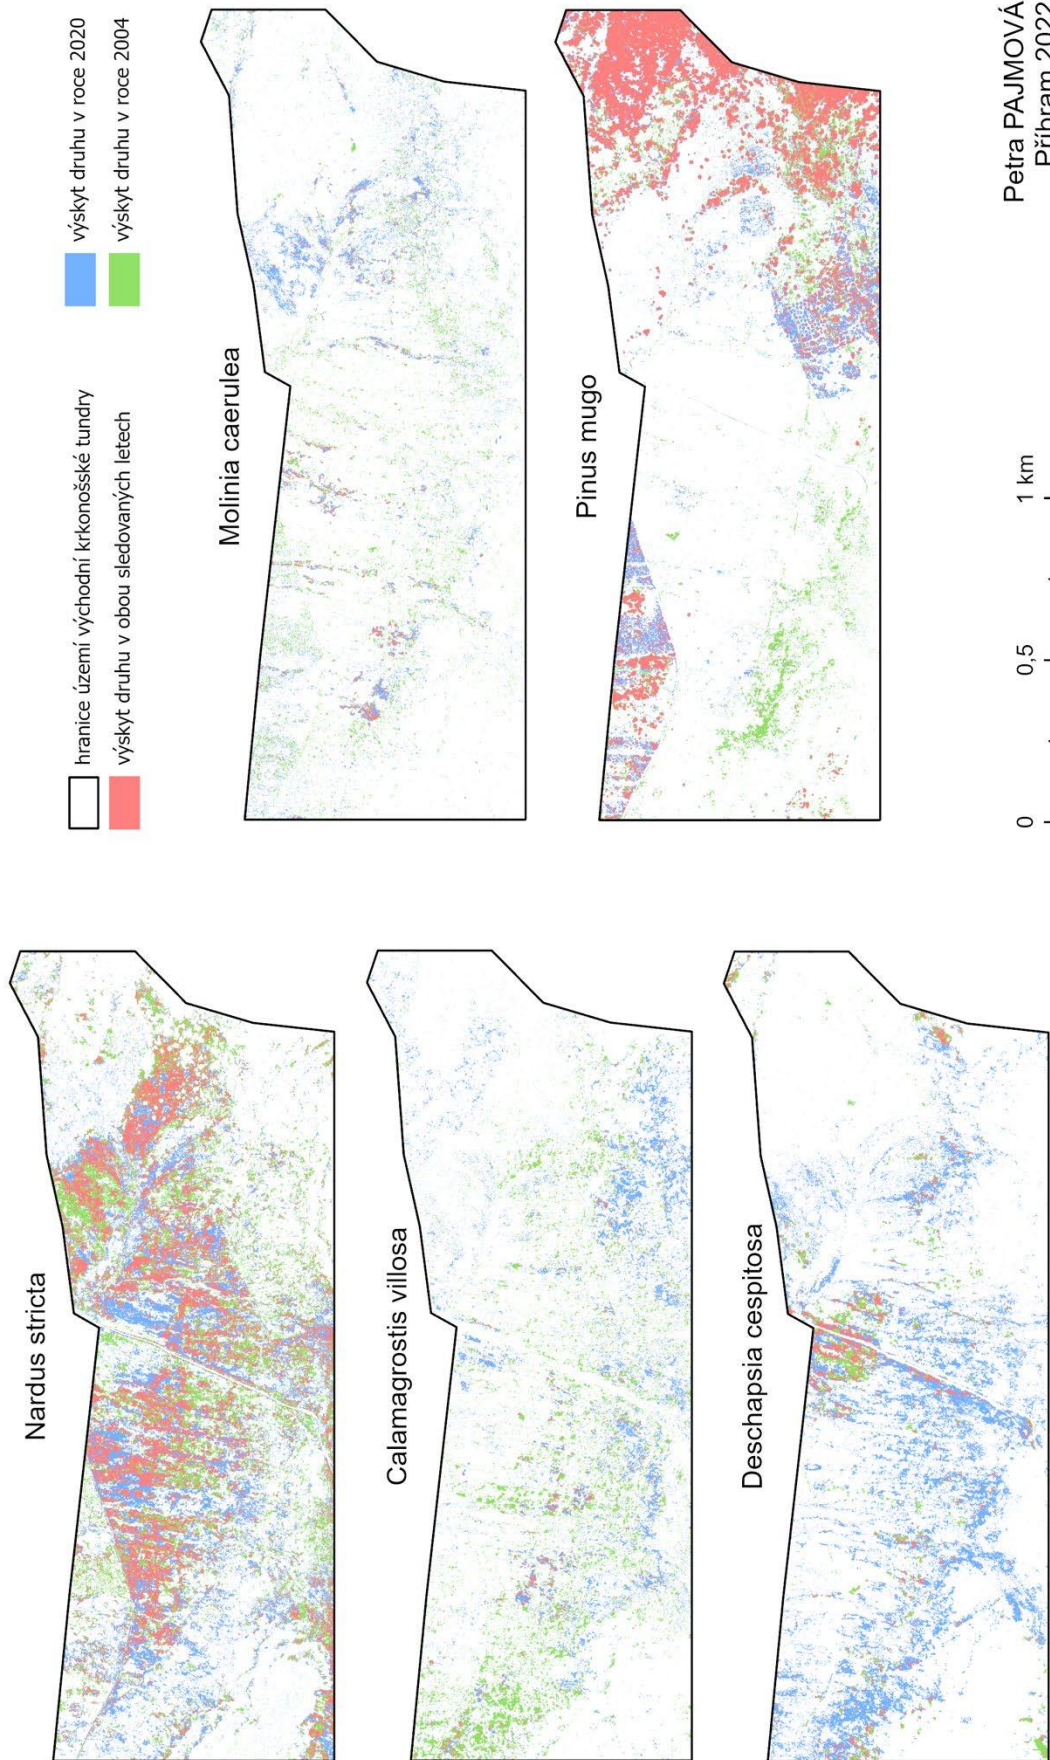
klasifikace Random forest



Příloha 6: Úpské rašeliniště – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím klasifikace Random forest mezi lety 2004 a 2020

MAPA VÝVOJE VYBRANÝCH KATEGORIÍ VEGETAČNÍHO POKRYVU

na území východní krkonošské tundry mezi lety 2004 a 2020
objektově orientovaná klasifikace

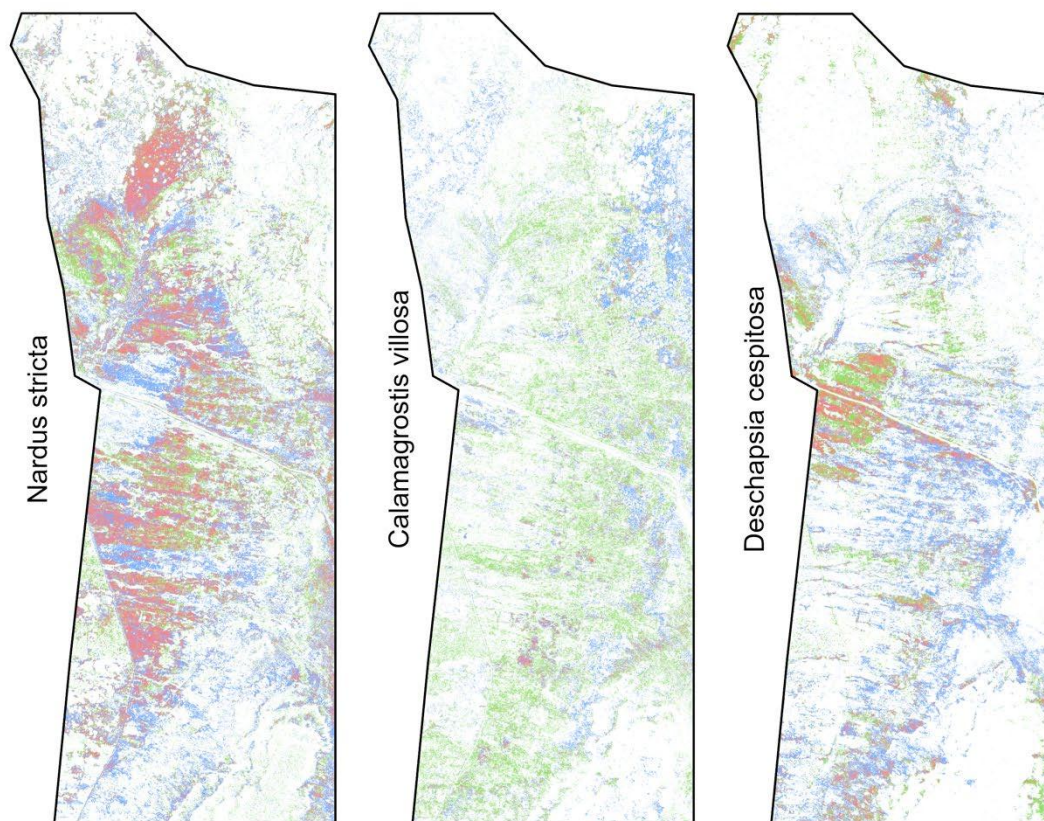


Petra PAJMOVÁ
Příbram 2022

Příloha 7: širší území tundry – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím objektově orientované klasifikace mezi lety 2004 a 2020

MAPA VÝVOJE VYBRANÝCH KATEGORIÍ VEGETAČNÍHO POKRYVU

na území východní krkonošské tundry mezi lety 2004 a 2020
klasifikace Random forest



Příloha 8: širší území tundry – mapa vývoje vybraných kategorií vegetačního pokryvu s využitím klasifikace Random forest mezi lety 2004 a 2020