

**Univerzita Karlova**

**Přírodovědecká fakulta**

Studijní program: Geografie

Studijní obor: Geografie a kartografie



Vít Ježek

**ANALÝZA ROZŠÍŘENÍ OCHRANÁŘSKY DŮLEŽITÝCH TRAVNÍCH DRUHŮ V KRKONOŠSKÉ  
TUNDŘE S VYUŽITÍM DÁLKOVÉHO PRŮZKUMU ZEMĚ**

**ANALYSIS OF IMPORTANT GRASS SPECIES DISTRIBUTION IN THE KRKONOŠE MTS. TUNDRA  
USING REMOTE SENSING**

Bakalářská práce

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

Praha, 2022

**Vysoká škola:** Univerzita Karlova v Praze

**Fakulta:** Přírodovědecká

**Katedra:** Aplikované geoinformatiky a kartografie

**Školní rok:** 2021/2022

# Zadání bakalářské práce

**pro** Vít Ježek

**obor** Geografie a kartografie

**Název tématu:** Analýza rozšíření ochranně důležitých travních druhů v krkonošské tundře s využitím dálkového průzkumu Země

## Zásady pro vypracování

V poslední době patří k ochranným problémům krkonošské arko-alpínské tundry pravděpodobné rozšiřování tří expanzivních druhů trav – bezkolenec modrý (*Molinia caerulea*), třtina chloupkatá (*Calamagrostis villosa*) a metlice obecná (*Deschampsia cespitosa*) na úkor původně dominantních porostů smilkových trávníků (smilka tuhá – *Nardus stricta*). Tyto změny a jejich vývoj však zatím nejsou v širším měřítku spolehlivě dokumentovány a systematicky sledovány. Data a metody dálkového průzkumu Země ve spojení s botanickými vstupy (přesně prostorově lokalizovaná trénovací a validační data pro jednotlivé druhy) mohou přispět k potvrzení tohoto předpokladu a být spolehlivým nástrojem pro monitoring travních druhů. Bakalářská práce bude vycházet z projektu Operačního programu životní prostředí: „Vývoj metod pro sledování změn vegetace krkonošské tundry analýzou dat z multispektrálních, hyperspektrálních a LiDAR senzorů UAV“, v rámci něhož byly pro území východní krkonošské tundry pořízeny různé typy dat s cílem navrhnout vhodné metody pro monitoring stavu a změn vegetace tohoto cenného území.

Cílem bakalářské práce je v rámci výše zmíněného projektu testovat, s jakou přesností lze vyjmenované travní druhy mapovat pomocí multispektrálních a hyperspektrálních UAV dat s prostorovým rozlišením cca 3–9 cm v trvalých plochách vymezených v rámci východní části krkonošské tundry (velikost ploch cca 100 x 100 m) s využitím různých metod klasifikace (pixelových a objektové).

Dalším cílem je porovnat přesnost klasifikačních výstupů jednotlivých travních druhů na malých plochách s klasifikačními výstupy širšího území, pro které není k dispozici tak velké množství trénovacích a validačních dat jako v případě ploch malých.

**Rozsah grafických prací:** 10 stran

**Rozsah průvodní zprávy:** 50 stran

**Seznam odborné literatury:**

FRASER, R.H., OLTHOF, I., LANTZ, T.C., SCHMITT, C. (2016): UAV photogrammetry for mapping vegetation in the low-Arctic. *Arct. Sci.* 2, 79–102.

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.

MARCINKOWSKA, A., ZAGAJEWSKI, B., OCHTYRA, A., JAROCIŃSKA, A., RACZKO, E., KUPKOVÁ, L., ŠTYCH, P., MEULEMAN, K. (2014): Mapping vegetation communities of the Karkonosze National Park using APEX hyperspectral data and Support Vector Machines. *Miscellanea Geographica*, 18(2), 23–29.

NELSON, P.R. A KOL. (2022): Remote Sensing of Tundra Ecosystems Using High Spectral Resolution Reflectance: Opportunities and Challenges. *JGR: Biogeosciences* 127, 2.

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.

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

Konzultant bakalářské práce: x

Datum zadání bakalářské práce: 8.10.2021

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 vypracoval samostatně a s použitím uvedené literatury a pramenů.

Jsem si vědom 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 27. 7. 2022

.....

Vít Ježek



## **Poděkování**

Rád bych tímto upřímně poděkoval vedoucí mé práce doc. RNDr. Lucii Kupkové, Ph.D. za čas, který mi věnovala, za ochotu a trpělivost při konzultacích a také za poskytnutí cenných rad v průběhu tvorby této práce. Dále bych chtěl poděkovat Botanickému ústavu AV ČR za poskytnutí botanických vstupů pro tvorbu trénovacích a validačních polygonů.

## **Analýza rozšíření ochranně důležitých travních druhů v krkonošské tundře s využitím dálkového průzkumu Země**

### **Abstrakt**

Cílem této práce bylo testovat aplikaci klasifikačních metod maximální věrohodnosti, Random forest, Support vector machine a objektově orientované klasifikační metody s klasifikátorem Support vector machine na vybraných plochách v krkonošské reliktní arкто-alpínské tundře za účelem mapování rozšíření vegetace se zaměřením na ochranně důležité travní druhy. Pro výzkum byla využita předzpracovaná multitemporální hyperspektrální data a multispektrální data z UAS s prostorovým rozlišením 0,03 m resp. 0,06 m a hyperspektrální letecká data s prostorovým rozlišením 0,6 m společně s trénovacími a validačními daty nasbíranými botaniky přímo v terénu s využitím GPS (všechna data pocházela z let 2019–2021). Klasifikace dosáhly výborných výsledků. Nejlepších celkových přesností bylo dosaženo objektově orientovanou metodou klasifikace, jejíž přesnost se pohybovala mezi 80-95 %. Podobně dobrých výsledků bylo dosaženo také pixelovými metodami Random forest a Support vector machine (nejvyšší celková přesnost 94 %). Z důležitých travních druhů byly nejlépe vyklasifikovány *Calamagrostis villosa* (zpracovatelská přesnost 99,73 %, uživatelská přesnost 99,95 %) a *Deschampsia cespitosa* (zpracovatelská přesnost 99,98 %, uživatelská přesnost 99,33 %).

**Klíčová slova:** klasifikace, tundra, travní druhy, UAS, Krkonošský národní park, pixelová klasifikace, objektově orientovaná klasifikace

## **Analysis of important grass species distribution in the Krkonoše Mts. tundra using remote sensing**

### **Abstract**

The aim of this thesis was to test the application of maximum likelihood classification, Random forest, Support vector machine and object-oriented classification with the Support vector machine classifier on selected areas in the Krkonoše Mts. relict arctic-alpine tundra for the purpose of mapping the distribution of vegetation with a focus on conservation-important grass species. The research used pre-processed multitemporal hyperspectral data and multispectral data from UAS with a spatial resolution of 0.03 m and 0.06 m and hyperspectral aerial data with a spatial resolution of 0.6 m together with training and validation data collected by botanists directly from the fields using GPS (all data are from 2019-2021). The classifications achieved excellent results. The best overall accuracies were achieved by the object-oriented classification, with accuracies ranging between 80-95 %. Similarly, good results were also achieved by pixel methods – Random forest and Support vector machine (highest overall accuracy 94 %). Of the important grass species, *Calamagrostis villosa* (producer's accuracy 99.73 %, user's accuracy 99.95 %) and *Deschampsia cespitosa* (producer's accuracy 99.98 %, user's accuracy 99.33 %) were best classified.

**Keywords:** classification, tundra, grass species, UAS, The Krkonoše Mts. National Park, pixel classification, object-oriented classification

# Obsah

Seznam obrázků .....	10
Seznam tabulek .....	10
Seznam grafů .....	11
1 Úvod a cíle práce .....	13
2 Úvod do problematiky a literární rešerše.....	14
2.1 Klasifikace .....	14
2.2 Trénovací etapa .....	15
2.3 Klasifikační etapa.....	15
2.4 Hodnocení přesnosti .....	16
2.5 Multitemporální přístup .....	17
2.6 Využití DPZ pro mapování tundry.....	17
2.7 Využití DPZ v Krkonoších .....	19
3 Studované území .....	21
3.1 Reliktní arкто-alpínská tundra v Krkonoších.....	21
3.2 Studované plochy .....	21
4 Použitá data a metodika .....	26
4.1 Použitá data a jejich předzpracování.....	26
4.2 Klasifikované kategorie vegetačního pokryvu.....	28
4.3 Metody analýzy dat a hodnocení přesnosti výsledků .....	35
5 Výsledky.....	37
5.1 Výsledky plochy „U Luční boudy“ s využitím hyperspektrálních dat.....	37
5.2 Výsledky plochy „U Zahrádky“ s využitím hyperspektrálních dat .....	39
5.3 Výsledky plochy „U Luční boudy“ s využitím multispektrálních dat .....	41
5.4 Výsledky plochy „U Zahrádky“ s využitím multispektrálních dat .....	43
5.5 Výsledky pro širší území tundry s využitím hyperspektrálních dat .....	45
5.6 Výsledky pro širší území tundry s využitím multispektrálních dat .....	48
5.7 Porovnání výsledků klasifikací z multispektrálních a hyperspektrálních dat .....	50
5.8 Porovnání mapových výstupů z hyperspektrálních a multispektrálních dat.....	54
5.9 Analýza překryvů .....	57

6. Diskuse.....	62
7. Závěr.....	68
Použitá literatura.....	70
Přílohy.....	73

## Seznam obrázků

Obrázek 1: Studovaná oblast .....	22
Obrázek 2: Plocha „U Luční boudy“ z kamery Headwall Nano-Hyperspec .....	23
Obrázek 3: Plocha „U Zahrádky“ z kamery Headwall Nano-Hyperspec .....	24
Obrázek 4: Plocha širšího území z kamery MicaSense Altum .....	25
Obrázek 5: Plocha širšího území ze sensoru CASI .....	25
Obrázek 6: smilka tuhá ( <i>Nardus stricta</i> ).....	29
Obrázek 7: metlice trsnatá ( <i>Deschampsia cespitosa</i> ) .....	29
Obrázek 8: bezkolenec modrý ( <i>Molinia caerulea</i> ) .....	30
Obrázek 9: třtina chloupkatá ( <i>Calamagrostis villosa</i> ) .....	31
Obrázek 10: borovice kleč ( <i>Pinus mugo</i> ).....	31
Obrázek 11: smrk ztepilý ( <i>Picea abies</i> ).....	32
Obrázek 12: metlička křivolaká ( <i>Avenella flexuosa</i> ).....	32
Obrázek 13: ostřice bigelowova ( <i>Carex bigelowii</i> ).....	33
Obrázek 14: mokřady a rašeliniště.....	33
Obrázek 15: vřes obecný ( <i>Calluna vulgaris</i> ).....	34
Obrázek 16: brusnice borůvka ( <i>Vaccinium myrtillus</i> ).....	34
Obrázek 17: kamenná moře.....	35
Obrázek 18: vodní plochy.....	35
Obrázek 19: Mapové výstupy z klasifikace Random forest pro plochu „U Luční boudy“ z hyperspektrálních dat .....	55
Obrázek 20: Mapové výstupy z klasifikace Support vector machine pro plochu „U Zahrádky“ z hyperspektrálních dat .....	56
Obrázek 21: Mapové výstupy z klasifikace OBIA pro širší území tundry z hyperspektrálních dat .....	57
Obrázek 22: Mapový výstup překryvu klasifikací RF a SVM na ploše „U Luční boudy“ za využití hyperspektrálních dat .....	59
Obrázek 23: Mapový výstup překryvu klasifikací RF a SVM na ploše „U Zahrádky“ za využití hyperspektrálních dat .....	60

## Seznam tabulek

Tabulka 1: Vstupní trénovací a validační data pro plochu „U Luční boudy“ .....	27
Tabulka 2: Vstupní trénovací a validační data pro plochu „U Zahrádky“ .....	28
Tabulka 3: Vstupní trénovací a validační data pro širší území tundry.....	28
Tabulka 4: Hodnocení přesnosti „U Luční boudy“ s využitím hyperspektrálních dat metodou MLC.....	37
Tabulka 5: Hodnocení přesnosti „U Luční boudy“ s využitím hyperspektrálních dat metodou RF.....	38
Tabulka 6: Hodnocení přesnosti „U Luční boudy“ s využitím hyperspektrálních dat metodou SVM .....	38
Tabulka 7: Hodnocení přesnosti „U Luční boudy“ s využitím hyperspektrálních dat metodou OBIA.....	39

Tabulka 8: Hodnocení přesnosti „U Zahrádky“ s využitím hyperspektrálních dat metodou MLC .....	39
Tabulka 9: Hodnocení přesnosti „U Zahrádky“ s využitím hyperspektrálních dat metodou RF.....	40
Tabulka 10: Hodnocení přesnosti „U Zahrádky“ s využitím hyperspektrálních dat metodou SVM .....	40
Tabulka 11: Hodnocení přesnosti „U Zahrádky“ s využitím hyperspektrálních dat metodou OBIA .....	41
Tabulka 12: Hodnocení přesnosti „U Luční boudy“ s využitím multispektrálních dat metodou MLC.....	41
Tabulka 13: Hodnocení přesnosti „U Luční boudy“ s využitím multispektrálních dat metodou RF.....	42
Tabulka 14: Hodnocení přesnosti „U Luční boudy“ s využitím multispektrálních dat metodou SVM .....	42
Tabulka 15: Hodnocení přesnosti „U Luční boudy“ s využitím multispektrálních dat metodou OBIA.....	43
Tabulka 16: Hodnocení přesnosti „U Zahrádky“ s využitím multispektrálních dat metodou MLC .....	43
Tabulka 17: Hodnocení přesnosti „U Zahrádky“ s využitím multispektrálních dat metodou RF .....	44
Tabulka 18: Hodnocení přesnosti „U Zahrádky“ s využitím multispektrálních dat metodou SVM .....	44
Tabulka 19: Hodnocení přesnosti „U Zahrádky“ s využitím multispektrálních dat metodou OBIA .....	45
Tabulka 20: Hodnocení přesnosti širšího území s využitím hyperspektrálních dat metodou MLC.....	46
Tabulka 21: Hodnocení přesnosti širšího území s využitím hyperspektrálních dat metodou RF .....	47
Tabulka 22: Hodnocení přesnosti širšího území s využitím hyperspektrálních dat metodou OBIA.....	47
Tabulka 23: Hodnocení přesnosti širšího území s využitím multispektrálních dat metodou MLC.....	48
Tabulka 24: Hodnocení přesnosti širšího území s využitím multispektrálních dat metodou RF .....	49
Tabulka 25: Hodnocení přesnosti širšího území s využitím multispektrálních dat metodou OBIA.....	49
Tabulka 26: Shrnující tabulka celkových shod překryvů u klasifikačních metod RF a SVM.....	58
Tabulka 27: Porovnání přesností důležitých travních druhů mezi jednotlivými plochami s využitím multitemporálních hyperspektrálních dat .....	62
Tabulka 28: Porovnání přesností důležitých travních druhů mezi jednotlivými plochami s využitím multispektrálních dat .....	63
Tabulka 29: Porovnání celkových přesností z klasifikací hyperspektrálních dat mezi monotemporálními snímky a multitemporálním kompozitem z června, července a srpna.....	66

## Seznam grafů

Graf 1: Porovnání zpracovatelské a uživatelské přesnosti mezi hyperspektrálními a multispektrálními daty na ploše „U Luční boudy“ .....	50
Graf 2: Porovnání rozloh jednotlivých tříd mezi hyperspektrálními a multispektrálními daty na ploše „U Luční boudy“ .....	51
Graf 3: Porovnání zpracovatelské a uživatelské přesnosti mezi hyperspektrálními a multispektrálními daty na ploše „U Zahrádky“ .....	52
Graf 4: Porovnání rozloh jednotlivých tříd mezi hyperspektrálními a multispektrálními daty na ploše „U Zahrádky“ .....	52
Graf 5: Porovnání zpracovatelské a uživatelské přesnosti mezi hyperspektrálními a multispektrálními daty na širším území tundry“ .....	53
Graf 6: Porovnání rozloh jednotlivých tříd mezi hyperspektrálními a multispektrálními daty na širším území tundry .....	54
Graf 7: Shody jednotlivých klasifikačních metod „U Luční boudy“ pro jednotlivé třídy s využitím hyperspektrálních dat .....	58

Graf 8: Shody jednotlivých klasifikačních metod „U Zahrádky“ pro jednotlivé třídy s využitím hyperspektrálních dat .....	59
Graf 9: Shody jednotlivých klasifikačních metod „U Luční boudy“ pro jednotlivé třídy s využitím multispektrálních dat .....	61
Graf 10: Shody jednotlivých klasifikačních metod „U Zahrádky“ pro jednotlivé třídy s využitím multispektrálních dat .....	61



# 1 Úvod a cíle práce

Práce se zabývá klasifikací původních (*Nardus stricta*) a expanzivních (*Calamagrostis villosa*, *Molinia caerulea* a *Deschampsia cespitosa*) druhů travin společně s dalšími doprovodnými druhy vegetace z obrazových dat dálkového průzkumu Země s velmi vysokým prostorovým rozlišením v řádu centimetrů pořízených s využitím UAS na dvou plochách vymezených v rámci území Bílé louky v blízkosti Luční boudy na území Krkonošského národního parku. Jde o jednu z nejcennějších oblastí krkonošské reliktní tundry, kde je monitoring expanzivních druhů důležitý kvůli možnému ohrožení druhové diverzity.

Hlavním cílem práce bylo porovnat přesnost různých metod klasifikace (několika pixelových a objektově orientované) a ověřit/potvrdit, zda je pro travní druhy na dvou vymezených zájmových plochách možné dosáhnout vysoce přesných výsledků (uživatelské a zpracovatelské přesnosti nad 90 %), jakých bylo dosaženo pro jinou, ale charakterem velmi podobnou plochu vymezenou v rámci Bílé louky v projektu „Vývoj metod pro sledování změn vegetace a krkonošské tundry analýzou dat z multispektrálních, hyperspektrálních a LiDAR senzorů UAV“ řešeném výzkumným týmem TILSPEC ([www.tilspec.cz](http://www.tilspec.cz)) na katedře aplikované geoinformatiky a kartografie PřF. K této analýze byla využita multitemporální hyperspektrální data z UAS nasnímaná v letech 2020 a 2021 a trénovací a validační data získaná pomocí botanického mapování jednotlivých druhů lokalizovaných přesnou GPS (v letech 2019–2021). Dalším cílem bylo porovnat přesnost klasifikace sledovaných travních druhů na malých plochách, pro něž bylo k dispozici velké množství botanických trénovacích a validačních dat s přesností, jakou je možné dosáhnout s využitím stejných klasifikačních metod pro úroveň širšího území tundry s využitím multispektrálních dat pořízených z UAS v roce 2021 a hyperspektrálních leteckých dat získaných v roce 2020, pro které bylo množství trénovacích a validačních dat omezeno. Zjištěné informace mohou posloužit k vytipování nejlepšího období ke snímkování, k určení nejvhodnější metody klasifikace, k porovnání přesnosti klasifikace multispektrálních a hyperspektrálních dat a tím přispět k zefektivnění monitoringu travní vegetace. Při hodnocení přesnosti klasifikací bylo kromě tradičně prováděného hodnocení celkové, uživatelské a zpracovatelské přesnosti (Jensen, 1986) využito také srovnání prostorové shody klasifikovaných kategorií v různých klasifikačních výstupech a porovnány byly též rozlohy jednotlivých tříd získané rozdílnými metodami klasifikace.

Využití bezpilotních systémů (UAS) nabízí velmi efektivní způsob sběru dat pro dálkový průzkum Země. L. Bing (2017) konstatuje, že ve srovnání se satelitním průzkumem mohou UAS pracovat rychle a opakovaně a zároveň nabízí dostatečně podrobné prostorové rozlišení pro zkoumání vegetačního pokryvu. Právě z těchto důvodů byla UAS technologie využita i pro analýzu druhového

složení zájmových ploch ve východní krkonošské tundře. Poskytla mimo jiné možnost tvorby multitemporálních kompozitů z období června, července a srpna. Kombinace dat z jednotlivých termínů totiž umožňuje současné zohlednění spektrálních projevů jednotlivých druhů, které se objevují pouze v konkrétních fenologických obdobích (Marcinkowska-Ochtyra a kol., 2019).

## 2 Úvod do problematiky a literární rešerše

### 2.1 Klasifikace

Obecným cílem klasifikace obrazu je kategorizace všech pixelů do určité třídy krajinného pokryvu (Lillesand a kol., 2015). K tomu je nutné vytvořit postup, podle kterého rozřídění proběhne. Tomuto postupu se říká klasifikační pravidlo. K vytvoření klasifikačního pravidla se používají příznaky, což jsou velmi charakteristické vlastnosti naměřených dat, které se od sebe dostatečně odlišují. Příznaky mohou být založeny na prostorových, spektrálních, anebo časových změnách (Kolář a kol., 1997).

Klasifikace je možné rozřídít do několika kategorií. Obecně ji lze dělit na klasifikaci řízenou a neřízenou. Hlavním rozdílem je způsob, jakým probíhá výběr klasifikovaných kategorií. Při řízené klasifikaci zpracovatel předem určí počet tříd, do kterých budou všechny pixely rozřazeny, a to pomocí trénovacích ploch, které označují místa, u kterých lze jednoznačně definovat známý povrch. U klasifikace neřízené jsou nejprve všechny pixely rozříděny do určitých tříd, například pomocí shlukové analýzy, a až poté dává zpracovatel těmto třídám informační obsah. Trénovací plochy tak v tomto případě nejsou potřeba (Dobrovolný, 1998).

Vzhledem k dostupnosti trénovacích ploch se práce věnuje pouze metodám řízené klasifikace. Jendou z její hlavních výhod je totiž kontrola nad třídami, do kterých budou pixely rozřazeny. To je velmi důležité pro porovnávání stejných ploch z různých časových období nebo sousedních ploch ze stejné oblasti. Trénovací data jsou k tomu totiž cíleně vytvořena (Campbell, Wynne, 2011). Využity byly pixelové klasifikační metody maximální věrohodnosti (MLC), Random forest (RF), Support vector machine (SVM) a objektově orientované klasifikace (OBIA) s využitím klasifikátoru SVM.

V případě pixelových klasifikací je každý pixel rozřazen samostatně a izolovaně. Naproti tomu OBIA používá jak spektrální, tak prostorovou informaci. To znamená, že jednotlivé pixely jsou segmentovány do diskrétních celků (shluků/objektů) a až ty jsou klasifikovány. Základní předpoklad vychází z toho, že se klasifikovaný snímek skládá z homogenních ploch, které jsou větší než jednotlivé pixely (Lillesand a kol., 2015; Blaschke, 2010).

Pracovní postup u řízené klasifikace můžeme rozdělit do tří etap. Nejprve je vytvořen trénovací dataset, následně probíhá samotná klasifikace a na závěr je hodnocena její přesnost.

## 2.2 Trénovací etapa

Při řízené klasifikaci je prvním krokem výběr trénovacích ploch. Ten provádí zpracovatel sám pomocí podkladových informací o výskytu vybraných tříd alespoň na několika místech snímku, přičemž spolehlivost a kvalita těchto informací určuje kvalitu výsledné klasifikace (Kolář a kol., 1997). Trénovací data musí být především kompletní a reprezentativní. Tím je myšleno, že všechny hledané třídy musí být charakterizovány v dostatečném počtu a velikosti a také vhodně umístěné na místa, která jsou pro danou třídu typická. Dále je nutné do ploch volit pixely s co nejpodobnějšími DN hodnotami, které jsou zároveň dostatečně odlišné od ploch jiné třídy (Dobrovolný, 1998). Důležitost tohoto kroku potvrdil i Hixon a kol. (1980), který konstatuje, že výběr trénovacích dat může být při určování přesnosti klasifikace dokonce důležitější než výběr klasifikačního algoritmu.

Pro potřeby hlubší analýzy tréninkových množin lze využít několik nástrojů. Ty mohou být grafické a kvantitativní. Jeden ze zástupců grafických nástrojů je histogram. Ten velmi dobře reprezentuje rozložení jednotlivých tříd, což může být užitečné například u klasifikátoru MLC, protože poskytuje vizuální kontrolu normality spektra. Neusnadňuje ale srovnávání několika tříd mezi sebou. Pro porovnávání je tedy vhodnější například graf koincidence, ze kterého lze vyčíst případný překryv různých tříd (Lillesand a kol., 2015). Podle Koláře a kol. (1997) je ale nejvhodnější rozptylogram, ze kterého se separabilita jednotlivých tříd pozná nejsnáze.

Jedním ze statistických parametrů vyjádřený ve kvantitativní formě může být tzv. divergence čili vážená vzdálenost mezi průměrovými vektory uvažovaných tříd. Tady platí, že čím větší je divergence, tím větší je pravděpodobnost správné klasifikace tříd (Dobrovolný, 1998).

## 2.3 Klasifikační etapa

V tomto kroku probíhá samotné klasifikování. Jde o automatickou práci počítače, který zařadí jednotlivé pixely do předem vybraných tříd a vytvoří tak zcela nový obraz, který má stejné rozlišení a stejnou prostorovou velikost pixelu, ale zcela nové funkční hodnoty (Kolář a kol., 1997). Součástí klasifikační etapy je také vhodný výběr a nastavení klasifikátoru. Podle Jensena (1986) neexistuje obecně platný funkční postup klasifikace, a tak je často některé kroky nutné opakovat a experimentovat s jiným nastavením vstupních parametrů za účelem postupného zpřesňování výsledků. V práci byly využity tyto klasifikátory.

### 2.3.1 Klasifikátor maximální pravděpodobnosti

Klasifikátor maximální pravděpodobnosti (MLC) pracuje s předpokladem, že mračno bodů, které tvoří tréninková data, má Gaussovo rozdělení. Pokud je tato podmínka splněna, tak se každý pixel porovná se všemi kategoriemi a je zařazen do té s největší pravděpodobností výskytu (Lillesand a kol., 2015).

MLC se řadí mezi parametrické klasifikátory. Goméz a kol. (2016) to ale považuje za jednu z hlavních nevýhod, jelikož tato kategorie klasifikátorů nerozlišuje hraniční pixely dostatečně flexibilně, a zvláště u složitějších území může být méně efektivní. Na druhou stranu ho ale pokládá za jednoduše aplikovatelný a lehce interpretovatelný.

### 2.3.2 Klasifikátor Random forest

Random forest (RF) je metodou strojového učení, která se skládá z kombinace rozhodovacích stromů, kde je každý další strom generován pomocí náhodného vektoru, který je nezávislý na vektoru vstupním. Každý strom následně volí třídu, do které by měl být pixel zařazený (Breiman, 1999). Hlavní výhodou je schopnost pracovat s rozsáhlými daty a obecně vysoká přesnost. Problémem mohou být neznámá rozhodovací pravidla (jde o tzv. černou skříňku) a také velká výpočetní náročnost (Goméz a kol., 2016).

### 2.3.3 Klasifikátor Support vector machine

Support vector machine (SVM) je jednou z metod strojového učení, která má za cíl určit rozmístění hranic, které optimálně oddělují jednotlivé třídy mezi sebou. Klasifikátor vybírá z nekonečného počtu přímek a snaží se určit tu, která ponechává největší rozpětí mezi oběma třídami (Vapnik, 1998). SVM je v oblasti dálkového průzkumu Země populární díky své schopnosti přesné klasifikace i s malým vzorkem trénovacích dat. Nedostatkem jsou problémy s přiřazováním parametrů, které mohou významně ovlivnit výsledky (Mountrakis, Ogole, 2011).

### 2.3.4 Klasifikátor objektivně orientovaný

Objektivně orientované klasifikace (OBIA) nepracuje se samostatnými pixely, ale se shluky/objekty ze spektrálně homogenních pixelů, které vznikly segmentací obrazu. Tento druh klasifikace se v poslední době stává čím dál tím více populární, protože splňuje vysoké uživatelské nároky pro zpracování stále detailnějších geoprostorových dat (Blaschke, 2010). OBIA často reprezentuje strukturu povrchu lépe než pixelové klasifikace. Může vzít v úvahu například vliv sousedících shluků a lépe tak charakterizovat rozdíly mezi spektrálně podobnými třídami (Campbell, Wynne, 2011).

## 2.4 Hodnocení přesnosti

Jedním z nejvíce používaných přístupů k hodnocení úspěšnosti klasifikace je výpočet klasifikační chybové matice. Chybová matice porovnává u všech klasifikovaných tříd vztah mezi validačními plochami a výsledky klasifikace. Validační plochy je pro objektivní testování nutné vybrat z rozdílných míst obrazu než plochy trénovací (Dobrovolný, 1998). V principu se jedná o tabulku o rozměrech  $n \times n$ , kde  $n$  představuje počet klasifikovaných tříd. V ní je porovnáváno kolik pixelů z validačních dat se pozičně shoduje s výsledky klasifikace (Campbell, Wynne, 2011). Z hodnot v matici se dá následně pro každou třídu dopočítat uživatelská přesnost (počet správně klasifikovaných pixelů / celkový počet pixelů), zpracovatelská přesnost (počet správně klasifikovaných pixelů / počet pixelů použitých pro

testování dané třídy) a kappa index, který porovnává klasifikaci s náhodným rozdělením pixelů do jednotlivých tříd (Dobrovolný, 1998).

## 2.5 Multitemporální přístup

Obrazová data pořizovaná distančními metodami lze pro dané místo získávat opakovaně v určitých časových intervalech. Tato data poté vytvářejí časovou řadu a jsou označována jako multitemporální. Ty jsou využity k detekci časových změn v krajině. Můžeme je rozdělit na dlouhodobé, jako je například využití půdy nebo procesy desertifikace a na krátkodobé, kam lze zařadit monitorování průběhu povodní, vývoj sněhové pokrývky či sledování jednotlivých fenologických fází rostlin (Dobrovolný, 1998).

Všeobecně můžeme multitemporální přístup při sledování vegetace rozdělit na dvě skupiny. V prvním případě se hodnotí snímky z více termínů v rámci jedné sezóny. V průběhu fenologického cyklu totiž rostlina mění i spektrální vlastnosti. Při klasifikaci multitemporálních kompozitů je tak možné zachytit určité příznaky mnohem efektivněji a zvýšit díky tomu přesnost. S využitím druhého způsobu jsou analyzovány prostorové změny na sledovaném území v rámci delšího časového horizontu. Tento přístup je označován jako change detection. V DPZ má velký význam při monitorování změn krajinného pokryvu (Asokan, Anitha, 2019).

## 2.6 Využití DPZ pro mapování tundry

Mapování ekosystémů tundry je věnována velká pozornost zejména z důvodu ohrožení těchto hodnotných území například v důsledku globálních změn. Jsou využity různé technologie sběru dat a také různé klasifikační metody. Velká část výzkumu se primárně zaměřuje na oblasti arktické tundry. Atkinson a Treitz (2012) se zaměřili na dvě území v oblasti severní Kanady. Výzkum zkoumal vztah mezi ekologickými a spektrálními proměnnými za účelem klasifikace vegetace z dat dálkového průzkumu Země. Snímky ze satelitu IKONOS byly podrobeny korespondenčním, shlukovým a spektrálně separačním analýzám. Klasifikace měly celkovou přesnost mezi 69 % až 79 % a hodnoty Kappa 0,54–0,69. Vegetační třídy byly obecně odlišitelné v obou lokalitách s výjimkou ostřicových mokřadů.

Cílem Davidsona a kol. (2016) bylo zjistit, zda jsou dominantní vegetační společenstva arktické tundry v oblasti severní Aljašky spektrálně odlišitelná pomocí dat z pozemního spektrometru UniSpec-DC a multispektrálních satelitních snímků WorldView 2 s prostorovým rozlišením 2 metry. Z dat nasbíraných ze čtyř testovacích ploch byly vypočítány indexy NDVI, NDWI a EVI, použita metoda hlavních komponent a následně i lineární diskriminační analýza. Po zpracování dat z pozemního spektrometru bylo dosaženo přesnosti klasifikace 92 % až 96 %. Při použití satelitních dat ale došlo k výraznému zhoršení přesnosti na přibližně 70 %. Tyto výsledky ukazují, že multispektrální satelitní

snímky s prostorovým rozlišením 2 metry nejsou dostatečně detailní k reprezentaci vegetační homogenity na území tundry.

Arktické tundře se věnoval také Assmann a kol. (2020). Na ostrově Qikiqtaruk-Herschel v teritoriu Yukon v Kanadě testoval, zda mezi sebou hodnoty z dat získaných z UAV a ze satelitu korespondují. A to při sledování sezónních změn obsahu chlorofylu v rostlinách. Principem studie bylo porovnání NDVI z multispektrálních snímků získaných pomocí dronu a z družic Sentinel-2, Landsat 8 a MODIS. Data z dronu se ve středních hodnotách obsahu chlorofylu shodovala s družicovými daty (Spearman  $\rho$  0.67–0.87), ale zároveň lépe zachytila prostorovou heterogenitu v NDVI. Z výsledků je zřejmé, že UAV dokážou zachytit důležité ekologické procesy a umožňují studium v dříve nedostupných měřících. Zaplňují tedy mezeru mezi pozemním sledováním a snímkováním ze satelitu.

UAV společně s metodami terénní spektrometrie ve svém výzkumu použil i Thomson a kol. (2021). Ten studoval tři výzkumné plochy v arktické oblasti kolem Longyearbyenu v souostroví Svalbard v Norsku. Pomocí dat z terénní spektroskopie a analýzy Random forest byl schopný rozlišit osm běžných arktických rostlinných druhů se 74% přesností. S pomocí UAV byl schopný zmapovat tři funkční skupiny rostlin (mechy, traviny a zakrslé keře) s přesností 72 %. I zde bylo UAV oceněno jako efektivní nástroj, který vyplňuje mezeru mezi pozemním sběrem dat a družicovým průzkumem.

Bezpilotní letouny kvitoval též Fraser a kol. (2016), který ve své práci studoval potenciál fotografických průzkumů UAV ke zmapování arktické vegetace poblíž Tuktoyaktuku v Kanadě. Získané snímky byly zpracovány do 3D mračen a výškových vegetačních profilů s rozlišením 1 cm. Pomocí metody Structure from Motion (SfM) bylo klasifikováno 11 tříd s 82% přesností.

Nelson a kol. (2022) ve své práci rozebral hlavní metody sběru dat na charakteristických površích od lišejníků, mechorostů, cévnatých rostlin až po místa bez vegetace. Z důvodu silné sezónnosti arktických rostlin a často nehostinným podnebným podmínkám doporučil ke zvýšení efektivity výzkumu víceúrovňový přístup. Tedy kombinací celého spektra metod sběru dat od laboratorního výzkumu přes letecký průzkum až po satelitní snímkování společně s vhodným statistickým modelováním. Pozorování poté musí být vyhodnocena společně.

Některé výzkumy proběhly i na území Česka. Oblasti jesenické arкто-alpínské tundry se věnoval Král (2009). Zdrojem dat byla ortofotomapa v infračerveném spektru s rozlišením 0,9 metru. Cílem studie bylo odvodit aktuální a komplexní informace o současném vegetačním pokryvu rezervace Praděd se zvláštním zřetelem k unikátnímu ekotonu alpínského stromořadí tvořeného krummholzem smrku ztepilého. S využitím metody MLC bylo vyklasifikováno celkem sedm kategorií s finální přesností 78 %.

## 2.7 Využití DPZ v Krkonoších

Na území Krkonošského národního parku (KRNAP) bylo provedeno několik výzkumů zaměřujících se na analýzu vegetace. Müllerová (2005) se zaměřila na mapování subalpínské vegetace na území Labské louky v západních Krkonoších. K tomu byly využity multispektrální letecké snímky z let 1986, 1989 a 1997. Naskenované snímky byly digitalizovány a poté provedena neřízená klasifikace ISODATA. Klasifikátor identifikoval celkem 15 tříd. Mnoho z nich ale obsahovalo stejné typy vegetace, tak proběhlo sloučení do finálních 6 tříd. Celková přesnost dosáhla na 63 %. Autorka následně provedla klasifikaci MCL pro 7 tříd s celkovou přesností 79 %. Mapy založené na leteckých snímcích byly porovnány s dostupnou vegetační mapou získanou terénním průzkumem. Shoda se pohybovala v rozmezí 24–75 %, přičemž nejvyšší hodnoty byly získány pro borové porosty a smilkové trávníky. Ve srovnání s terénním průzkumem poskytlo letecké snímkování méně detailů a vegetaci charakterizovaly převážně dominantní druhy.

Archivní snímky z leteckého snímkování použili také Potůčková a kol. (2021), a to pro porovnání dat z pěti období mezi lety 1936 až 2018. Klasifikace snímků odhalila za posledních osmdesát let změnu tříd krajinného pokryvu o 44 %. Zjištěnou hrozbou byla zrychlená expanze borovice kleče z 30,6 % na 48,6 % a to většinou na úkor travních porostů.

Vhodnost multispektrálních dat s různým prostorovým a spektrálním rozlišením pro klasifikaci vegetaci nad horní hranicí lesa studovala Suchá a kol. (2016). Zdrojem dat byla letecká ortofota s prostorovým rozlišením 12,5 cm a data ze satelitů Landsat 8 a WorldView 2 s prostorovým rozlišením 2 metry. Na nich proběhly pixelové klasifikace (MLC, SVM, neural net) a také OBIA. Pro klasifikace byly navrženy dvě legendy. Podrobná s dvanácti třídami a zjednodušená s osmi. Nejlepších výsledků s oběma legendami bylo dosaženo u ortofoto snímků s použitím OBIA (celková přesnost 71,96 % a 83,56 %). Klasifikace WorldView 2 přinesla nejlepší výsledky při použití OBIA se zjednodušenou legendou (68,4 %). Data z Landsat 8 byla nejlépe klasifikovaná pomocí MLC (78,31 %). Na základě srovnání dat bylo konstatováno, že velmi vysoké prostorové rozlišení je rozhodujícím znakem, který je nezbytný pro dosažení vysoké celkové přesnosti klasifikace při detailním mapování.

Na článek od Suché a kol. (2016) následně navázala Kupková a kol. (2017). Ta se však věnovala hyperspektrálním datům taktéž na území krkonošské tundry nad horní hranicí lesa. V této studii byly použity snímky z leteckých senzorů APEX a AISA Dual a ze satelitu Sentinel-2A. Snímky byly klasifikovány také pomocí metod MLC, SVM, neural net a OBIA. Nejlepších výsledků bylo dosaženo pro data AISA Dual s použitím klasifikační metody SVM s celkovou přesností 84,3 %. Naopak nejhůře dopadaly klasifikace ze satelitu Sentinel-2A. Pro získání srovnatelných výsledků zde bylo nutné zjednodušit legendu klasifikace. S touto bylo dosaženo přesnosti 77,7 % (MLC). Tyto snímky tak

nesplňovaly požadavky pro podrobnou klasifikaci vegetace tundry. Rozlišení snímků nebylo dostatečné a některé třídy travních druhů nebyly dobře rozlišitelné. Ze závěrů tohoto článku také vyplývá zásadní vliv prostorového rozlišení snímku na výsledky klasifikace na úrovni detailů.

Důležitou část studia Krkonoš tvoří výzkum zaměřený i na polskou část pohoří. Na KRNP za státní hranicí navazuje Karkonoski Park Narodowy (KPN), kterému se věnovala například Marcinkowska a kol. (2014). Ta se zaměřila na okolí hory Szrenica. Cílem práce bylo odhalit potenciál hyperspektrálních dat pro mapování ekosystému horské vegetace. Snímky byly získány senzorem APEX. Pro klasifikaci bylo potom v terénu pomocí GPS vybráno 15 tříd vegetačních společenstev pro tvorbu trénovacích a validačních dat. Pomocí metody SVM bylo dosaženo celkové přesnosti 79,13 %.

Hyperspektrální data ze senzoru APEX použili také Raczek a Zagajewski (2018), kteří se ale zaměřili na mapování dřevin. Pro klasifikaci byl použit algoritmus umělé neuronové sítě s jednou skrytou vrstvou. Nakonec bylo dosaženo celkové přesnosti 87 %. Nejlépe klasifikované třídy byly smrk, buk a bříza se zpracovatelskou přesností 93 %, 88 % a 83 %. Naopak třída borovice dosáhla nejnižší zpracovatelské přesnosti (68 % a 75 %).

Studiem přeshraniční biosférické rezervace UNESCO Krkonoše/Karkonosze se zabýval Zagajewski a kol. (2021). V této studii použil data z družic Sentinel-2 a Landsat 8 k posouzení klasifikace lesních porostů. K tomu autoři použili tři algoritmy strojového učení, kterými byly RF, SVM a Artificial Neural Network (ANN). Nejlepších výsledků bylo dosaženo pomocí metody SVM s celkovou přesností 86,5 %.

Zatím však nebyla publikována žádná studie, která by se zabývala klasifikací hyperspektrálních dat z UAV a vyhodnocením přesnosti klasifikace na úrovni druhů se zaměřením na travní vegetaci.



## 3 Studované území

### 3.1 Reliktní arko-alpínská tundra v Krkonoších

Krkonošská tundra je v celé střední Evropě unikátní prostředí. Na české i polské straně pokrývá dohromady 47 km<sup>2</sup> nad alpínskou hranicí lesa (7,4 % z rozlohy Krkonoš). Zahrnuje ledovcové kary, alpínské trávníky a rašeliniště na náhorních plošinách (etchplénech) i mrazem a větrem formované nejvyšší vrcholy (KRNAP, 2015).


Soukupová a kol. (1995) dělí krkonošskou tundru detailněji na tři různé druhy. První je zóna lišejníkové tundry (kryo–eolické) nacházející se na nejvyšších vrcholech a hřbetech, kde panují nejextrémnější podnebné podmínky. Průměrná roční teplota se zde pohybuje kolem +1 °C a celá oblast je pod silnou expozicí větru. Vyskytují se zde vzácné severské a alpínské lišejníky a mechorosty, kamenná pole a kryoplanační terasy. Tento druh tundry se nachází také na vrcholcích Luční a Studniční hory.

Na kryo–eolickou tundru navazuje zóna travnaté tundry (kryo–vegetační). Ta se rozkládá na třetihorních vrcholových plochách s vyrovnaným terénem označovaných jako etchplén. Z hlediska flóry se zde vyskytují především alpínské trávníky, kleče a severská rašeliniště. Do této skupiny můžeme zařadit i Bílou louku u Luční boudy. Tato místa jsou již méně větrná a jsou charakteristická velkým množstvím sněhových i dešťových srážek.

Posledním druhem je tundra květnatá (niveo–glaciální). Tu lze nalézt v závětrných místech, které v minulosti vyplňovaly ledovce a byly intenzivně ovlivněny mrazovým zvětráváním. Jedná se o svahy ledovcových karů a karoidů, nivační deprese nebo sněhové prohlubně. Intenzivní vliv sněhových lavin v těchto místech podpořil vznik velmi pestrých ekosystémů, které jsou označovány jako krkonošské botanické zahrádky.

### 3.2 Studované plochy


Jednotlivé klasifikace proběhly na dvou menších ohraničených plochách a v oblasti širšího území v zóně kryo–vegetační tundry na území Bílé louky (obr. 1). Již v 16. století využívali obyvatelé Luční boudy tuto oblast k pastvě hospodářských zvířat. Na konci 18. století byly místní travní plochy dokonce dvakrát ročně sečeny a pravidelně hnojeny. Hospodářské využití Bílé louky bylo zcela zakázáno až v 50. letech 20. století (KRNAP, 2010).



Obrázek 1: Studovaná oblast (zdroj: ČÚZK, 2022)

### 3.2.1 Plocha „U Luční boudy“

První a větší plocha s rozlohou 1,2 ha se nachází jen několik desítek metrů jihovýchodně od Luční boudy v nadmořské výšce 1420 m n. m. (obr. 2). Severní stranu plochy lemuje Stará Bucharova cesta. Kromě travních společenstev smilky tuhé (*Nardus stricta*), metlice trsnaté (*Deschampsia cespitosa*), bezkolence modrého (*Molinia caerulea*) a třtiny chloupkaté (*Calamagrostis villosa*) se ve východní části objevují také mokřady a rašeliniště společně s vodními plochami. Minoritně se zde vyskytují i alpské trávníky s dominantními druhy *Avenella flexuosa* a *Carex bigelowii*.




Obrázek 2: Plocha „U Luční boudy“, červencový termín, ortofoto z kamery Headwall Nano-Hyperspec

### 3.2.2 Plocha „U Zahrádky“

Tato menší plocha s rozlohou 1,1 ha leží cca o 700 metrů dále na jihovýchod od plochy „U Luční boudy“ v nadmořské výšce 1450 m n. m. (obr. 3). V tomto území se nacházejí stejná travní společenstva smilky tuhé (*Nardus stricta*), metlice trsnaté (*Deschampsia cespitosa*) a bezkolence modrého (*Molinia caerulea*). Jižní straně dominuje třtina chloupkatá (*Calamagrostis villosa*). Výrazněji zastoupeny jsou zde alpské trávníky v čele s *Avenella flexuosa*. Vyskytují se zde také samostatně rostoucí jedinci borovice kleče (*Pinus mugo*) a smrku ztepilého (*Picea abies*).






Obrázek 3: Plocha „U Zahrádky“, červencový termín, ortofoto z kamery Headwall Nano-Hyperspec



### 3.2.3 Plocha širšího území

Největší z ploch – plocha širšího území tundry (pro níž byla pořízena multispektrální UAV data v roce 2021) má rozlohou 1,2 km<sup>2</sup> a leží v nadmořské výšce od 1420 do 1550 m n. m. Území ohraničuje z jihu spojnice mezi Luční a Studniční horou. Ze severu poté Stará Bucharova cesta, Luční bouda a JZ cíp Úpského rašeliniště (obr. 4; obr. 5). Centrem snímku prochází severojižním směrem naučná stezka Krkonošská tundra. Na území se nacházejí stejné vegetační druhy jako na dvou malých plochách. Dále se zde vyskytují kamenná moře v těsné blízkosti Luční hory, vřes obecný (*Calluna vulgaris*) a brusnicová vegetace. Plocha širšího území byla klasifikována jednak jako celek a dále byly klasifikovány výřezy pro obě malé plochy, aby bylo možné porovnat výsledky klasifikací multispektrálních a hyperspektrálních dat.





Obrázek 4: Plocha širšího území, ortofoto z kamery MicaSense Altum



Obrázek 5: Plocha širšího území, ortofoto ze sensoru CASI

## 4 Použitá data a metodika

### 4.1 Použitá data a jejich předzpracování

#### 4.1.1 Hyperspektrální snímky z UAS

Ke snímkování ploch „U Luční boudy“ a „U Zahrádky“ byl využit bezpilotní dron Matrice 600 PRO s kamerou Headwall Nano-Hyperspec, která povrch snímá ve 270 spektrálních pásmech ve vlnových délkách od 400 do 1000 nm s rozlišením 2,2 nm na pixel. Snímky byly pořízeny týmem Laboratorní a obrazové spektroskopie TILSPEC ([www.tilspec.cz](http://www.tilspec.cz)) z katedry aplikované geoinformatiky a kartografie Přírodovědecké fakulty UK celkem v šesti termínech. Plocha „U Zahrádky“ byla nasnímana v červnu, červenci a srpnu v roce 2020. Plocha „U Luční boudy“ poté ve stejných měsících v roce 2021. Všechny získané snímky mají prostorové rozlišení 0,03 m.

Pro tuto práci byla poskytnuta již předzpracovaná data. Na všech snímcích byla provedena radiometrická a geometrická korekce s využitím softwaru SpectralView – Hyperspec v 3.1.0 (Červená a kol., 2020). Následně byly snímky ze všech termínů přetransformovány metodou Minimum Noise Fraction (MNF) v softwaru ENVI 5.5. Na základě hodnot „Eigenvalue“ z MNF grafu bylo u všech takto upravených snímků pro klasifikace vybráno prvních 10 pásem, která zahrnovala prakticky veškerou informaci obsaženou v původních datech, a v nichž byl redukován šum. Poté byly vytvořeny multitemporální kompozity. Pro plochy „U Luční boudy“ i „U Zahrádky“ se jednalo o kombinaci červnových, červencových a srpnových snímků po MNF transformaci. Celkový počet pásem byl tak 30, tedy 10 z každého termínu.

#### 4.1.2 Multispektrální snímky z UAS

Pro pořízení multispektrálních dat širšího území tundry bylo využito bezpilotní VTOL křídlo Atmos Marlyn s integrovanou kamerou MicaSense Altum. Ta měří hodnoty DN v 6 pásmech: modrém (475 nm ± 20 nm), zeleném (560 nm ± 20 nm), červeném (668 nm ± 10 nm), red edge (717 nm ± 10 nm), blízkém infračerveném (840 nm ± 40 nm) a termálním (8-14 um). Snímkování bylo zajištěno opět týmem TILSPEC 3. září 2021. Finální snímek má prostorové rozlišení 0,06 m.

Data byla nejprve předzpracována v software Geotagger, kde byly využity informace z modulu Post Processing Kinematic – PPK v kombinaci s korekčními daty RINEX. Tvorba ortofota probíhala v softwaru Agisoft Metashape s využitím radiometrické korekce na základě snímků pořízených před letem a po letu. Ve středu snímku se nepodařilo odstranit pruh zastínění (viz obr. 4). Data projevují odlišnou radiometrii v jednotlivých následných řadách (liší se hodnoty pro řady snímáné ve směru západ-východ a opačném). I přes tyto problémy byla data pro práci využita s tím, že se teprve s dodavatelem kamery Altum řeší, jak problémy korigovat.

#### 4.1.3 Hyperspektrální letecká data

Data byla pořízena 21. 9. 2020 ve spolupráci s CzechGlobe v Brně pomocí jejich letecké infrastruktury FLIS, konkrétně senzoru CASI. Atmosférickou a geometrickou korekci provedl dodavatel dat svými standardními metodami (CzechGlobe, 2022). Prostorové rozlišení snímku je 0,6 m a zahrnuje 48 pásem v rozmezí vlnových délek 383–1054 nm.

Snímek byl oříznut dle hranice širšího území tundry (viz obr. 1). Na výřezu byla provedena transformace MNF v programu ENVI 5.5. Z hodnot „Eigenvalue“ z MNF grafu bylo vybráno prvních 10 pásem, která byla využita pro následné klasifikace.

#### 4.1.3 Terénní data

Trénovací a validační polygony jednotlivých vegetačních tříd byly pro všechny tři plochy získány terénním průzkumem v průběhu let 2019 až 2021. Data nasbírali botanici z Botanického ústavu AV ČR, kteří k zaměření výskytu využili přístroj GPS s centimetrovou přesností. Data širšího území tundry byla následně rozšířena o novou kategorii stínů (pro multispektrální data z UAV a hyperspektrální letecká data zvláště) a u vodních ploch, *Pinus mugo* a *Picea abies* byly přidány nové polygony z důvodu nízké separability. Tyto polygony pro rozšíření datasetu byly získány z obrazu. Na ploše „U Luční boudy“ byl celkový podíl trénovacích a validačních polygonů vůči rozloze celého území 5,7 %. Na ploše „U Zahrádky“ 9,2 % a na širším území tundry podstatně méně, a to 0,7 %. Polygony pro všechny tři plochy byly rozděleny v poměru 1:2, kdy 1/3 polygonů byla využita pro natrénování klasifikátoru a 2/3 k validaci výsledné klasifikace. Charakteristiku vstupních trénovacích a validačních dat pro jednotlivé plochy shrnují tabulky 1-3.

Tabulka 1: Vstupní trénovací a validační data pro plochu „U Luční boudy“

<b>U Luční boudy</b>			
<b>celková plocha polygonů: 694,39 m<sup>2</sup></b>		<b>celkový počet polygonů: 404</b>	
<b>třída</b>	<b>rozloha ploch (m<sup>2</sup>)</b>	<b>počet trénovacích polygonů</b>	<b>počet validačních polygonů</b>
Carex bigelowii	0,82	2	2
Molinia caerulea	183,25	37	63
Deschampsia cespitosa	291,01	43	83
mokřady a rašeliniště	23,51	20	39
Nardus stricta	178,02	29	59
Calamagrostis villosa	0,95	3	3
vodní plochy	2,77	6	8
Avenella flexuosa	14,06	3	4

Tabulka 2: Vstupní trénovací a validační data pro plochu „U Zahrádky“

U Zahrádky			
celková plocha polygonů: 893,79 m <sup>2</sup>		celkový počet polygonů: 151	
třída	rozloha ploch (m <sup>2</sup> )	počet trénovacích polygonů	počet validačních polygonů
Avenella flexuosa	66,66	4	7
Calamagrostis villosa	440,06	15	29
Carex bigelowii	2,34	1	2
Deschampsia cespitosa	27,42	6	8
Pinus mugo	12,50	1	1
Molinia caerulea	1,13	2	2
Nardus stricta	328,36	23	43
Picea abies	15,33	3	4

Tabulka 3: Vstupní trénovací a validační data pro širší území tundry

Širší území			
celková plocha polygonů: 8049,47m <sup>2</sup> + stíny		celkový počet polygonů : 2602 + stíny	
třída	rozloha ploch (m <sup>2</sup> )	počet trénovacích polygonů	počet validačních polygonů
stíny (pouze pro HS data)	76,59	18	36
stíny (pouze pro MS data)	196,57	33	66
Molinia caerulea	666,48	83	164
Vaccinium myrtillus	228,78	27	56
cesta	223,76	19	36
kamenná moře	477,62	15	31
Pinus mugo	1573,83	49	99
Deschampsia cespitosa	1135,11	105	210
mokřady a rašeliniště	314,36	103	206
Nardus stricta	1216,28	132	262
Picea abies	148,07	42	85
Calamagrostis villosa	1209,75	62	125
vodní plochy	28,31	14	26
Calluna vulgaris	331,18	63	126
Avenella flexuosa	389,14	117	235
Carex bigelowii	106,81	37	73

## 4.2 Klasifikované kategorie vegetačního pokryvu

### 4.2.1 Smilka tuhá (*Nardus stricta*)

Tato vytrvalá travina patří do čeledi lipnicovitých dorůstá do výšky 30 cm (obr. 6). Kvete v období května a června. Jedná se o dominantní druh trávníků alpínských na silikátech, subalpínských a horských acidofilních a submontánních smilkových (Pladias, 2022). V Krkonoších je smilka tuhá dominantním druhem travní vegetace alpínského bezlesí a v mozaice s klečovými porosty pokrývá



ve spodním a svrchním alpínském stupni české strany Krkonoš rozlohu téměř 2 300 ha (Štursa, Wild, 2014).



Obrázek 6: smilka tuhá (*Nardus stricta*) (zdroj: Wikipedia commons)

#### 4.2.2 Metlice trsnatá (*Deschampsia cespitosa*)

Další zástupce čeledi lipnicových dosahuje výšky 60 až 150 cm (obr. 7). Rostlina kvete v období od června do října. Dominantně se vyskytuje na aluviálních loukách nížinných řek nebo na střídavě vlhkých bezkolencových loukách (Pladias, 2022). Metlice je velmi plastický druh s velkou ekologickou amplitudou. V alpínské tundře Krkonoš tvoří mnoho morfologicky odlišných klonů. Většina z nich je velmi úspěšná v expanzi do polopřirozených tundrových společenstev (Fabšičová, 2004).



Obrázek 7: metlice trsnatá (*Deschampsia cespitosa*) (zdroj: Wikipedia commons)

#### 4.2.3 Bezkolenec modrý (*Molinia caerulea*)

Bezkolenec modrý je vytrvalá bylina spadající do čeledi lipnicovitých. Dorůstá výšky od 15 do 150 cm (obr. 8). Kvete mezi červnem a zářím. Primárně roste na střídavě vlhkých bezkolencových loukách a vápnatých slatiništích (Pladias, 2022). V Krkonoších došlo k výraznému rozšíření bezkolence v posledních 50 letech po ukončení sečby subalpínských trávníků. V minulosti dominoval pouze na okrajích pramenišť a rašelinišť a ve sněhových korytech, kde se sníh držel velmi dlouho (Hejcman a kol., 2010).



Obrázek 8: bezkolenec modrý (*Molinia caerulea*) (zdroj: Wikipedia commons)

#### 4.2.4 Třtina chloupkatá (*Calamagrostis villosa*)

Tato lipnicovitá vytrvalá rostlina dorůstá výšky 50 až 130 cm (obr. 9). Kvete od června do srpna. Hlavními místy výskytu jsou subalpínské listnaté křoviny, kosodřeviny a acidofilní i vysokobylinné smrčiny (Pladias, 2022). Třtina je v Krkonoších expanzivním druhem. Podle Hejcmana a kol. (2009) může za její výrazné rozšíření až do oblasti subalpínských pastvin ukončení zemědělského hospodaření a zvýšení atmosférické depozice dusíku.



Obrázek 9: třtina chloupkatá (*Calamagrostis villosa*) (zdroj: Wikipedia commons)

#### 4.2.5 Borovice kleč (*Pinus mugo*)

Borovice kleč je jednodomá kosodřevina dorůstající do výšky od 30 do 300 cm (obr. 10). Kvete v období od června do července. Běžně se vyskytuje v horských oblastech nad hranicí lesa a na vrchovištích (Pladias, 2022). Klečové porosty tvoří významnou část keřových společenstev ve spodním a částečně i svrchním alpínském stupni Krkonoš. Jde o velmi houževnatou dřevinu, která vzhledem ke své životní strategii bez problémů snáší extrémní růstové podmínky panující nad alpínskou hranicí lesa (Štursa, Wild, 2014).



Obrázek 10: borovice kleč (*Pinus mugo*) (zdroj: Wikipedia commons)

#### 4.2.6 Smrk ztepilý (*Picea abies*)

Tento stálezelený jehličnatý strom dorůstá v ideálních podmínkách výšky až 50 metrů (obr. 11). Kvete od dubna do června. Smrk ztepilý je aktuálně běžným druhem českých lesů (Pladias, 2022). V Krkonoších se původní horské smrčiny zachovaly v úzkém pruhu kolem alpínské hranice lesa a na úbočích karů. Průměrné stáří těchto porostů je obvykle uváděno mezi 120–200 roky (KRNAP, 2012).





Obrázek 11: smrk ztepilý (*Picea abies*) (autor: Lucie Červená)

#### 4.2.7 Alpínské trávníky s dominancí metličky křivolaké (*Avenella flexuosa*)


Metlička křivolaká je vytrvalá travina z čeledi lipnicovitých. Dorůstá výšky od 30 do 70 cm a kvete v období od června do srpna (obr. 12). Dominantně se vyskytuje na alpínských, subalpínských a horských acidofilních trávnících. Běžně roste také v acidofilních doubravách, boreokontinentálních borech a smrkových monokulturách (Pladias, 2022). V této třídě jsou minoritně zastoupeny také *Anthoxanthum alpinum* či *Carex bigelowii*.



Obrázek 12: metlička křivolaká (*Avenella flexuosa*) (zdroj: Wikipedia commons)

#### 4.2.8 Alpínské trávníky s dominancí ostřice bigelowovy (*Carex bigelowii*)

*Carex bigelowii* je jednoděložná vytrvalá rostlina spadající do čeledi šáchorovitých (obr. 13). Standardně dorůstá do výšky 30 cm a kvete mezi červnem a červencem. V Česku je rozšířen pouze v oblastech alpínských trávníků na silikátech (Pladias, 2022).



Obrázek 13: ostřice bigelowova (*Carex bigelowii*) (zdroj: Wikipedia commons)

#### 4.2.9 Mokřady a rašeliniště

V této třídě (obr. 14) je zastoupeno více druhů rostlin vyskytujících se v různých poměrech. Jedná se primárně o *Carex limosa*, *Eriophorum angustifolium*, *Eriophorum vaginatum*, *Juncus filiformis*, *Sphagnum* sp. či *Trichophorum cespitosum*.



Obrázek 14: mokřady a rašeliniště (autor: Lucie Kupková)

#### 4.2.10 Vřesové porosty

V této třídě je nejvíce rozšířena *Calluna vulgaris* (obr. 15). Částečně je zastoupena i další keříčková vegetace z čeledi vřesovcovitých.



Obrázek 15: vřes obecný (*Calluna vulgaris*) (zdroj: Wikipedia commons)

#### 4.2.11 Subalpínská brusnicová vegetace

Dominantním druhem v této kategorii je porost *Vaccinium myrtillus* (obr. 16). V menší míře se objevuje také jiná keříčková vegetace z čeledi vřesovcovitých.



Obrázek 16: brusnice borůvka (*Vaccinium myrtillus*) (zdroj: Wikipedia commons)

#### 4.2.12 Kamenná moře

Tato třída představuje souvislé plochy pokryté kameny či většími balvany, jejichž rozpad z větších celků způsobilo mrazové zvětrávání (obr. 17). Primárním místem výskytu je okolí Luční hory. Kameny jsou většinou pokryty různými druhy lišejníků.





Obrázek 17: kamenná moře (autor: Lucie Červená)

#### 4.2.13 Vodní plochy

Jedná se o plochy s viditelnou vodní hladinou (obr. 18).



Obrázek 18: vodní plochy (autor: Lucie Kupková)

### 4.3 Metody analýzy dat a hodnocení přesnosti výsledků

Ke klasifikaci v práci využitých dat uvedených výše byly aplikovány pixelové klasifikační metody maximální věrohodnosti (MLC), Random forest (RF), Support vector machine (SVM) a objektově orientované klasifikace (OBIA) s využitím klasifikátoru SVM. Většina klasifikací probíhala v softwaru ENVI 5.5, klasifikace Random forest pak převážně v R 4.1.3 a v některých případech v ArcGIS Pro. Nastavení jednotlivých klasifikátorů vycházelo do značné míry ze zkušeností týmu TILSPEC s klasifikací vegetace v krkonošské tundře (Kupková a kol., 2021). Před aplikováním klasifikačních metod byla provedena analýza separability trénovacích dat.

#### 4.3.1 Testování separability trénovacích dat

Pro všechny tři datasey trénovacích polygonů byl separátně pro multispektrální i hyperspektrální data proveden výpočet spektrální separability pro všechny dvojice klasifikovaných tříd. K výpočtu byl využit software ENVI, ve kterém byla vypočtena Jeffries-Matusitova vzdálenost a Transformed

Divergence index. Výsledkem analýzy byla hodnota pohybující se od 0 do 2. Výsledek s hodnotou vyšší než 1,9 představoval výbornou oddělitelnost. Naopak hodnoty pohybující se kolem 1 a méně znamenaly velmi špatnou separabilitu (L3 Harris Geospatial, 2022).

#### 4.3.2 Metoda maximální věrohodnosti

Tato metoda byla u všech tří ploch využita několikrát z důvodu ladění a úprav trénovacích polygonů. Průběh klasifikace byl totiž rychlý a umožňoval časté opakování. Výpočet byl proveden v softwaru ENVI s výchozím nastavením.

#### 4.3.3 Metoda Random forest v softwaru R

Nejprve bylo do programu naimportováno několik doplňkových knihoven a pluginů. Následně byl spuštěn skript převzatý od týmu TILSPEC, jenž jej vytvořil pro potřeby klasifikací v projektech, kterými se v minulosti zabýval. Pro všechny pokusy bylo nastavení vstupních parametrů stejné. Počet rozhodovacích stromů (ntree) byl ponechán na 1000. Výpočet důležitosti prvku pro další analýzu byl nastaven na true (Importance=TRUE). Tyto parametry se osvědčily jako vhodné pro dosažení maximální přesnosti v minulých analýzách vegetace tundry (Kupková a kol., 2021).

#### 4.3.4 Metoda Random forest v softwaru ArcGIS Pro

K natrénování metody Random forest byla použita funce Train Random Trees Classifier. Maximální počet rozhodovacích stromů (Max Number of Trees) byl nastaven na 1000, počet rozhodovacích pravidel každého stromu (Max Tree Depth) na 300 a počet vzorků pro definování jednotlivých tříd (Max Number of Samples Per Class) na 1000. V nastavení segmentace byly pro výpočet zvoleny všechny atributy.

#### 4.3.5 Metoda Support vector machine

K výpočtu byl použit software ENVI. Kernel Type byl nastaven na Radial Basis Function.

#### 4.3.6 Metoda objektivě orientované klasifikace

Pro výpočet objektivě orientované klasifikace byl využit nástroj Example Based Feature Extraction Workflow v softwaru ENVI. V nastavení segmentace byl vybrán algoritmus „Edge“ s hodnotou Scale Level na 20. Pro fázi slučování byl zvolen algoritmus „Full Lambda Schedule“ s hodnotou Merge Level na 30. Velikost kernelu byla nastaven na hodnotu 5. Pro následnou klasifikaci byl použit algoritmus SVM. Toto nastavení bylo převzato od Kupkové a kol. (2021), která stejný postup použila pro klasifikaci plochy „Bílá louka“, která je z vegetačního hlediska velmi podobná studovaným plochám v této práci.

#### 4.3.7 Hodnocení přesnosti výsledných klasifikací

Přesnost výsledných klasifikací byla hodnocena celkem třemi způsoby. Metodou statistickou (celková, uživatelská a zpracovatelská přesnost) vypočtenou pomocí chybové matice (viz. kapitola 2.4). Dále byla



hodnocena prostorová shoda klasifikovaných kategorií pomocí překryvů klasifikačních výstupů podle vzorce  $MA_t = M / (A_1 + A_2 - M)$ , kde M je plocha, ve které se obě klasifikační metody shodují a  $A_1$  a  $A_2$  jsou celkové plochy, na kterých byla třída jednotlivými metodami klasifikována (Kupková a kol., 2022). Třetí metodou bylo porovnávání rozloh tříd mezi různými klasifikačními výstupy.

## 5 Výsledky

### 5.1 Výsledky plochy „U Luční boudy“ s využitím hyperspektrálních dat

U všech čtyř metod bylo nejlepších výsledků dosaženo pro multitemporální kompozity z června, července a srpna (výsledky uvedené v jednotlivých kapitolách jsou právě pro tento kompozit). Z důležitých travních druhů byly dosaženy zpracovatelské a uživatelské přesnosti vyšší než 90 % pro třídy *Deschampsia cespitosa*, *Nardus stricta* a *Molinia caerulea*, a to u pixelových metod RF a SVM. U OBIA byl trend stejný kromě třídy *Molinia caerulea*, jejíž přesnost byla podprůměrná. Všechny klasifikované kategorie byly z hlediska vypočtené separability výborně rozeznatelné kromě dvojice tříd *Nardus stricta* a *Avenella flexuosa* (1,68).

#### 5.1.1 Maximální pravděpodobnost

Při použití standardních trénovacích polygonů byl v SZ části snímku vyklasifikován ostrý přechod způsobený rozdílnými světelnými podmínkami v době pořízení některých snímků. Tento efekt byl znatelný pouze u metody MLC. K vyřešení problému byla použita indexace, kdy byl trénovací dataset rozdělen na dvě části a po dokončení klasifikace byly třídy opět sloučeny. Nejlepšího výsledku s celkovou přesností 92,26 % bylo dosaženo právě použitím indexace (tab. 4). V porovnání s jinými metodami byla s nadprůměrně dobrými hodnotami přesností klasifikována *Calamagrostis villosa*. Zajímavostí je rozloha u *Deschampsia cespitosa*, která je ve srovnání s dalšími metodami větší v průměru o 6 procentních bodů na úkor rozlohy u *Nardus stricta*.

Tabulka 4: Hodnocení přesnosti „U Luční boudy“ s využitím hyperspektrálních dat metodou MLC

U Luční boudy			
celková přesnost: 92,26 %		Kappa koeficient: 0,89	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Carex bigelowii	58,55 %	47,64 %	0,32 %
Molinia caerulea	94,37 %	96,96 %	15,00 %
Deschampsia cespitosa	98,17 %	95,46 %	52,18 %
mokřady a rašeliniště	88,92 %	65,29 %	7,21 %
Nardus stricta	82,42 %	93,60 %	22,72 %
Calamagrostis villosa	52,57 %	81,71 %	0,22 %
vodní plochy	95,53 %	91,16 %	0,11 %
Avenella flexuosa	70,58 %	44,28 %	2,24 %

### 5.1.2 Random forest

S využitím klasifikátoru RF bylo dosaženo celkové přesnosti 94,72 % (tab. 5). Za zmínku stojí velmi rozdílný výsledek zpracovatelské a uživatelské přesnosti u *Calamagrostis villosa*. Důvodem může být velmi malá rozloha třídy, která byla výrazně menší než u jiných metod.

Tabulka 5: Hodnocení přesnosti „U Luční boudy“ s využitím hyperspektrálních dat metodou RF

U Luční boudy			
celková přesnost: 94,72 %		Kappa koeficient: 0,92	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Carex bigelowii	31,45 %	100,00 %	0,01 %
Molinia caerulea	96,53 %	96,89 %	18,24 %
Deschampsia cespitosa	98,58 %	97,18 %	46,63 %
mokřady a rašeliniště	72,35 %	88,39 %	2,67 %
Nardus stricta	93,65 %	90,73 %	31,88 %
Calamagrostis villosa	9,01 %	93,51 %	0,04 %
vodní plochy	99,81 %	87,29 %	0,14 %
Avenella flexuosa	50,12 %	67,84 %	0,39 %

### 5.1.3 Support vector machine

Celková přesnost 94,24 % u metody SVM je velmi podobná výsledku klasifikace RF. Hodnoty zpracovatelské a uživatelské přesnosti u jednotlivých tříd jsou ale mnohem kompaktnější a nevykazují žádný extrémní výkyv (tab. 6).

Tabulka 6: Hodnocení přesnosti „U Luční boudy“ s využitím hyperspektrálních dat metodou SVM

U Luční boudy			
celková přesnost: 94,24 %		Kappa koeficient: 0,92	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Carex bigelowii	59,86 %	74,01 %	0,15 %
Molinia caerulea	96,09 %	97,21 %	16,61 %
Deschampsia cespitosa	98,23 %	97,52 %	45,15 %
mokřady a rašeliniště	73,61 %	86,18 %	3,10 %
Nardus stricta	92,55 %	90,48 %	32,80 %
Calamagrostis villosa	43,55 %	28,41 %	0,82 %
vodní plochy	98,04 %	85,43 %	0,16 %
Avenella flexuosa	46,37 %	51,38 %	1,21 %

### 5.1.4 Objektově orientovaná klasifikace

Metoda OBIA dosáhla nejlepší celkové přesnosti ze všech metod, a to 95,37 % (tab. 7). V porovnání s ostatními metodami dopadla podprůměrně přesnost u *Molinia caerulea*. Výsledky dalších tříd byly velmi dobré.

Tabulka 7: Hodnocení přesnosti „U Luční boudy“ s využitím hyperspektrálních dat metodou OBIA

U Luční boudy			
celková přesnost: 95,37 %		Kappa koeficient: 0,93	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Carex bigelowii	96,21 %	98,69 %	0,17 %
Molinia caerulea	73,04 %	84,99 %	16,33 %
Deschampsia cespitosa	98,98 %	98,33 %	46,79 %
mokřady a rašeliniště	82,47 %	88,00 %	3,80 %
Nardus stricta	92,06 %	93,68 %	30,45 %
Calamagrostis villosa	64,08 %	27,19 %	0,74 %
vodní plochy	96,88 %	87,32 %	0,15 %
Avenella flexuosa	73,95 %	53,27 %	1,58 %

## 5.2 Výsledky plochy „U Zahrádky“ s využitím hyperspektrálních dat

U všech čtyř metod bylo nejlepších výsledků dosaženo pro multitemporální kompozit z června, července a srpna (výsledky uvedené v jednotlivých kapitolách jsou právě pro tento kompozit). Skvělých výsledků zpracovatelské a uživatelské přesnosti dosáhly třídy *Calamagrostis villosa* a *Nardus stricta*, a to u všech metod klasifikace. Z hlediska separability byla hůře rozeznatelná pouze kombinace tříd *Nardus stricta* a *Avenella flexuosa* (1,64).

### 5.2.1 Maximální pravděpodobnost

S použitím klasifikátoru MLC bylo dosaženo celkové přesnosti 90,27 % (tab. 8). Špatné výsledky byly zaznamenány u třídy *Carex bigelowii*. Naopak výborně dopadly třídy *Molinia caerulea* a *Picea abies*. Zajímavostí jsou stejně jako u výsledků v kapitole 5.1.1 výrazné odchylky v rozlohách tříd v porovnání s výsledky jiných metod. Největším rozdílem je průměrně o 10 procentních bodů nižší rozloha třídy *Nardus stricta* na úkor tříd *Avenella flexuosa* a *Deschampsia cespitosa*.

Tabulka 8: Hodnocení přesnosti „U Zahrádky“ s využitím hyperspektrálních dat metodou MLC

U Zahrádky			
celková přesnost: 90,27 %		Kappa koeficient: 0,85	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Avenella flexuosa	75,39 %	46,56 %	27,96 %
Calamagrostis villosa	99,26 %	99,95 %	27,52 %
Carex bigelowii	20,02 %	15,81 %	0,17 %
Deschampsia cespitosa	78,58 %	51,91 %	11,65 %
Pinus mugo	98,01 %	94,40 %	0,20 %
Molinia caerulea	90,87 %	95,43 %	0,09 %
Nardus stricta	82,36 %	97,47 %	31,75 %
Picea abies	91,10 %	97,09 %	0,66 %

### 5.2.2 Random forest

Metodou RF byla plocha „U Zahrádky“ vyklasifikována s celkovou přesností 93,05 % (tab. 9). Zajímavostí je významný rozdíl ve zpracovatelské a uživatelské přesnosti kategorie *Molinia caerulea*.

Tabulka 9: Hodnocení přesnosti „U Zahrádky“ s využitím hyperspektrálních dat metodou RF

U Zahrádky			
celková přesnost: 93,05 %		Kappa koeficient: 0,88	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Avenella flexuosa	72,65 %	57,83 %	21,70 %
Calamagrostis villosa	99,40 %	99,68 %	28,49 %
Carex bigelowii	32,92 %	34,34 %	0,16 %
Deschampsia cespitosa	73,16 %	75,19 %	4,10 %
Pinus mugo	97,37 %	83,36 %	0,31 %
Molinia caerulea	57,68 %	100,00 %	0,03 %
Nardus stricta	91,58 %	95,03 %	44,72 %
Picea abies	73,38 %	96,51 %	0,49 %

### 5.2.3 Support vector machine

U SVM bylo dosaženo celkové přesnosti 94,07 %. Stejně jako v kapitole 5.1.3 jsou výsledky bez výrazných výkyvů. Nadprůměrně dobře byla vyklasifikována třída *Molinia caerulea* (tab. 10).

Tabulka 10: Hodnocení přesnosti „U Zahrádky“ s využitím hyperspektrálních dat metodou SVM

U Zahrádky			
celková přesnost: 94,07 %		Kappa koeficient: 0,90	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Avenella flexuosa	70,46 %	68,79 %	21,06 %
Calamagrostis villosa	99,22 %	99,87 %	27,13 %
Carex bigelowii	38,36 %	23,69 %	0,30 %
Deschampsia cespitosa	75,65 %	68,37 %	6,24 %
Pinus mugo	97,35 %	83,19 %	0,32 %
Molinia caerulea	81,88 %	96,42 %	0,09 %
Nardus stricta	94,86 %	95,22 %	44,30 %
Picea abies	69,13 %	94,26 %	0,56 %

### 5.2.4 Objektově orientovaná klasifikace

Nejllepší celkové přesnosti bylo opět dosaženo metodou OBIA s hodnotou 94,95 % (tab. 11). Kromě třídy *Molinia caerulea* byly důležité travní druhy vyklasifikovány nadprůměrně dobře. Horších výsledků dosáhla třída *Picea abies*.

Tabulka 11: Hodnocení přesnosti „U Zahrádky“ s využitím hyperspektrálních dat metodou OBIA

U Zahrádky			
celková přesnost: 94,95 %		Kappa koeficient: 0,92	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Avenella flexuosa	80,09 %	70,16 %	24,15 %
Calamagrostis villosa	99,73 %	99,71 %	28,76 %
Carex bigelowii	49,02 %	32,47 %	0,25 %
Deschampsia cespitosa	80,97 %	74,21 %	5,30 %
Pinus mugo	99,28 %	82,73 %	0,29 %
Molinia caerulea	68,12 %	100,00 %	0,04 %
Nardus stricta	94,20 %	97,23 %	40,76 %
Picea abies	67,93 %	98,92 %	0,45 %

### 5.3 Výsledky plochy „U Luční boudy“ s využitím multispektrálních dat

Pro všechny čtyři metody klasifikace v této kapitole byl využit stejný dataset trénovacích a validačních polygonů jako pro hyperspektrální data v kapitole 5.1. Výsledky zpracovatelské a uživatelské přesnosti u čtyř hlavních travních druhů byly horší než s využitím hyperspektrálních dat. Z důležitých travních druhů dosahovala nejlepšího výsledku třída *Deschampsia cespitosa*. Při hodnocení separability byla špatně rozeznatelná kombinace tříd *Nardus stricta* – *Avenella flexuosa* (0,53) a z důležitých travních druhů také dvojice *Molinia caerulea* a *Deschampsia cespitosa* (0,91) či *Nardus stricta* a *Calamagrostis villosa* (1,07).

#### 5.3.1 Maximální pravděpodobnost

Nejhorších výsledků bylo dosaženo metodou MLC s celkovou přesností 53,43 % (tab. 12). Největší nesoulady v porovnání s dalšími metodami byly u rozloh jednotlivých tříd. Nejzásadnějším rozdílem byla více než 17% rozloha u *Calamagrostis villosa*, která se ve výsledcích u jiných metod téměř nevyskytuje a u SVM nebyla dokonce ani vyklasifikována. Velké rozdíly byly zjištěny také u tříd mokřady a rašeliniště, vodní plochy a *Avenella flexuosa*. Rozlohy těchto tříd byly vyšší nejvíce na úkor třídy *Deschampsia cespitosa*.

Tabulka 12: Hodnocení přesnosti „U Luční boudy“ s využitím multispektrálních dat metodou MLC

U Luční boudy			
celková přesnost: 53,43 %		Kappa koeficient: 0,40	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Carex bigelowii	41,85 %	3,49 %	2,69 %
Molinia caerulea	67,15 %	69,86 %	16,97 %
Deschampsia cespitosa	51,78 %	80,55 %	30,61 %
mokřady a rašeliniště	47,35 %	28,54 %	6,25 %
Nardus stricta	42,74 %	76,89 %	13,92 %
Calamagrostis villosa	61,82 %	0,76 %	17,15 %
vodní plochy	41,19 %	5,68 %	4,22 %
Avenella flexuosa	62,15 %	13,65 %	8,19 %

### 5.3.2 Random forest

S využitím klasifikátoru RF bylo dosaženo celkové přesnosti 78,68 % (tab. 13). Nadprůměrně dobře byly vyklasifikovány vodní plochy s uživatelskou přesností 94,56 %. Velké rozdíly uživatelské/zpracovatelské přesnosti a rozlohy jsou znatelné u třídy *Carex bigelowii*.

Tabulka 13: Hodnocení přesnosti „U Luční boudy“ s využitím multispektrálních dat metodou RF

U Luční boudy			
celková přesnost: 78,68 %		Kappa koeficient: 0,68	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
<i>Carex bigelowii</i>	1,09 %	100,00 %	0,01 %
<i>Molinia caerulea</i>	77,98 %	81,65 %	19,29 %
<i>Deschampsia cespitosa</i>	88,34 %	81,38 %	54,60 %
mokřady a rašeliniště	27,59 %	71,35 %	1,75 %
<i>Nardus stricta</i>	77,88 %	72,36 %	24,03 %
<i>Calamagrostis villosa</i>	0,45 %	33,33 %	0,01 %
vodní plochy	22,90 %	94,56 %	0,12 %
<i>Avenella flexuosa</i>	6,62 %	28,06 %	0,19 %

### 5.3.3 Support vector machine

Výsledky metody SVM s celkovou přesností 74,80 % byly méně přesné než u metody RF, ale výrazně přesnější než výsledky u metody MLC. Největší zajímavostí je nulová rozloha třídy *Calamagrostis villosa*, která nebyla vůbec vyklasifikována (tab. 14). Při porovnání s metodou RF dopadly výrazně lépe pouze výsledky u třídy *Avenella flexuosa*.

Tabulka 14: Hodnocení přesnosti „U Luční boudy“ s využitím multispektrálních dat metodou SVM

U Luční boudy			
celková přesnost: 74,80 %		Kappa koeficient: 0,62	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
<i>Carex bigelowii</i>	14,13 %	23,01 %	0,12 %
<i>Molinia caerulea</i>	71,25 %	76,73 %	19,28 %
<i>Deschampsia cespitosa</i>	85,42 %	75,06 %	54,96 %
mokřady a rašeliniště	30,32 %	59,64 %	2,53 %
<i>Nardus stricta</i>	71,99 %	76,91 %	22,29 %
<i>Calamagrostis villosa</i>	0,00 %	0,00 %	0,00 %
vodní plochy	27,68 %	76,36 %	0,17 %
<i>Avenella flexuosa</i>	26,60 %	31,98 %	0,65 %

### 5.3.4 Objektově orientovaná klasifikace

Zdaleka nejlepších výsledků bylo dosaženo metodou OBIA s celkovou přesností 85,42 %. Téměř u všech tříd byly získány i nejlepší výsledky zpracovatelské a uživatelské přesnosti (tab. 15).

Tabulka 15: Hodnocení přesnosti „U Luční boudy“ s využitím multispektrálních dat metodou OBIA

U Luční boudy			
celková přesnost: 85,42 %		Kappa koeficient: 0,78	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Carex bigelowii	26,09 %	52,17 %	0,06 %
Molinia caerulea	85,59 %	89,06 %	19,46 %
Deschampsia cespitosa	93,32 %	89,02 %	47,73 %
mokřady a rašeliniště	56,27 %	67,07 %	3,92 %
Nardus stricta	82,15 %	81,29 %	27,63 %
Calamagrostis villosa	27,27 %	41,38 %	0,20 %
vodní plochy	32,62 %	35,68 %	0,40 %
Avenella flexuosa	26,86 %	38,95 %	0,60 %

## 5.4 Výsledky plochy „U Zahrádky“ s využitím multispektrálních dat

Pro všechny čtyři metody klasifikace v této kapitole byl využit stejný dataset trénovacích a validačních polygonů jako pro hyperspektrální data v kapitole 5.2. U všech metod byla třída *Molinia caerulea* vyklasifikována s nulovou přesností. Podprůměrná přesnost byla zaznamenána u kategorie *Deschampsia cespitosa*. Velmi dobrých výsledků zpracovatelské a uživatelské přesnosti naopak dosáhly třídy *Calamagrostis villosa* a *Nardus stricta*. Z hlediska separability byly hůře rozeznatelné pouze kombinace tříd *Avenella flexuosa* – *Deschampsia cespitosa* (0,76), *Deschampsia cespitosa* – *Molinia caerulea* (1,42) a *Avenella flexuosa* – *Molinia caerulea* (1,55).

### 5.4.1 Maximální pravděpodobnost

S celkovou přesností 86,95 % byla metoda MLC i zde nejméně přesná (tab. 16). Největší rozdíly v porovnání s dalšími metodami byly zaznamenány u rozlohy tříd. A to konkrétně u *Nardus stricta*, která je v tomto případě zastoupená průměrně o 8 % méně než u dalších metod klasifikace. U třídy *Deschampsia cespitosa* je naopak rozloha výrazně vyšší, avšak zpracovatelská přesnost dopadla v tomto případě nejlépe ze všech metod.

Tabulka 16: Hodnocení přesnosti „U Zahrádky“ s využitím multispektrálních dat metodou MLC

U Zahrádky			
celková přesnost: 86,95 %		Kappa koeficient: 0,79	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
Avenella flexuosa	29,45 %	41,82 %	14,48 %
Calamagrostis villosa	98,68 %	99,48 %	28,51 %
Carex bigelowii	70,61 %	57,86 %	0,46 %
Deschampsia cespitosa	60,81 %	30,09 %	19,99 %
Pinus mugo	76,36 %	91,99 %	0,30 %
Molinia caerulea	0,00 %	0,00 %	3,87 %
Nardus stricta	85,78 %	96,06 %	31,31 %
Picea abies	82,24 %	88,16 %	1,08 %

#### 5.4.2 Random forest

Klasifikace s využitím metody RF proběhla s celkovou přesností 88,03 % (tab. 17). Podprůměrných výsledků bylo dosaženo u třídy *Picea abies*.

Tabulka 17: Hodnocení přesnosti „U Zahrádky“ s využitím multispektrálních dat metodou RF

U Zahrádky			
celková přesnost: 88,03 %		Kappa koeficient: 0,81	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
<i>Avenella flexuosa</i>	54,30 %	48,75 %	19,14 %
<i>Calamagrostis villosa</i>	97,04 %	97,89 %	31,55 %
<i>Carex bigelowii</i>	89,39 %	80,07 %	0,45 %
<i>Deschampsia cespitosa</i>	24,70 %	20,17 %	7,90 %
<i>Pinus mugo</i>	84,75 %	85,85 %	0,41 %
<i>Molinia caerulea</i>	0,00 %	0,00 %	0,14 %
<i>Nardus stricta</i>	89,94 %	93,45 %	39,29 %
<i>Picea abies</i>	59,08 %	51,57 %	1,12 %

#### 5.4.3 Support vector machine

Metodou SVM bylo dosaženo celkové přesnosti 91,52 % (tab. 18). Kromě horších výsledků u třídy *Deschampsia cespitosa* nevykazují přesnosti jednotlivých tříd výrazné rozdíly.

Tabulka 18: Hodnocení přesnosti „U Zahrádky“ s využitím multispektrálních dat metodou SVM

U Zahrádky			
celková přesnost: 91,52 %		Kappa koeficient: 0,86	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
<i>Avenella flexuosa</i>	65,07 %	53,24 %	22,35 %
<i>Calamagrostis villosa</i>	99,00 %	98,98 %	31,06 %
<i>Carex bigelowii</i>	91,22 %	83,86 %	0,60 %
<i>Deschampsia cespitosa</i>	17,20 %	23,50 %	3,34 %
<i>Pinus mugo</i>	86,20 %	91,25 %	0,40 %
<i>Molinia caerulea</i>	0,00 %	0,00 %	0,24 %
<i>Nardus stricta</i>	94,40 %	95,21 %	40,93 %
<i>Picea abies</i>	80,47 %	98,11 %	1,08 %

#### 5.4.4 Objektově orientovaná klasifikace

Nejlepších výsledků bylo opět dosaženo metodou OBIA s celkovou přesností 93,96 %. Téměř u všech tříd byly získány i nejlepší výsledky zpracovatelské a uživatelské přesnosti (tab. 19).



Tabulka 19: Hodnocení přesnosti „U Zahrádky“ s využitím multispektrálních dat metodou OBIA

U Zahrádky			
celková přesnost: 93,96 %		Kappa koeficient: 0,90	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
<i>Avenella flexuosa</i>	77,47 %	68,94 %	19,66 %
<i>Calamagrostis villosa</i>	99,25 %	99,32 %	31,16 %
<i>Carex bigelowii</i>	99,39 %	97,40 %	0,52 %
<i>Deschampsia cespitosa</i>	41,22 %	38,98 %	8,78 %
<i>Pinus mugo</i>	90,04 %	90,19 %	0,26 %
<i>Molinia caerulea</i>	0,00 %	0,00 %	0,30 %
<i>Nardus stricta</i>	95,95 %	97,68 %	38,25 %
<i>Picea abies</i>	78,39 %	98,90 %	1,07 %

## 5.5 Výsledky pro širší území tundry s využitím hyperspektrálních dat

Výsledky zpracovatelské a uživatelské přesnosti ochranářsky důležitých travních druhů vycházely v porovnání s ostatními vegetačními druhy nadprůměrně dobře. Nejlepších výsledků dosahovala třída *Calamagrostis villosa*. Při porovnání separability byla zjištěna špatná rozpoznatelnost kategorie *Carex bigelowii* vůči všem ochranářsky důležitým travním druhům (1,4–1,55). Hůře rozeznatelná byla také třída mokřadů a rašelinišť s *Molinia caerulea* (1,26) a *Carex bigelowii* (1,34).

### 5.5.1 Maximální pravděpodobnost

Metodou MLC bylo pro letecká hyperspektrální data ze sensoru CASI s prostorovým rozlišením 0,6 m a spektrálním rozlišením 48 pásem dosaženo celkové přesnosti 72,16 % (tab. 20). V porovnání s dalšími metodami jde sice o nejhorší výsledek, ale hodnoty zpracovatelské a uživatelské přesnosti u většiny kategorií nevykazují zásadní rozdíly. Podprůměrně dopadly výsledky u tříd *Picea abies* a *Avenella flexuosa*. Problematické jsou výsledky u třídy *Carex bigelowii*. Ten byl touto metodou vyklasifikován na 15,04 % území a v porovnání s dalšími metodami jde v průměru o 14 % vyšší hodnotu.

Tabulka 20: Hodnocení přesnosti širšího území s využitím hyperspektrálních dat metodou MLC

Širší území			
celková přesnost: 72,16 %		Kappa koeficient: 0,69	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
stíny	94,53 %	68,20 %	0,50 %
Molinia caerulea	72,76 %	73,62 %	7,82 %
Vaccinium myrtillus	77,70 %	82,34 %	3,65 %
cesta	86,68 %	99,14 %	0,56 %
kamenná moře	96,59 %	75,65 %	0,89 %
Pinus mugo	85,92 %	96,11 %	8,75 %
Deschampsia cespitosa	68,00 %	78,27 %	11,19 %
mokřady a rašeliniště	52,29 %	56,54 %	6,92 %
Nardus stricta	77,17 %	75,39 %	27,02 %
Picea abies	54,23 %	32,70 %	4,12 %
Calamagrostis villosa	77,00 %	91,74 %	2,84 %
vodní plochy	46,92 %	33,15 %	0,95 %
Calluna vulgaris	78,59 %	69,86 %	5,00 %
Avenella flexuosa	19,36 %	50,48 %	4,75 %
Carex bigelowii	47,00 %	11,96 %	15,04 %

### 5.5.2 Random forest

Nejlepších výsledků z hlediska celkové přesnosti bylo dosaženo metodou RF, a to 81,74 %. Výsledky zpracovatelské a uživatelské přesnosti jednotlivých tříd nevykazovaly v porovnání s ostatními metodami výrazné odchylky. Zásadní rozdíly nebyly zjištěny ani u rozloh tříd. Velká diference mezi zpracovatelskou a uživatelskou přesností byla objevena u tříd vodní plochy a *Carex bigelowii* (tab. 21). To je pravděpodobně způsobeno velmi malou rozlohou tříd.

Tabulka 21: Hodnocení přesnosti širšího území s využitím hyperspektrálních dat metodou RF

Širší území			
celková přesnost: 81,74 %		Kappa koeficient: 0,79	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
stíny	75,38 %	65,78 %	0,26 %
Molinia caerulea	84,25 %	76,37 %	8,77 %
Vaccinium myrtillus	75,74 %	87,17 %	2,22 %
cesta	95,50 %	99,80 %	0,61 %
kamenná moře	95,17 %	86,47 %	0,68 %
Pinus mugo	95,99 %	96,57 %	9,63 %
Deschampsia cespitosa	84,55 %	72,39 %	17,29 %
mokřady a rašeliniště	55,46 %	70,81 %	5,07 %
Nardus stricta	86,24 %	76,89 %	33,30 %
Picea abies	74,32 %	83,39 %	2,46 %
Calamagrostis villosa	90,77 %	87,28 %	5,66 %
vodní plochy	10,77 %	100,00 %	0,01 %
Calluna vulgaris	84,61 %	81,25 %	5,43 %
Avenella flexuosa	46,94 %	67,43 %	8,44 %
Carex bigelowii	5,80 %	78,68 %	0,17 %

### 5.5.3 Objektově orientovaná klasifikace

Výsledky zpracovatelské i uživatelské přesnosti a rozloh tříd byly po klasifikaci metodou OBIA podobně dobré jako u metody RF a nebyly objeveny výrazné diference. Nejhorší přesnosti byly zaznamenány u třídy *Carex bigelowii*. Naopak nadprůměrně dobrých výsledků dosáhla třída vodní plochy. Z hlediska celkové přesnosti bylo dosaženo hodnoty 79,64 % (tab. 22).

Tabulka 22: Hodnocení přesnosti širšího území s využitím hyperspektrálních dat metodou OBIA

Širší území			
celková přesnost: 79,64 %		Kappa koeficient: 0,77	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
stíny	66,26 %	71,71 %	0,25 %
Molinia caerulea	79,61 %	75,20 %	7,16 %
Vaccinium myrtillus	71,08 %	81,23 %	2,94 %
cesta	92,87 %	100,00 %	0,71 %
kamenná moře	93,34 %	87,98 %	0,71 %
Pinus mugo	93,04 %	98,50 %	8,70 %
Deschampsia cespitosa	81,94 %	79,43 %	14,39 %
mokřady a rašeliniště	60,91 %	64,58 %	7,15 %
Nardus stricta	81,29 %	76,71 %	31,09 %
Picea abies	68,73 %	58,26 %	3,85 %
Calamagrostis villosa	88,88 %	85,36 %	5,52 %
vodní plochy	60,00 %	82,98 %	0,12 %
Calluna vulgaris	83,36 %	68,09 %	5,79 %
Avenella flexuosa	47,18 %	57,38 %	9,38 %
Carex bigelowii	15,53 %	32,89 %	2,24 %

## 5.6 Výsledky pro širší území tundry s využitím multispektrálních dat

Pro klasifikaci multispektrálních dat z kamery MicaSense Altum s prostorovým rozlišením 0,06 m a spektrálním rozlišením 6 pásem z širšího území tundry byla použita stejná trénovací a validační data jako v kapitole 5.5. Jediným rozdílem je třída stínů, která byla pro multispektrální a hyperspektrální data rozdílná z důvodu rozdílných světelných podmínek na snímcích. Z důležitých travních druhů dosahovala nejlepších výsledků zpracovatelské a uživatelské přesnosti třída *Calamagrostis villosa*. Obecně špatné výsledky separability byly zjištěny mezi třídami *Molinia caerulea* – *Deschampsia cespitosa* (0,76) a *Molinia caerulea* – *Carex bigelowii* (0,88). Horší odlišitelnost byla však zaznamenána prakticky u všech travních druhů (méně než 1,7).

### 5.6.1 Maximální pravděpodobnost

Metodou MLC bylo dosaženo celkové přesnosti 67,24 % (tab. 23). V porovnání s nejlepší klasifikací OBIA (viz níže) byly výsledky obecně podprůměrné bez výrazných výkyvů. Z důležitých travních druhů dopadla nejhůře *Molinia caerulea*. Z hlediska rozloh tříd byla největší odchylka v porovnání s OBIA zjištěna u třídy *Carex bigelowii* a to téměř o 12 %.

Tabulka 23: Hodnocení přesnosti širšího území s využitím multispektrálních dat metodou MLC

Širší území			
celková přesnost: 67,24 %		Kappa koeficient: 0,64	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
stíny	89,58 %	35,96 %	1,36 %
<i>Molinia caerulea</i>	53,07 %	59,24 %	6,58 %
<i>Vaccinium myrtillus</i>	67,62 %	59,97 %	4,43 %
cesta	94,19 %	99,99 %	0,32 %
kamenná moře	97,86 %	88,85 %	0,90 %
<i>Pinus mugo</i>	65,75 %	87,04 %	8,14 %
<i>Deschampsia cespitosa</i>	54,45 %	65,68 %	17,66 %
mokřady a rašeliniště	55,67 %	39,35 %	8,43 %
<i>Nardus stricta</i>	68,34 %	78,83 %	22,49 %
<i>Picea abies</i>	50,50 %	23,66 %	2,60 %
<i>Calamagrostis villosa</i>	82,88 %	94,72 %	3,59 %
vodní plochy	63,55 %	100,00 %	0,02 %
<i>Calluna vulgaris</i>	84,34 %	80,90 %	4,51 %
<i>Avenella flexuosa</i>	26,84 %	37,52 %	6,18 %
<i>Carex bigelowii</i>	53,03 %	11,46 %	12,79 %

### 5.6.2 Random forest

Z důvodu mimořádně velké výpočetní náročnosti byla tato klasifikace provedena v softwaru ArcGIS Pro (nikoliv s využitím skriptu v R, jako v případě všech ostatních klasifikací RF). Výsledky celkové přesnosti (63,58 %) jsou nejhorší ze všech tří použitých metod. Výsledky zpracovatelské a uživatelské přesnosti byly v porovnání s nejlepší klasifikací (OBIA) podprůměrné napříč všemi kategoriemi. Z důležitých

travních druhů dopadla nejhůře třída *Molinia caerulea* (tab. 24). Oproti výsledkům OBIA byly zjištěny i výrazné rozdíly v rozloze tříd, a to hlavně u kategorií *Nardus stricta* a *Carex bigelowii*.

Tabulka 24: Hodnocení přesnosti širšího území s využitím multispektrálních dat metodou RF

Širší území			
celková přesnost: 63,58 %		Kappa koeficient: 0,60	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
stíny	85,25 %	56,91 %	1,22 %
<i>Molinia caerulea</i>	37,13 %	55,81 %	10,15 %
<i>Vaccinium myrtillus</i>	58,47 %	66,77 %	3,35 %
cesta	93,42 %	95,45 %	0,43 %
kamenná moře	97,99 %	88,38 %	0,96 %
<i>Pinus mugo</i>	72,10 %	92,19 %	6,85 %
<i>Deschampsia cespitosa</i>	51,81 %	62,96 %	20,74 %
mokřady a rašeliniště	45,13 %	29,73 %	10,54 %
<i>Nardus stricta</i>	63,35 %	76,95 %	18,77 %
<i>Picea abies</i>	51,92 %	26,79 %	2,06 %
<i>Calamagrostis villosa</i>	78,19 %	91,06 %	3,96 %
vodní plochy	94,00 %	95,72 %	0,06 %
<i>Calluna vulgaris</i>	81,94 %	78,92 %	4,48 %
<i>Avenella flexuosa</i>	36,84 %	39,67 %	9,31 %
<i>Carex bigelowii</i>	40,57 %	15,46 %	7,12 %

### 5.6.3 Objektově orientovaná klasifikace

Nejlepšího výsledku celkové přesnosti bylo dosaženo metodou OBIA, a to 82,65 % (tab. 25). Výsledky zpracovatelské a uživatelské přesnosti byly prakticky u všech tříd nadprůměrně dobré. Nejhůře byla z hlediska výsledků vyklasifikována třída *Carex bigelowii*.

Tabulka 25: Hodnocení přesnosti širšího území s využitím multispektrálních dat metodou OBIA

Širší území			
celková přesnost: 82,65 %		Kappa koeficient: 0,80	
třída	zpracovatelská přesnost	uživatelská přesnost	rozloha třídy
stíny	89,92 %	84,96 %	0,68 %
<i>Molinia caerulea</i>	81,04 %	71,29 %	8,06 %
<i>Vaccinium myrtillus</i>	75,97 %	87,28 %	2,79 %
cesta	99,22 %	100,00 %	0,44 %
kamenná moře	98,52 %	92,39 %	0,80 %
<i>Pinus mugo</i>	94,44 %	94,52 %	9,32 %
<i>Deschampsia cespitosa</i>	72,87 %	69,30 %	24,38 %
mokřady a rašeliniště	56,21 %	57,50 %	6,13 %
<i>Nardus stricta</i>	81,92 %	83,74 %	27,05 %
<i>Picea abies</i>	53,57 %	63,10 %	1,15 %
<i>Calamagrostis villosa</i>	93,15 %	91,24 %	4,86 %
vodní plochy	94,29 %	95,31 %	0,12 %
<i>Calluna vulgaris</i>	93,87 %	90,13 %	5,73 %
<i>Avenella flexuosa</i>	47,04 %	58,37 %	7,65 %
<i>Carex bigelowii</i>	20,03 %	43,28 %	0,84 %


## 5.7 Porovnání výsledků klasifikací z multispektrálních a hyperspektrálních dat

V grafech 1-6 jsou shrnuty výsledky zpracovatelské a uživatelské přesnosti a rozloh jednotlivých tříd vybraných klasifikací z hyperspektrálních dat v přímém porovnání s klasifikacemi z dat multispektrálních.

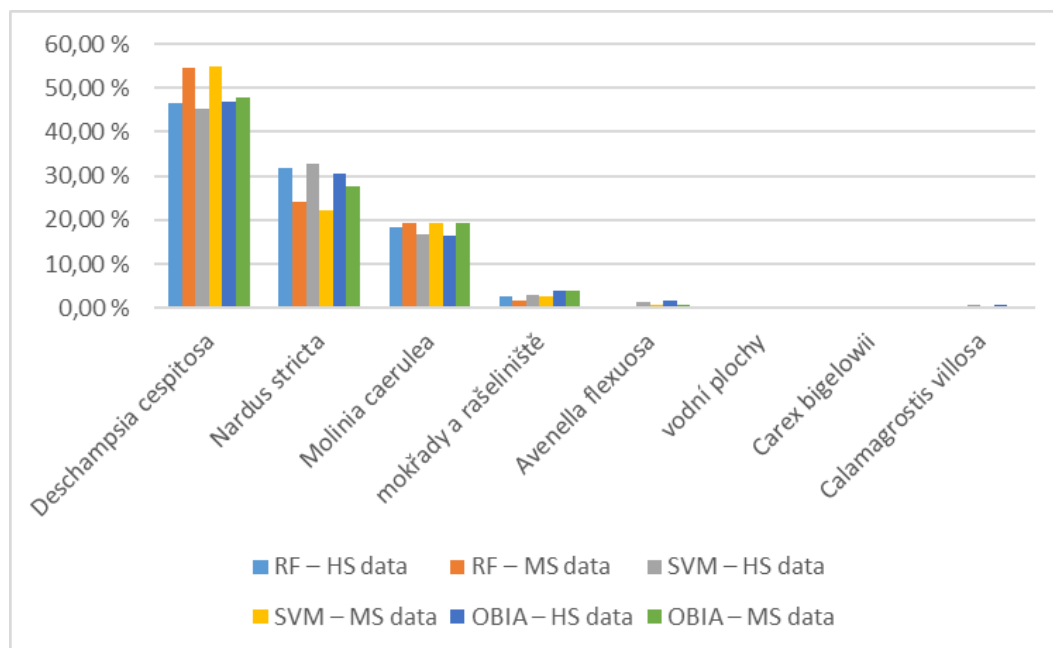
### 5.7.1 Porovnání výsledků plochy „U Luční boudy“

Z ochrannásky důležitých travních druhů dosahovala stabilně dobrých výsledků třída *Deschampsia cespitosa*, *Nardus stricta* a *Molinia caerulea*. Z grafu 1 lze však vysledovat zhoršení zpracovatelských a uživatelských přesností při použití dat multispektrálních oproti datům hyperspektrálním. Tento propad byl minimální pouze u klasifikace OBIA. Nízkou přesnost vykazovala třída *Calamagrostis villosa*. Při porovnání rozloh tříd (graf 2) byla znatelná větší rozloha třídy *Deschampsia cespitosa* při klasifikaci z multispektrálních dat metodami RF a SVM primárně na úkor třídy *Nardus stricta*, kde byl trend opačný. U klasifikací metodou OBIA nebyl rozdíl mezi typy dat u těchto dvou travních druhů tak výrazný.

Graf 1: Porovnání zpracovatelské a uživatelské přesnosti mezi hyperspektrálními a multispektrálními daty na ploše „U Luční boudy“ (HS = hyperspektrální, MS = multispektrální)




Graf 2: Porovnání rozloh jednotlivých tříd mezi hyperspektrálními a multispektrálními daty na ploše „U Luční boudy“ (HS = hyperspektrální, MS = multispektrální)



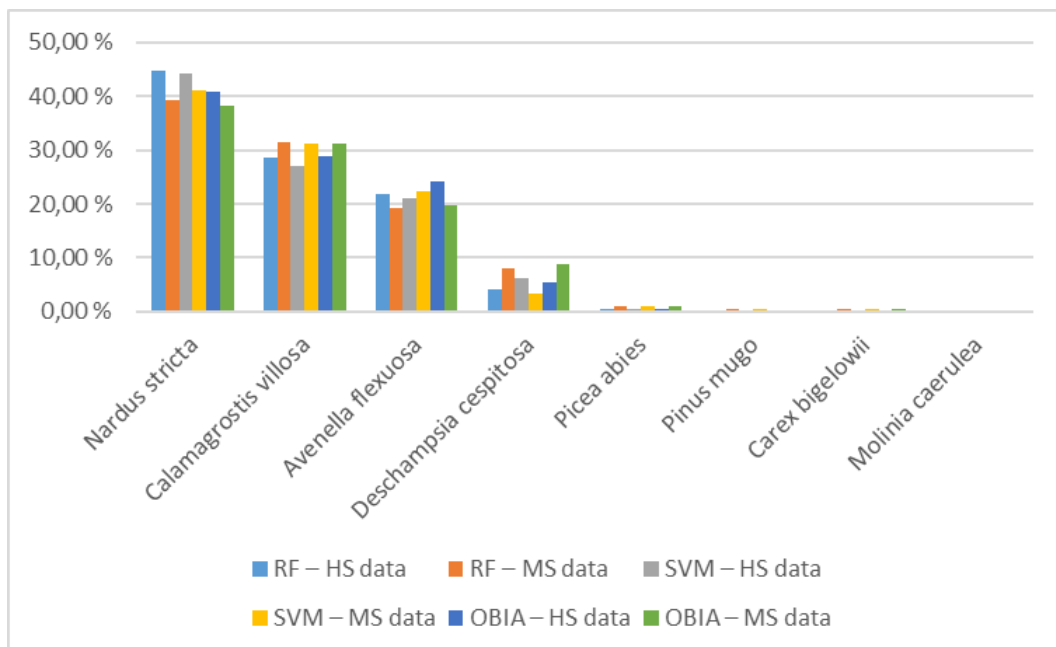
### 5.7.2 Porovnání výsledků plochy „U Zahrádky“

Z grafu 3 lze vyčíst, že výborných výsledků zpracovatelské i uživatelské přesnosti napříč všemi metodami i zdroji dat dosahovala *Calamagrostis villosa*. Velmi dobře dopadla také třída *Nardus stricta*. Zajímavostí byl výrazný propad hodnot přesnosti u třídy *Deschampsia cespitosa*, která při použití multispektrálních dat dosahovala výrazně horších výsledků než s hyperspektrálními daty, a to u všech metod. U rozloh tříd byl znatelný rozdíl u třídy *Nardus stricta*, která byla u všech metod s využitím hyperspektrálních dat vyklasifikována na větší ploše než s daty multispektrálními, a to hlavně na úkor třídy *Calamagrostis villosa* (graf 4). Za povšimnutí stojí také rozdílná rozloha třídy *Deschampsia cespitosa* jak mezi metodami, tak i zdroji dat.

Graf 3: Porovnání zpracovatelské a uživatelské přesnosti mezi hyperspektrálními a multispektrálními daty na ploše „U Zahrádky“ (HS = hyperspektrální, MS = multispektrální)



Graf 4: Porovnání rozloh jednotlivých tříd mezi hyperspektrálními a multispektrálními daty na ploše „U Zahrádky“ (HS = hyperspektrální, MS = multispektrální)



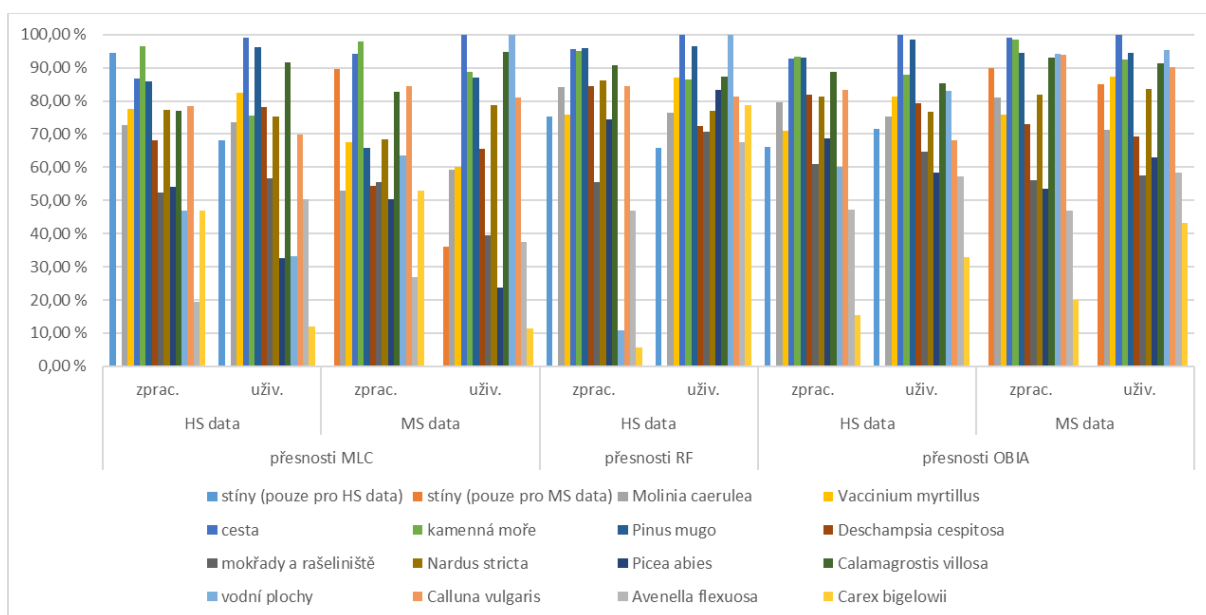
### 5.7.3 Porovnání výsledků širšího území tundry

Stabilně dobrých výsledků dosahovaly primárně nevegetační třídy jako cesta nebo kamenná pole (graf 5). U travních druhů byl rozdíl znatelný hlavně mezi metodou MLC s metodami RF a OBIA. Mnohem




menších výkyvů, než na dvou malých plochách bylo z hlediska zpracovatelské a uživatelské přesnosti dosaženo mezi daty hyperspektrálními a multispektrálními. Z ochrannářsky důležitých travních druhů dopadla nejlépe třída *Calamagrostis villosa*. Velmi špatně byla vyklasifikována třída *Carex bigelowii*. Větší rozdíly byly znatelné při analýze rozloh tříd, a to hlavně u tříd *Nardus stricta*, *Deschampsia cespitosa* a *Carex bigelowii* (graf 6). Zajímavostí je velmi významný rozdíl rozloh hlavně u třídy *Carex bigelowii*, a to mezi metodou MLC s metodami RF a OBIA a také výrazně vyšší rozloha třídy *Deschampsia cespitosa* vyklasifikovaná metodou OBIA z multispektrálních dat.

Graf 5: Porovnání zpracovatelské a uživatelské přesnosti mezi hyperspektrálními a multispektrálními daty na širším území tundry“ (HS = hyperspektrální, MS = multispektrální)



Graf 6: Porovnání rozloh jednotlivých tříd mezi hyperspektrálními a multispektrálními daty na širším území tundry (HS = hyperspektrální, MS = multispektrální)




## 5.8 Porovnání mapových výstupů z hyperspektrálních a multispektrálních dat

Pro dvě malé plochy byla pro porovnání vybrána vždy jedna pixelová klasifikační metoda s nejlepší celkovou přesností. U plochy „U Luční boudy“ se jednalo o metodu Random forest a pro plochu „U Zahrádky“ o metodu Support vector machine. Pro širší území tundry byly pro analýzu zvoleny mapové výstupy z objektově orientované klasifikace. Další mapové výstupy lze nalézt v přílohách 1-6, kde jsou pro porovnání s nejlepšími pixelovými klasifikacemi pro dvě malé plochy z této kapitoly dostupné výstupy z klasifikace OBIA. Pro širší území tundry jsou k dispozici nejlepší pixelové klasifikace (nejvyšší celková přesnost).

### 5.8.1 Analýza mapových výstupů z plochy „U Luční boudy“

Z klasifikačního výstupu z multispektrálních dat bylo zřejmé výraznější promísení kategorií *Nardus stricta* a *Deschampsia cespitosa* oproti hyperspektrálním datům (obr. 19). Jejich hlavní místa výskytu se však shodují. U třídy mokřady a rašeliniště bylo rozšíření na snímku z hyperspektrálních dat mnohem kompaktnější a více rozšířené.

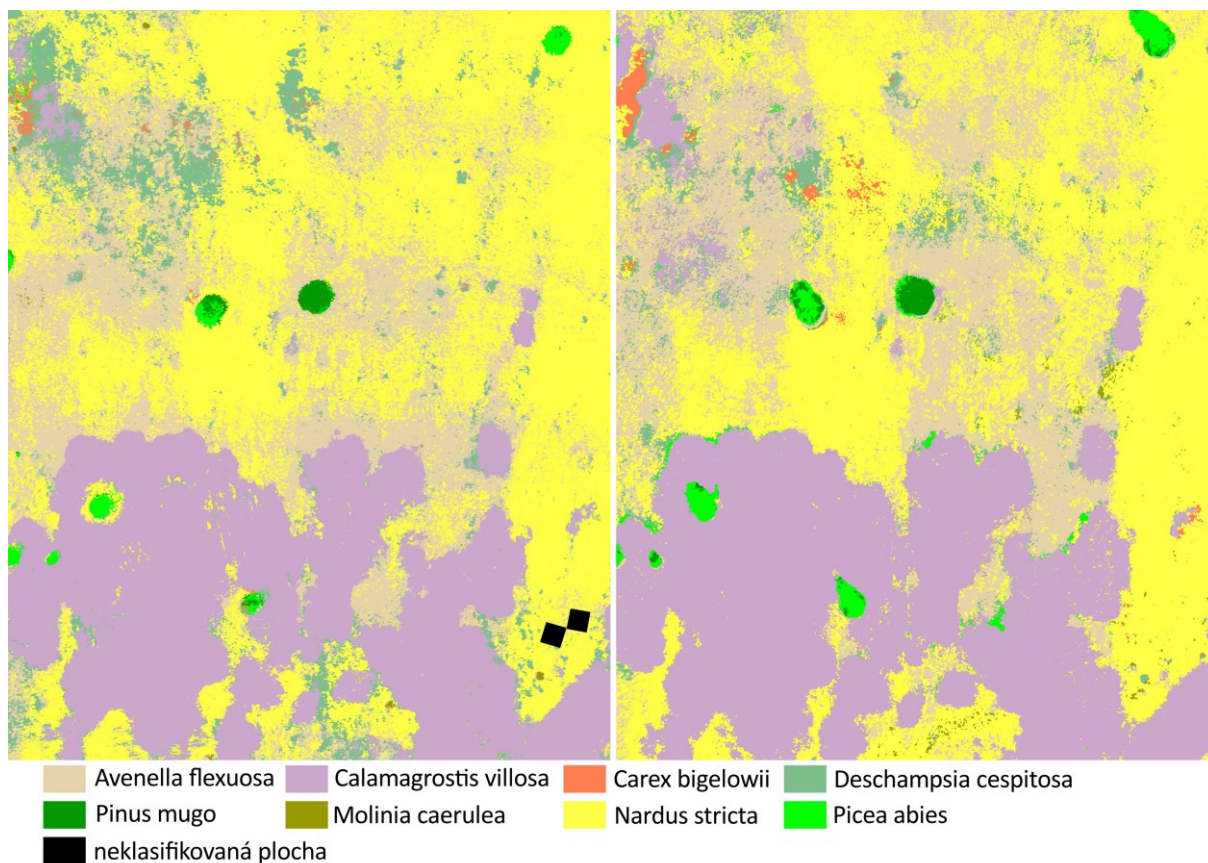


Obrázek 19: Mapové výstupy z klasifikace Random forest pro plochu „U Luční boudy“ z hyperspektrálních dat (horní snímek) a z multispektrálních dat (dolní snímek)

### 5.8.2 Analýza mapových výstupů z plochy „U Zahrádky“

Hlavní místa výskytu jednotlivých druhů byla i zde při porovnání hyperspektrálních a multispektrálních dat stejná. Pouze v SZ části snímku byla znatelná drobná diference mezi druhy *Carex bigelowii*, *Calamagrostis villosa* a *Deschampsia cespitosa* (obr. 20). Na mapovém výstupu z multispektrálních dat byla třída *Picea abies* vyklasifikována v oválném protáhlém tvaru. Za to může pravděpodobně zastínění na odvrácené straně stromu od slunce.



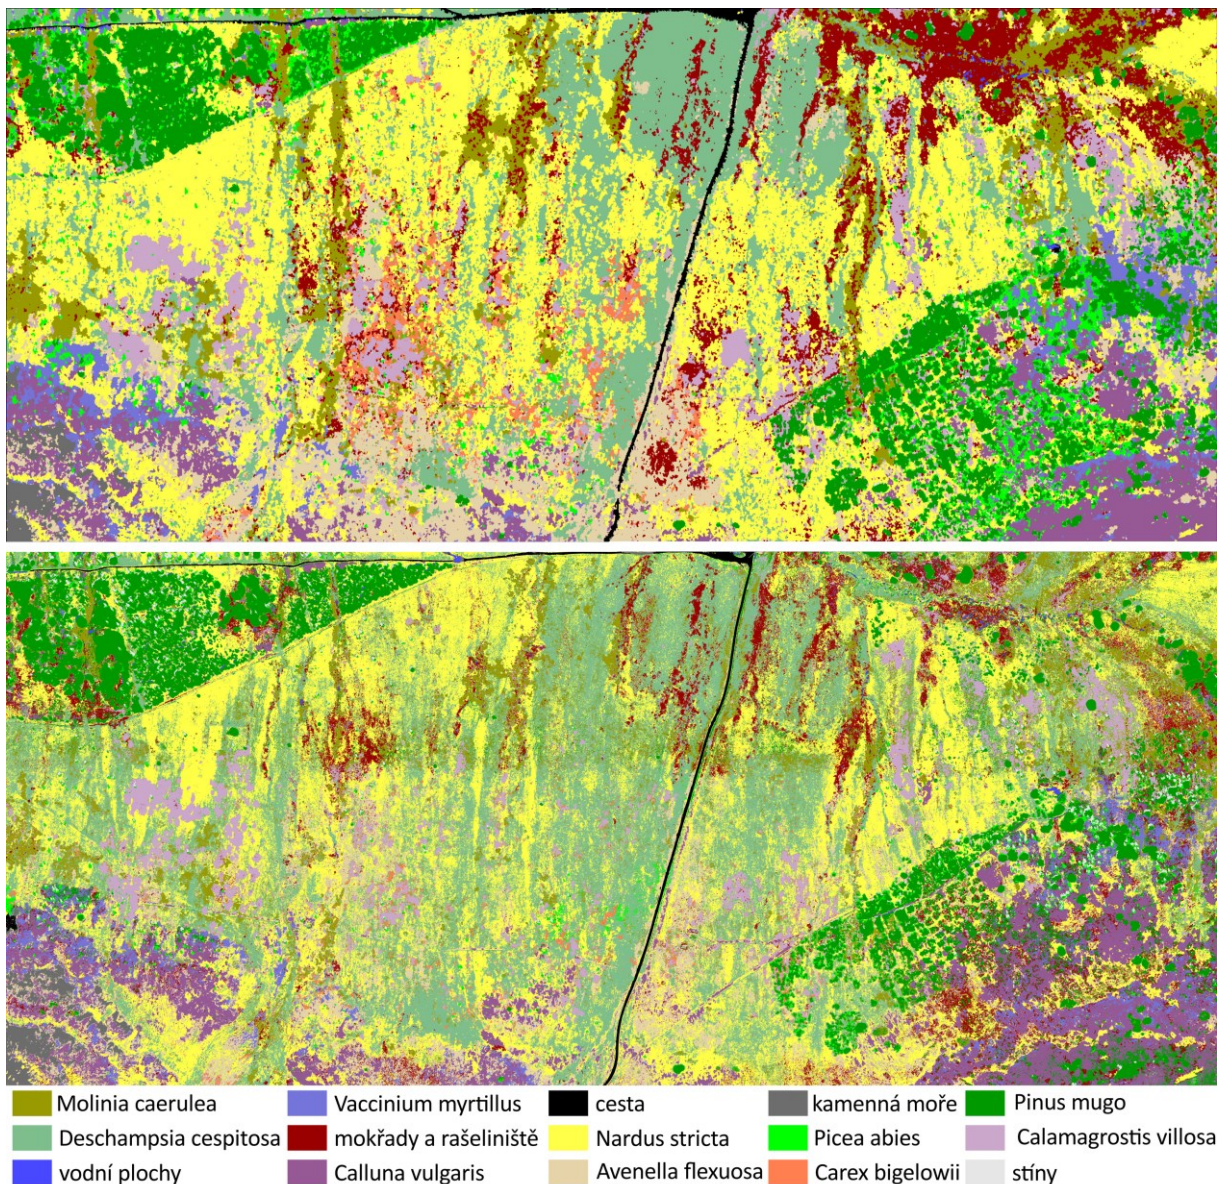


Obrázek 20: Mapové výstupy z klasifikace Support vector machine pro plochu „U Zahrádky“ z hyperspektrálních dat (vlevo) a z multispektrálních dat (vpravo)

### 5.8.3 Analýza mapových výstupů z širšího území tundry

Při porovnávání výstupů klasifikací širšího území tundry byly znatelné již markantní diference. Velkým rozdílem byl výskyt třídy mokřady a rašeliniště v SV části území, která se na snímku z hyperspektrálních dat vyskytovala výrazně více než na snímku z dat multispektrálních (obr. 21). Stejný případ byl zaznamenán u třídy *Avenella flexuosa* v jižní části snímku. Na téměř celé ploše bylo znatelné také rozdílné rozšíření tříd *Nardus stricta* a *Deschampsia cespitosa*. Zajímavostí byl také vyšší výskyt tříd *Picea abies* a *Pinus mugo* na snímku z hyperspektrálních dat v JV části.





Obrázek 21: Mapové výstupy z klasifikace OBIA pro širší území tundry z hyperspektrálních dat (horní snímek) a z multispektrálních dat (dolní snímek)

## 5.9 Analýza překryvů

Analýzou překryvů byly získány počty shodně klasifikovaných pixelů pro klasifikační výstupy obou malých ploch metodami RF a SVM, a to jak z multitemporálních hyperspektrálních dat (červen, červenec, srpen), tak i z multispektrálních dat. Výsledkem je procento území, na kterém byly oběma metodami vyklasifikovány stejné třídy. Pro každou třídu byla následně vypočtena souhrnná hodnota shody  $MA_t$  (reprezentující průnik rozlohy dané kategorie v obou klasifikacích), která je definována vzorcem  $MA_t = M / (A_1 + A_2 - M)$ , kde  $M$  je plocha, ve které se obě klasifikační metody shodují a  $A_1$  a  $A_2$  jsou celkové plochy, na kterých byla třída jednotlivými metodami klasifikována (Kupková a kol., 2022). U klasifikací z multispektrálních dat dosahovala celková shoda na obou plochách 78 %. U dat hyperspektrálních 88 % (tab. 26). Překryvy klasifikací hyperspektrálních dat (pro něž byly dosaženy

lepší výsledky než pro MS data) byly vizualizovány též ve formě map (opět jde o překryv klasifikací RF a SVM) – viz obrázky 22 a 23.


Tabulka 26: Shrnující tabulka celkových shod překryvů u klasifikačních metod RF a SVM

plocha	shoda RF a SVM hyperspektrální data	shoda RF a SVM multispektrální data
U Luční boudy	88,36 %	78,31 %
U Zahrádky	88,69 %	77,96 %

### 5.9.1 Analýza překryvů klasifikačních výstupů hyperspektrálních dat

Na ploše „U Luční boudy“ dosahovaly nejvyšší prostorové shody v obou klasifikacích travní druhy *Molinia caerulea*, *Deschampsia cespitosa* a *Nardus stricta* (graf 7). Výrazně se shodovaly i vodní plochy. Prakticky nulová prostorová shoda byla zaznamenána u tříd *Calamagrostis villosa* a *Carex bigelowii*, jejichž rozšíření v této ploše bylo velmi malé. Prostorové rozložení shod tříd je znázorněno na obrázku 22.

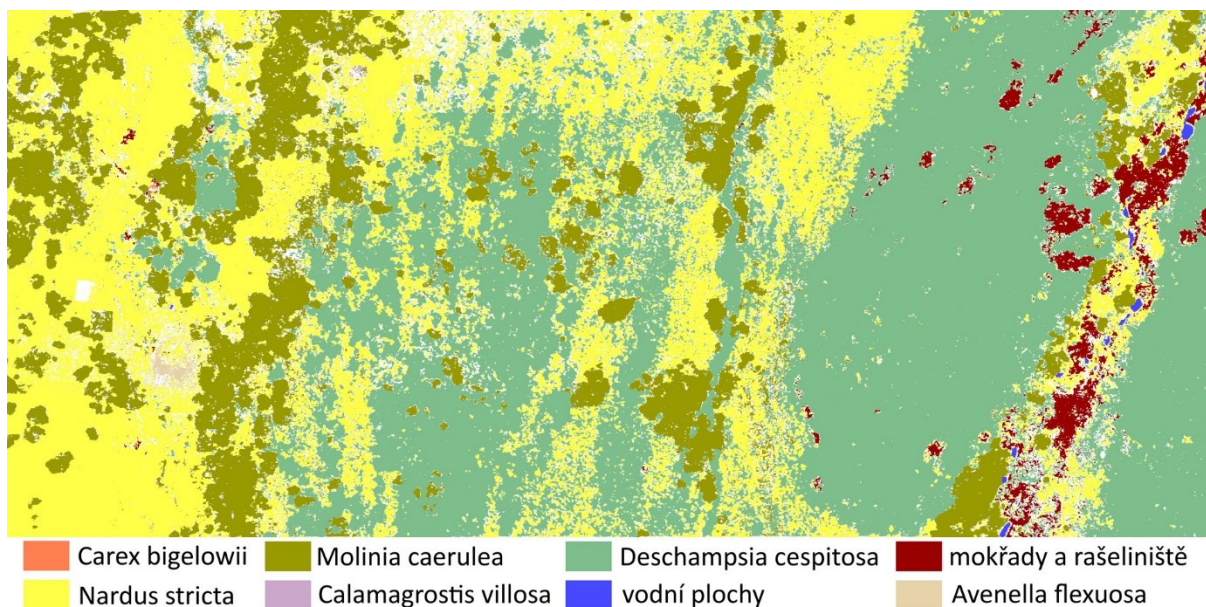

Graf 7: Shody jednotlivých klasifikačních metod „U Luční boudy“ pro jednotlivé třídy s využitím hyperspektrálních dat



„U Zahrádky“ z důležitých travních druhů dosáhly výborných výsledků prostorové shody tříd *Calamagrostis villosa* a *Nardus stricta* (graf 8). Naopak hůře dopadly třídy *Molinia caerulea* a *Deschampsia cespitosa*, které se shodovaly v méně než 40 % respektive 50 %. Rozšíření těchto dvou kategorií na ploše bylo ale velmi malé. Mapový výstup překryvu klasifikací je zobrazen na obrázku 23.




Graf 8: Shody jednotlivých klasifikačních metod „U Zahrádky“ pro jednotlivé třídy s využitím hyperspektrálních dat



Obrázek 22: Mapový výstup překryvu klasifikací RF a SVM na ploše „U Luční boudy“ za využití hyperspektrálních dat. Bílá barva v mapě reprezentuje místa, kde byly vyklasifikovány rozdílné kategorie, případně místa, kde byl položen koberec pro radiometrickou korekci dat.



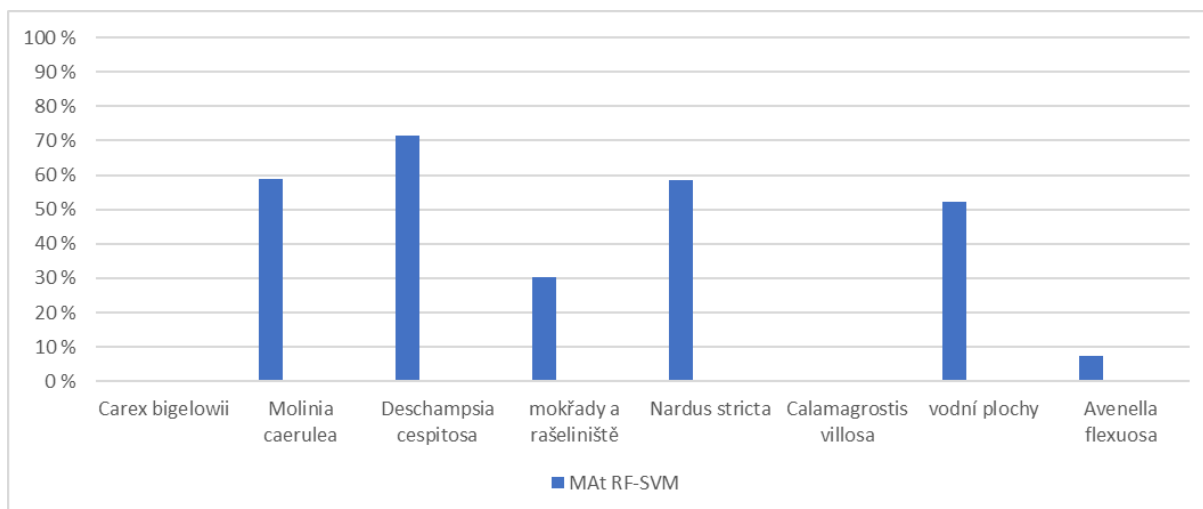


Obrázek 23: Mapový výstup překryvu klasifikací RF a SVM na ploše „U Zahrádky“ za využití hyperspektrálních dat. Bílá barva v mapě reprezentuje místa, kde byly vyklasifikovány rozdílné kategorie.

### 5.9.2 Analýza překryvů z multispektrálních dat


Na ploše „U Luční boudy“ nejlepší souhrnné shody překryvu dosáhla třída *Deschampsia cespitosa* (graf 9). Z grafů je ale patrné, že v porovnání s hyperspektrálními daty jsou výsledky souhrnné shody horší napříč všemi třídami. Nulová shoda byla zaznamenána u třídy *Calamagrostis villosa*, jejíž rozloha v ploše byla však velmi malá.

Graf 9: Shody jednotlivých klasifikačních metod „U Luční boudy“ pro jednotlivé třídy s využitím multispektrálních dat



Podobný trend zhoršení výsledků byl patrný i na ploše „U Zahrádky“. Velkým rozdílem při porovnání s hyperspektrálními daty bylo výrazné zhoršení souhrnné shody překryvu u třídy *Molinia caerulea* (velmi malé rozšíření třídy na ploše). Nejlepšího výsledku bylo dosaženo opět u třídy *Calamagrostis villosa* (graf 10).

Graf 10: Shody jednotlivých klasifikačních metod „U Zahrádky“ pro jednotlivé třídy s využitím multispektrálních dat



## 6. Diskuse

Hlavním cílem této práce bylo s využitím různých metod klasifikace (pixelových a objektové) zjistit, jak přesné výsledky (celkové, zpracovatelské a uživatelské přesnosti, prostorová shoda rozšíření druhů a shoda v rozlohách klasifikovaných druhů ve výstupech z různých klasifikačních metod) je možno dosáhnout pro čtyři hlavní ochranné významné druhy travin (*Nardus stricta*, *Calamagrostis villosa*, *Molinia caerulea* a *Deschampsia cespitosa*) na plochách „U Luční boudy“ a „U Zahrádky“. Klasifikována byla multitemporální hyperspektrální data z UAV s prostorovým rozlišením 3 cm a spektrálním rozlišením 270 pásem pořízená v červnu, červenci a srpnu v letech 2020 a 2021. Snahou bylo též ověřit, zda bude pro tyto dvě plochy možné dosáhnout srovnatelných výsledků s plochou „Bílá louka“ klasifikovanou v projektu „Vývoj metod pro sledování změn vegetace a krkonošské tundry analýzou dat z multispektrálních, hyperspektrálních a LiDAR senzorů UAV“. Pro klasifikace této plochy byla využita hyperspektrální a multispektrální data s prostorovým rozlišením 0,09 m, ze kterých byly vytvořeny multitemporální kompozity (Kupková a kol., 2021). V tabulkách 27 a 28 je k dispozici porovnání zpracovatelských a uživatelských přesností pro různé klasifikační metody společně s jejich nejvyšším součtem.

Tabulka 27: Porovnání přesností důležitých travních druhů mezi jednotlivými plochami s využitím multitemporálních hyperspektrálních dat (ZP = zpracovatelská přesnost, UP = uživatelská přesnost)

		Bílá louka			U Luční boudy			U Zahrádky		
		nejlepší ZP	nejlepší UP	nejlepší UP+ZP	nejlepší ZP	nejlepší UP	nejlepší UP+ZP	nejlepší ZP	nejlepší UP	nejlepší UP+ZP
<b>Calamagrostis villosa</b>	přesnost	99,61%	98,74%	198,26%	64,08%	93,51%	134,28%	99,73%	99,95%	199,44%
	metoda	OBIA	MLC	OBIA	OBIA	RF	MLC	OBIA	MLC	OBIA
<b>Molinia caerulea</b>	přesnost	95,65%	98,60%	193,87%	96,53%	97,21%	193,42%	90,87%	95,43%	186,30%
	metoda	OBIA	OBIA	OBIA	RF	SVM	RF	MLC	MLC	MLC
<b>Nardus stricta</b>	přesnost	89,64%	85,22%	172,96%	93,65%	93,68%	185,74%	94,86%	97,74%	191,43%
	metoda	OBIA	OBIA	OBIA	RF	OBIA	OBIA	SVM	MLC	OBIA
<b>Deschampsia cespitosa</b>	přesnost	94,29%	87,89%	181,22%	98,98%	98,33%	197,31%	80,97%	75,19%	155,18%
	metoda	RF	OBIA	OBIA	OBIA	OBIA	OBIA	OBIA	RF	OBIA

zdroj: Kupková a kol., 2021

Tabulka 28: Porovnání přesností důležitých travních druhů mezi jednotlivými plochami s využitím multispektrálních dat (ZP = zpracovatelská přesnost, UP = uživatelská přesnost)

		Bílá louka			U Luční boudy			U Zahrádky		
		nejlepší ZP	nejlepší UP	nejlepší UP+ZP	nejlepší ZP	nejlepší UP	nejlepší UP+ZP	nejlepší ZP	nejlepší UP	nejlepší UP+ZP
<b>Calamagrostis villosa</b>	přesnost	99,22%	98,17%	197,39%	61,82%	41,38%	68,65%	99,25%	99,48%	198,57%
	metoda	MLC	MLC	MLC	MLC	OBIA	OBIA	OBIA	MLC	OBIA
<b>Molinia caerulea</b>	přesnost	97,29%	98,29%	192,69%	85,59%	89,06%	174,65%	0,00%	0,00%	0,00%
	metoda	OBIA	MLC	MLC	OBIA	OBIA	OBIA			
<b>Nardus stricta</b>	přesnost	82,66%	86,92%	168,17%	82,15%	81,29%	163,44%	95,95%	97,68%	193,63%
	metoda	OBIA	OBIA	MLC	OBIA	OBIA	OBIA	OBIA	OBIA	OBIA
<b>Deschampsia cespitosa</b>	přesnost	95,08%	89,25%	184,17%	93,32%	89,02%	182,34%	60,81%	38,98%	90,90%
	metoda	OBIA	MLC	MLC	OBIA	OBIA	OBIA	MLC	OBIA	MLC

zdroj: Kupková a kol., 2021

Před samotným porovnáváním výsledků je třeba zmínit, že plocha „Bílá louka“ byla z hlediska rozšíření čtyř studovaných trav ideální, protože tyto druhy se v ní vyskytovaly vždy na minimálně 10 % území. To zajišťovalo větší šanci k získání vysoké přesnosti klasifikace a možnosti k popisování klasifikačních trendů u jednotlivých tříd. Na ploše „U Luční boudy“ byla z hlediska nízké rozlohy problematická třída *Calamagrostis villosa*, která se ve výsledcích rozloh vyskytovala v průměru na méně než 1 % území a na ploše „U Zahrádky“ třídy *Molinia caerulea* (rozloha méně než 1 %) a *Deschampsia cespitosa* s průměrnou rozlohou nižší než 10 %. Z tohoto důvodu se výsledky těchto tříd na uvedených plochách nedají zcela objektivně porovnat a budeme se zabývat porovnáním druhů, které byly zastoupeny na více než 10 % sledovaných ploch.

U výsledků klasifikací z hyperspektrálních dat byly důležité travní druhy s rozlohou vyšší než 10 % mapovány ve všech případech zpracovatelské i uživatelské přesnosti nad 90 % (tab. 27). Z hlediska nejpresnějších klasifikačních metod sice u obou malých ploch převažovala OBIA, ale velice dobré výsledky přinesly i ostatní použité, tedy pixelové metody. A to narozdíl od plochy „Bílá louka“, na které byla skoro ve všech případech nejpresnější OBIA. Zajímavostí je třída *Molinia caerulea* na ploše „U Luční boudy“, kde byla nejpresnější metoda RF. Důležitým výsledkem je, že třída *Nardus stricta* byla na obou plochách v této práci vyklasifikována výrazně lépe než na ploše „Bílá louka“. Třída *Calamagrostis villosa* dosahovala nejlepších výsledků na ploše „U Zahrádky“.

Nejlepší zpracovatelské a uživatelské přesnosti klasifikací z multispektrálních dat byly ve většině případů horší než s použitím dat hyperspektrálních, ale i přesto s hodnotami přes 80 %. Největší zhoršení bylo zaznamenáno u třídy *Nardus stricta* na ploše „U Luční boudy“. Ta byla ale problematická i na ploše „Bílá louka“. Naopak na ploše „U Zahrádky“ byla *Nardus stricta* vyklasifikována dokonce s vyšší přesností než s využitím hyperspektrálních dat. I zde dosahovala nejlepších výsledků třída *Calamagrostis villosa* na ploše „U Zahrádky“ s téměř 100% zpracovatelskou i uživatelskou přesností. Zajímavostí je absolutní převaha klasifikační metody OBIA při dosahování

nejlepších přesností na obou malých plochách z této práce. Na ploše „Bílá louka“ totiž nejlepší výsledky přinášela většinou metoda MLC.

Lze tedy konstatovat, že s využitím multitemporálních hyperspektrálních dat z UAV bylo u hlavních travních druhů dosaženo na plochách „U Luční boudy“ a „U Zahrádky“ velmi vysoké zpracovatelské a uživatelské přesnosti (přes 90 %), ale pouze za předpokladu, že se na území vyskytovaly s dostatečně velkou rozlohou (pokrývaly alespoň 10 % území).

Při porovnání klasifikačních metod na plochách „U Luční boudy“ a „U Zahrádky“ bylo dosaženo nejhorší celkové přesnosti s použitím metody MLC, a to jak při použití hyperspektrálních, tak i multispektrálních dat. O tom, že je tato metoda v porovnání s dalšími možnostmi klasifikace podprůměrná se lze dočíst i v literatuře (Kupková a kol., 2017). Ovšem při použití hyperspektrálních dat bylo i touto metodou dosaženo na obou malých plochách celkové přesnosti přes 90 % a třída *Picea abies* dopadla v porovnání s dalšími metodami dokonce nadprůměrně dobře (zpracovatelská přesnost 91 %, uživatelská přesnost 97 %).

Největším nedostatkem ve výsledcích z hyperspektrálních dat ale byly významné rozdíly v rozlohách tříd klasifikovaných různými metodami. Zde se metoda MLC rozcházela s ostatními pixelovými metodami (RF, SVM) i o více než 10 % na třídu. Důležité je, že rozlohy jednotlivých tříd byly u klasifikací s využitím ostatních pixelových metod konzistentní a s odchylkami maximálně 2 %. Stejně problémy s rozdílností rozloh tříd se vyskytovaly i u klasifikací z multispektrálních dat. Lze tedy polemizovat nad tím, jak spolehlivá je v tomto případě dosažená celková přesnost klasifikace při hodnocení výsledků.

O mnoho lépe dopadly klasifikace s použitím metod RF a SVM, u kterých bylo na obou malých plochách jak z dat hyperspektrálních, tak multispektrálních dosaženo podobných hodnot celkové přesnosti (u multispektrálních dat se rozcházela nejvíce o 4 %, u hyperspektrálních dat pouze o 1 %). V případě hyperspektrálních dat byla z hlediska celkové přesnosti nejlepší pixelová klasifikace oproti OBIA horší pouze o 1 %.

Pro spolehlivější určení přesnosti klasifikací byla provedena také analýza překryvů klasifikačních výstupů dvou různých pixelových metod s nejvyšší přesností klasifikace (RF a SVM), ze kterých bylo zjištěno, do jaké míry se jednotlivé vyklasifikované třídy polohově shodují. Nejlepších celkových shod obou klasifikací bylo dosaženo s využitím multitemporálních hyperspektrálních dat, pro něž se třídy celkově překrývaly u obou ploch z více než 88 %. Důležitým zjištěním bakalářské práce je zejména to, že u rozlohou nejrozšířenějších a zároveň ochranářsky důležitých travních druhů, jejichž analýza byla hlavním cílem této práce, byly výsledky překryvů velmi dobré. Hodnoty souhrnné shody MAT vycházely na ploše „U Luční boudy“ u tříd *Molinia caerulea*, *Deschampsia cespitosa* a *Nardus*

*stricta* vždy přes 70 %. Na ploše „U Zahrádky“ u tříd *Calamagrostis villosa* a *Nardus stricta* dokonce přes 80 %. Naopak pro málo rozsáhlé/prostorově málo rozšířené třídy byly výsledky shody špatné (MAt tříd *Carex bigelowii* a *Calamagrostis villosa* na ploše „U Luční boudy“ do 5 %). Zde je třeba dodat, že v případě plochy „U Luční boudy“ se z důležitých druhů velmi málo vyskytovala *Calamagrostis villosa* a na ploše „U Zahrádky“ byla marginálně zastoupena *Molinia caerulea*. Jako relevantní lze tedy brát výsledky pro tyto kategorie pouze v plochách, kde bylo jejich zastoupení významnější. U analýzy překryvů z multispektrálních dat se výsledky shod pohybovaly u obou malých ploch kolem 78 %.

Na obou malých plochách při využití hyperspektrálních i multispektrálních dat byly bez výjimky získány nejlepší výsledky celkové přesnosti s využitím klasifikace OBIA. Vyšší přesnost této metody klasifikace byla zřejmá hlavně při použití multispektrálních dat, kde celkové přesnosti převyšovaly ostatní metody výrazněji. Na ploše „U Luční boudy“ téměř o 8 %. Zpracovatelské a uživatelské přesnosti většiny jednotlivých tříd dopadly nadprůměrně dobře. Nejlepších výsledků bylo pro multitemporální snímky s vysokým rozlišením dosaženo metodou OBIA také u Suché a kol. (2016). Avšak číselné výsledky přesností u objektově orientovaných metod při klasifikaci vegetace by neměly být reprezentovány izolovaně, protože mohou být nadhodnocené. Způsobuje to samotný princip metody, kdy se jednotlivé části obrazu před klasifikováním segmentují do větších celků. Z toho důvodu mohou být smazány jemné rozdíly mezi jednotlivými pixely, které mohou být pro ochranné účely zásadní. Je ale nutné poznamenat, že v případě rozloh jednotlivých tříd na dvou malých plochách v této práci u metody OBIA byly s využitím multitemporálních hyperspektrálních dat rozdíly v rozlohách klasifikovaných kategorií v porovnání s pixelovými metodami RF a SVM malé pouze v řádech jednotek procent a dá se říci, že objektová klasifikace výsledky zejména pro dostatečně rozšířené kategorie příliš „nezkreslila“.

U málo zastoupených travních druhů byly výsledky špatné u všech klasifikačních metod. Jde zejména o třídy *Calamagrostis villosa* a *Carex bigelowii* na ploše „U Luční boudy“. Samotné nedostatečné rozšíření bylo pravděpodobně hlavním důvodem špatných výsledků. Pro takto málo rozšířené druhy byl k dispozici velmi omezený počet trénovacích polygonů (*Carex bigelowii* – 2, *Calamagrostis villosa* – 3) s velmi malou rozlohou. Pro klasifikační metody mohl být takto malý počet nedostatečný. Zároveň byly narozdíl od tříd vodní plochy nebo *Pinus mugo* mnohem hůře odlišitelné od dalších travních druhů (což potvrzují výsledky hodnocení separability). Tomuto tvrzení však odporují výsledky zpracovatelské a uživatelské přesnosti třídy *Carex bigelowii* na ploše „U Zahrádky“ z klasifikací multispektrálních dat, které v případě OBIA vyšly s téměř 100% přesností. Zde se mohlo projevit právě zkreslení dané principem metody objektové klasifikace (vliv segmentace).

Ze zmíněných výsledků klasifikací na dvou malých plochách nelze zcela jistě zhodnotit rozdíl v přesnosti multispektrálních a hyperspektrálních dat. Multispektrální data měla například výše zmíněné chyby v radiometrii, které mohly ovlivnit výsledky klasifikace. Hyperspektrální data dosahovala výborných výsledků v případě multitemporálních kompozitů. Pro monotemporální data z července a srpna byla celková přesnost ve všech případech horší. Propady i o více než 10 % byly zaznamenány hlavně u metod RF a SVM na ploše „U Luční boudy“ (tab. 29).

Tabulka 29: Porovnání celkových přesností z klasifikací hyperspektrálních dat mezi monotemporálními snímky a multitemporálním kompozitem z června, července a srpna

	U Luční boudy			U Zahrádky		
	RF	SVM	OBIA	RF	SVM	OBIA
<b>červencový termín</b>	85,63%	80,15%	90,82%	92,44%	91,44%	93,07%
<b>srpnový termín</b>	86,64%	83,16%	90,51%	92,86%	91,89%	94,43%
<b>multitemporální kompozit</b>	94,72%	94,23%	95,37%	93,05%	94,07%	94,95%

Důležitý fakt, který vyplývá z těchto výsledků, je vliv multitemporálních kompozitů pro maximalizaci přesnosti klasifikací. Při zkombinování dat z několika termínů lze totiž vysledovat fenologické změny vegetace, které nejsou ze snímku z jednoho termínu rozpoznatelné, a tím efektivněji rozlišit jednotlivé druhy.

V práci bylo klasifikováno také širší území tundry, a to jednak z multispektrálních dat a dále také z leteckých hyperspektrálních dat. Cílem bylo rozpoznat hlavní rozdíly v přesnosti klasifikace při použití menšího počtu trénovacích a validačních polygonů. V případě metody MLC z multispektrálních i hyperspektrálních leteckých dat byly zjištěny velmi podobné difference jako u klasifikace dvou malých ploch. Nejvýraznějším nedostatkem byla v případě multispektrálních dat výrazně vyšší rozloha třídy *Carex bigelowii*, která byla touto metodou vyklasifikována na ploše o více než 10 % větší než při porovnání s metodou OBIA. To bylo do značné míry téměř jistě způsobeno problémy s radiometrickými hodnotami multispektrálního snímku, kdy ze zatím nezjištěných příčin obsahovala data zastíněný pruh přibližně v centrální části ve směru východ-západ. Zajímavé je, že tuto chybu významně lépe překonala klasifikace metodou OBIA, která problém s třídou *Carex bigelowii* do značné míry eliminovala a snímek klasifikovala s větší přesností a relativně vyrovnaně. Celkové výsledky byly s použitím multispektrálních i hyperspektrálních leteckých dat výrazně lepší při použití metody OBIA.

Nejlepšího výsledku z hlediska celkové přesnosti klasifikace bylo v případě hyperspektrálních leteckých dat na širším území tundry dosaženo metodou RF v softwaru R (81,74 %). Jde o jediný případ v celé práci, kdy byla v celkové přesnosti překonána metoda OBIA. Zajímavostí je druhý extrém při použití dat multispektrálních. Zde byla metoda RF nejhorší. S velkou pravděpodobností lze říci, že je to způsobeno rozdílným softwarem. Klasifikace multispektrálního snímku totiž proběhla v ArcGIS Pro,



který nepracuje s totožným postupem výpočtu využívající strukturálních příznaků, jako tomu je v případě skriptu pro klasifikaci RF v softwaru R. Důvodem této změny byl příliš velký objem dat multispektrálního snímku, se kterými nebyl výpočet v softwaru R úspěšně dokončen.

Při přímém porovnání klasifikací širšího území tundry z multispektrálních a hyperspektrálních leteckých dat výsledky zpracovatelských a uživatelských přesností jednotlivých tříd nevykazovaly výrazné rozdíly. Problematické byly ve všech případech třídy *Carex bigelowii* a *Avenella flexuosa*, u kterých výsledky nedosahovaly srovnatelných přesností jako u dalších druhů. Zároveň se v těchto případech výrazně rozcházely i výsledky rozloh tříd. Špatné zpracovatelské a uživatelské přesnosti u těchto kategorií vycházely i u Kupkové a kol. (2021) na ploše „Bílá louka“. Hlavním důvodem je to, že jde o směs heterogenních travních druhů s úzkými listy, které jsou spektrálně špatně odlišitelné (to potvrzují i výsledky analýzy separability v této práci) a též výše zmíněné malé zastoupení těchto kategorií v malých plochách i širším území.

V širším území tundry velmi dobře dopadly výsledky zpracovatelských a uživatelských přesností čtyř hlavních sledovaných travních druhů. U nejlepších klasifikací (z hlediska zpracovatelské přesnosti) dosahovaly tyto třídy přesnosti přes 70 % ve všech případech. *Calamagrostis villosa* byla vyklasifikována dokonce s téměř 90% přesností, a to jak z multispektrálních, tak i hyperspektrálních leteckých dat. Na základě tohoto výsledku lze konstatovat, že s relativně vysokou úspěšností lze hlavní travní druhy mapovat i s omezeným množstvím trénovacích a validačních polygonů. Pro získání velmi vysokých přesností je ale dostatečně obsáhlý dataset trénovacích a validačních polygonů zásadní. Dokazují to výsledky hlavních travních druhů na dvou malých plochách, u kterých byly zpracovatelské a uživatelské přesnosti vyklasifikovány stále výrazně lépe (třída *Calamagrostis villosa* byla na ploše „U Zahrádky“ nejlépe vyklasifikována se zpracovatelskou i uživatelskou přesností přes 99 % oproti širšímu území s výsledkem 90 resp. 87 %; třída *Deschampsia cespitosa* byla na ploše „U Luční boudy“ nejlépe vyklasifikována se zpracovatelskou i uživatelskou přesností přes 98 % oproti širšímu území s výsledkem 85 resp. 72 % – vše z hyperspektrálních dat). Kromě výše zmíněných důvodů může být přesnost klasifikace širšího území tundry oproti dvěma malým plochám zhoršena také kvůli většímu množství kategorií v legendě.

Je důležité zmínit, že hyperspektrální letecká data měla prostorové rozlišení 0,6 m. To je zásadní rozdíl oproti ostatním zdrojům dat v této práci, které byly prostorově mnohem podrobnější. Podle literatury (Davidson a kol., 2016; Suchá a kol., 2016; Kupková a kol., 2017) je vysoké prostorové rozlišení snímku pro mapování vegetace nezbytné pro dosažení vysoké přesnosti. Výsledky této práce ale nevykazují zásadní rozdíly mezi multispektrálními a hyperspektrálními daty při klasifikaci širšího území. I přesto, že hyperspektrální letecké snímky nemají tak vysoké prostorové rozlišení jako snímky

multispektrální, je tento nedostatek s největší pravděpodobností kompenzován vyšším spektrálním rozlišením. Dá se ale předpokládat, že s využitím hyperspektrálních leteckých dat s vyšším prostorovým rozlišením by výsledky byly ještě přesnější.

Problematika pořízení kvalitních dat a jejich přesné předzpracování je podle výstupů této práce pro přesnost klasifikací také velmi důležitá. Příkladem mohou být ostré přechody a zastínění, které byly viditelné například na hyperspektrálních datech z plochy „U Luční boudy“ nebo na multispektrálním snímku širšího území tundry. Při tvorbě snímku je důležité standardizovat pracovní postup a zároveň vytipovat ideální povětrnostní podmínky (bezvětrí, jasno, minimum stínů). Jen tak je možné eliminovat maximum odchylek mezi různými termíny snímání ze stejné oblasti a chyby v klasifikačních výstupech. Z tohoto důvodu jsou pro snímkování teoreticky ideální systémy UAV na rozdíl od leteckého průzkumu. Nabízejí totiž výrazně jednodušší a levnější plánování letecké mise a samotné získávání dat může probíhat opakovaně. V praxi může však v některých územích, kde je častá oblačnost a vítr, být náročné i pořízení kvalitních dat pomocí UAV.

Podle zjištěných výsledků lze obecně říci, že nejlepší kombinací pro dosažení přesných výsledků klasifikace vegetace krkonošské tundry jsou multitemporální hyperspektrální kompozity tvořené snímky z června, července a srpna s velmi vysokým prostorovým rozlišením v řádu centimetrů klasifikované metodou OBIA s dostatečně rozsáhlým datasetem trénovacích a validačních polygonů nasbíraných v terénu. Výsledky klasifikací metodou OBIA je však dobré porovnat/korigovat ideálně s využitím velmi přesných výstupů pixelových klasifikací. Velmi dobrých výsledků lze dosáhnout i s využitím dat multispektrálních. Je ale nutné mít kvalitní data z hlediska radiometrické i geometrické přesnosti, zachovat vysoké prostorové rozlišení snímku a mít k dispozici dostatek polygonů k trénování a validaci. Z práce vyplývá, že k úspěšné klasifikaci jednotlivých travních druhů je kromě dostatečné separability žádoucí i dostatečně velká plocha, na které se třída nachází. Tím se minimalizují významné odchylky mezi výsledky z různých druhů klasifikací a díky tomu vzrůstá přesnost a spolehlivost výsledků. Pokud budou splněny tyto podmínky, je velmi pravděpodobné, že přesnosti klasifikací čtyř ochranných důležitých travních druhů, jimž se věnuje tato práce, budou i do budoucna velmi vysoké.

## 7. Závěr

V práci byla porovnána přesnost různých metod klasifikace travních druhů z multispektrálních a hyperspektrálních dat (UAV a leteckých) velmi vysokého prostorového rozlišení pro dvě malé plochy a širší území tundry. Cíle práce byly splněny. Pro ochranně důležité travní druhy (*Nardus stricta*, *Calamagrostis villosa*, *Molinia caerulea* a *Deschampsia cespitosa*) bylo dosaženo vysoké přesnosti klasifikace v případě, že pokrývaly alespoň 10 % zájmového území.

Výstupem této práce jsou přesné mapy vegetačního pokryvu ploch „U Luční boudy“, „U Zahrádky“ a širšího území krkonošské tundry. Tyto mapové výstupy byly vytvořeny klasifikací výše uvedených dat v kombinaci s celkem třemi datsety trénovacích a validačních polygonů pořízených v terénu. Pro dvě malé plochy byly terénní datsety velmi podrobné a pro širší území méně rozsáhlé (relativně – vztaženo k ploše území). Nejpřesnější výstupy byly získány pro multitemporální hyperspektrální data s prostorovým rozlišením 3 cm pořízená pomocí UAV pro malé plochy „U Luční boudy“ a „U Zahrádky“.

Nejlépších výsledků celkové přesnosti dosáhla v případě malých ploch metoda OBIA, která „U Luční boudy“ a „U Zahrádky“ dosahovala napříč použitými typy dat přesnosti vždy přes 85 %. Na těchto malých plochách byly všechny čtyři důležité travní druhy vyklasifikovány s vysokou přesností, ale pouze za předpokladu rozlohy třídy vyšší než přibližně 10 %. Nejpřesnějších výsledků dosahovaly druhy *Deschampsia cespitosa* (U Luční boudy; součet zpracovatelské a uživatelské přesnosti 197,31 % – OBIA) a *Calamagrostis villosa* (U Zahrádky; součet zpracovatelské a uživatelské přesnosti 199,44 % – OBIA). Největší problémy byly zaznamenány u rozlohou málo rozšířených travních druhů.

V případě klasifikací širšího území přinesla nejlepší výsledky také metoda OBIA (průměr z celkových přesností 81 %), ale stejně přesných výsledků dosahovala i metoda RF aplikovaná v programu R. Z důležitých travních druhů byla nejlépe vyklasifikována třída *Calamagrostis villosa* (zpracovatelská a uživatelská přesnost průměrně 90 %). Naopak velmi podprůměrně dopadly třídy *Carex bigelowii* a *Avenella flexuosa*.

Na základě výsledků práce lze říci, že metody DPZ využívající hyperspektrální a multispektrální data s velmi vysokým prostorovým rozlišením v řádu centimetrů jsou přesným a efektivním nástrojem monitoringu vegetace na úrovni jednotlivých druhů a přináší spolehlivé mapové výstupy využitelné pro studium rozšíření a změn vegetace na území krkonošské tundry. Pro další zlepšení přesnosti doporučuji do budoucna nadále testovat různé kombinace nastavení jak pixelových, tak objektově orientovaných klasifikačních metod, další metody strojového či hlubokého učení a také pokračovat v testování ideálního/minimálního množství botanických dat využívaných pro trénování a validaci tak, aby bylo dosaženo vysoké přesnosti klasifikací, a přitom minimalizováno množství terénní práce.

## Použitá literatura

ASSMANN, J., MYERS-SMITH, I., KERBY, J., CUNLIFFE, A., DASKALOVA, G. (2020): Drone data reveal heterogeneity in tundra greenness and phenology not captured by satellites. *Environmental Research Letters*. 15. 125002. <https://doi.org/10.1088/1748-9326/abbf7d>

ASOKAN, A., ANITHA, J. (2019): Change detection techniques for remote sensing applications: a survey. *Earth Sci Inform* 12, 143–160. <https://doi.org/10.1007/s12145-019-00380-5>

ATKINSON, D.M., TREITZ, P. (2012): Arctic ecological classifications derived from vegetation community and satellite spectral data. *Remote Sens.* 4, 3948–3971. <https://doi.org/10.3390/rs4123948>

BING, L., YUHONG, H. (2017): Species classification using Unmanned Aerial Vehicle (UAV)-acquired high spatial resolution imagery in a heterogeneous grassland. *ISPRS J. Photogramm. Remote Sens.* 128, 73–85. <https://doi.org/10.1016/j.isprsjprs.2017.03.011>

BLASCHKE, T. (2010): Object based image analysis for remote sensing. In *ISPRS Journal of Photogrammetry and Remote Sensing*. 65, 1, 2–16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>

BREIMAN, L. (1999): Random Forest—Random features. Technical report 567.

CAMPBELL, J. B., WYNNE, R. H. (2011): Introduction to remote sensing, 5th edition, The Guildford press. ISBN 978-1-60918-176-5

ČERVENÁ, L., LYSÁK, J., POTŮČKOVÁ, M., KUPKOVÁ, L. (2020): ZKUŠENOSTI SE ZPRACOVÁNÍM HYPERSPEKTRÁLNÍCH DAT POŘÍZENÝCH UAV. Prostorová data pro Smart City a Smart Region. GIS Ostrava 2020.

CZECH GLOBE (2022): Zpracování dat ze senzorů CASI a SASI, [https://olc.czechglobe.cz/?page\\_id=253%2F](https://olc.czechglobe.cz/?page_id=253%2F) (25. 7. 2022)

DAVIDSON, S.J., SANTOS, M.J., SLOAN, V.L., WATTS, J.D., PHOENIX, G.K., OECHEL, W.C., ZONA, D. (2016): Mapping Arctic Tundra Vegetation Communities Using Field Spectroscopy and Multispectral Satellite Data in North Alaska, USA. *Remote Sens.* 8, 978. <https://doi.org/10.3390/rs8120978>

DOBROVOLNÝ, P. (1998): Dálkový průzkum Země. Digitální zpracování obrazu. Vydavatelství Masarykovy Univerzity.

FABŠIČOVÁ, M. (2004): Morphological variability and phenotypic plasticity in dense tussock grass *Deschampsia cespitosa* in an alpine tundra of the Giant Mountains. *Opera Corcontica*, 41: 243–249.

FRASER, R.H., OLTHOF, I., LANTZ, T.C., SCHMITT, C. (2016): UAV photogrammetry for mapping vegetation in the low-Arctic. *Arct. Sci.* 2, 79–102. <https://doi.org/10.1139/as-2016-0008>

GOMÉZ, C., WHITE, J. C., WULDER, A. (2016): Optical remotely sensed time series data for land cover classification: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 116, 2016, 55–72. <https://doi.org/10.1016/j.isprsjprs.2016.03.008>

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, 577–582. <https://doi.org/10.1016/j.flora.2010.04.019>

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. <https://doi.org/10.1016/j.agee.2008.07.007>

HIXSON, M., FUHS, N., & AKIYAMA, T. (1980): Evaluation of Several Schemes for Classification of Remotely Sensed Data. *Photogrammetric Engineering and Remote Sensing*, 46(12), 1547–1553.

JENSEN, J.R. (1986): *Introductory Digital Image Processing. A remote sensing perspective.* Prentice Hall, London, Sydney, Toronto. 379 s.

KOLÁŘ, J., HALOUNOVÁ, L., PAVELKA, K. (1997): *Dálkový průzkum Země. Skripta.* ČVUT.

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 (2010): *Putování po krkonošských loukách.*

KRNAP (2012): *Lesy Krkonošského národního parku a péče o ně.* ISBN: 978-80-86418-90-2

KRNAP (2015): *Krkonošská tundra.* ISBN 978-80-87706-95-4

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. <https://doi.org/10.1080/22797254.2017.1274573>

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

KUPKOVÁ, L. A KOL. (2022): *Towards reliable monitoring of grass species in nature conservation practice: evaluation of the potential of UAS and PlanetScope multitemporal data in the Central European tundra (in prep.).*

L3 HARRIS GEOSPATIAL (2022): *Region of Interest (ROI) Tool,* <https://www.l3harrisgeospatial.com/docs/regionofinteresttool.html#ROISeparability> (25. 7. 2022)

LILLESAND, T. M., KIEFER, R. W., CHIPMAN, J. W. (2015): *Remote sensing and image interpretation (7th ed.).* Wiley.

MARCINKOWSKA-OCHTYRA, A., GRYGUC, K., OCHTYRA, A., KOPEĆ, D., JAROCIŃSKA, A., SŁAWIK, Ł. (2019): Multitemporal hyperspectral data fusion with topographic indices improving classification of natura 2000 grassland habitats. *Remote Sens.* 11. <https://doi.org/10.3390/rs11192264>

MARCINKOWSKA, A., ZAGAJEWSKI, B., OCHTYRA, A., JAROCIŃSKA, A., RACZKO, E., KUPKOVÁ, L., ŠTYCH, P., MEULEMAN, K. (2014): Mapping vegetation communities of the Karkonosze National Park using APEX hyperspectral data and Support Vector Machines. *Miscellanea Geographica*, 18(2), 23–29. <https://doi.org/10.2478/mgrsd-2014-0007>

MOUNTRAKIS, G., IM, J., OGOLE, C. (2011): Support vector machines in remote sensing: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, 3, 247-259, <https://doi.org/10.1016/j.isprsjprs.2010.11.001>.

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.

NELSON, P.R., a kol. (2022): Remote Sensing of Tundra Ecosystems Using High Spectral Resolution Reflectance: Opportunities and Challenges. *JGR: Biogeosciences* 127, 2. <https://doi.org/10.1029/2021JG006697>

PLADIAS – DATABÁZE ČESKÉ FLÓRY A VEGETACE (2022): [www.pladias.cz](http://www.pladias.cz) (23. 6. 2022)

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(12), 3433–3455. <https://doi.org/10.1007/s10531-021-02255-y>

RACZKO, E., ZAGAJEWSKI, B. (2018): Tree Species Classification of the UNESCO Man and the Biosphere Karkonoski National Park (Poland) Using Artificial Neural Networks and APEX Hyperspectral Images. *Remote. Sens.*, 10, 1111. <https://doi.org/10.3390/rs10071111>

SOUKUPOVÁ, L. A KOL. (1995): Arctic-alpine tundra in the Krkonoše, the Sudetes. *Opera corcontica*, 32, s. 5–88.

ŠTURSA, J., WILD, J. (2014): Kleč a smilka – klíčové hráči vývoje alpínského bezlesí Krkonoš (Vysoké Sudety, Česká republika). *Opera Corcontica* 51: 5–36.

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. <http://dx.doi.org/10.14712/23361980.2016.10>.

THOMSON, E.R. A KOL. (2021): *Environmental Research Letters*, 16, 5. <https://doi.org/10.1088/1748-9326/abf464>

VAPNIK, V.N. (1998): *Statistical learning theory*. New York: Wiley. ISBN 0-471-03003-1

ZAGAJEWSKI, B., KLUCZEK, M., RACZKO, E., NJEGOVEC, A., DABIJA, A., KYCKO, M. (2021): Comparison of random forest, support vector machines, and neural networks for post-disaster forest species mapping of the krkonoše/karkonosze transboundary biosphere reserve. *Remote Sensing*, 13(13). <https://doi.org/10.3390/rs13132581>

## Přílohy

### Seznam příloh:

Příloha 1: Výstup klasifikace plochy „U Luční boudy“ objektově orientovanou metodou z hyperspektrálních dat

Příloha 2: Výstup klasifikace plochy „U Luční boudy“ objektově orientovanou metodou z multispektrálních dat

Příloha 3: Výstup klasifikace plochy „U Zahrádky“ objektově orientovanou metodou z hyperspektrálních dat


Příloha 4: Výstup klasifikace plochy „U Zahrádky“ objektově orientovanou metodou z multispektrálních dat

Příloha 5: Výstup klasifikace širšího území tundry metodou Random forest z hyperspektrálních leteckých dat

Příloha 6: Výstup klasifikace širšího území tundry metodou maximální pravděpodobnosti z multispektrálních dat

# PŘÍLOHA 1: VÝSTUP KLASIFIKACE PLOCHY „U LUČNÍ BOUDY“

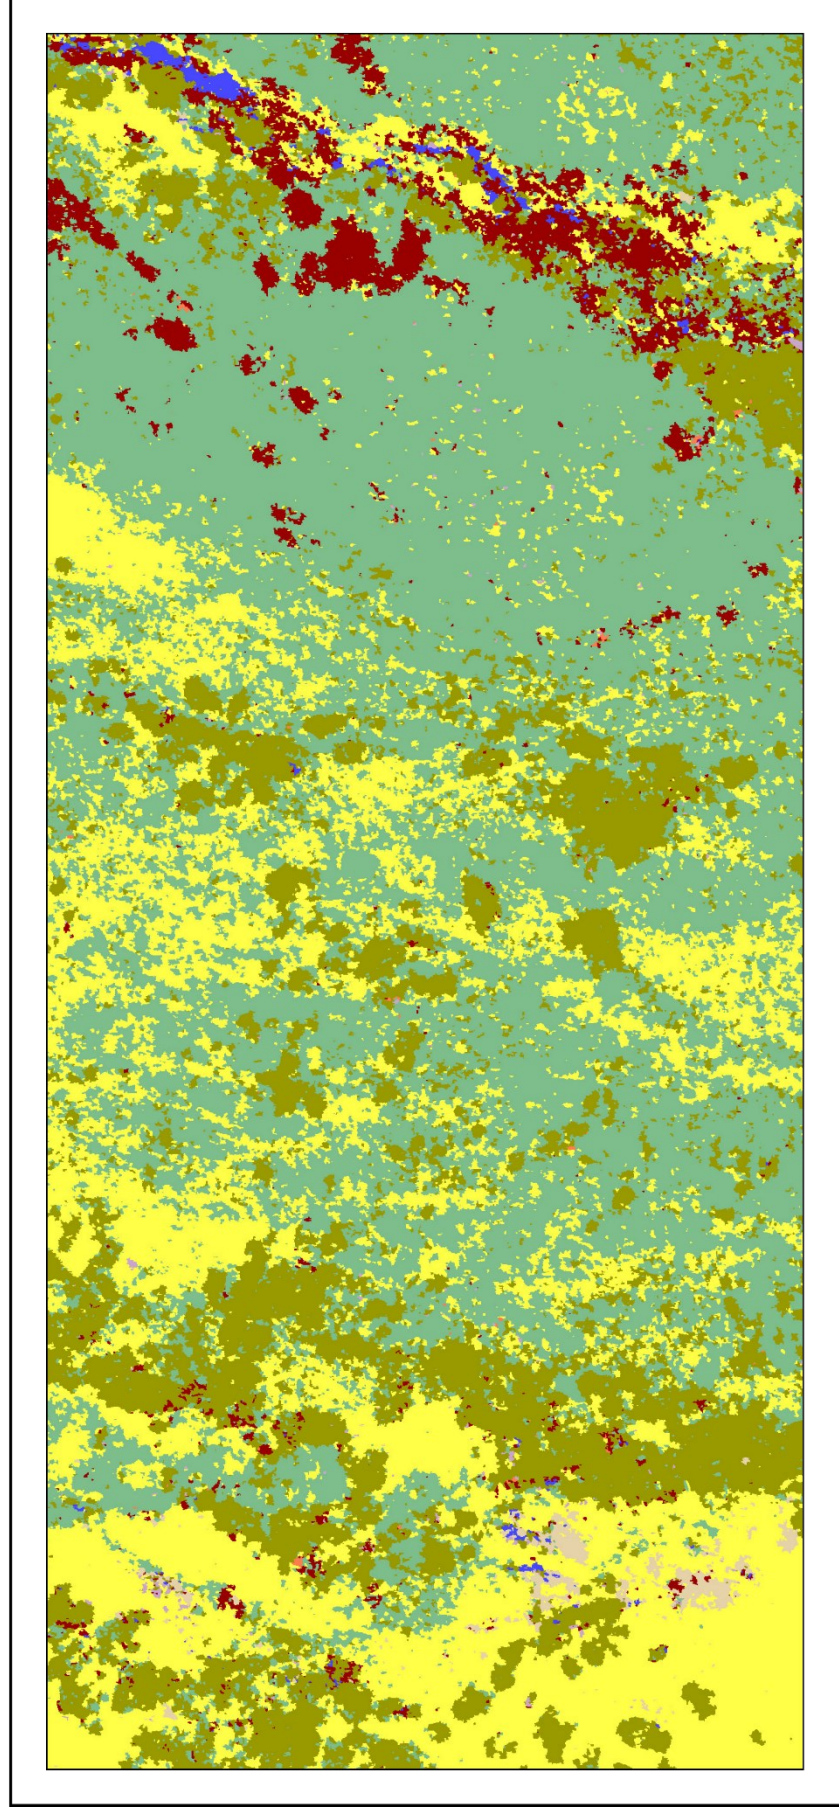
objektově orientovanou metodou z hyperspektrálních dat





## PŘÍLOHA 2: VÝSTUP KLASIFIKACE PLOCHY „U LUČNÍ BOUDY“

objektově orientovanou metodou z multispektrálních dat



50 m

0


25










Vít Ježek

Praha 2022



# PŘÍLOHA 3: VÝSTUP KLASIFIKACE PLOCHY „U ZAHRÁDKY“ objektově orientovanou metodou z hyperspektrálních dat




- |  |  |  |  |
|--|--|--|--|
|  <i>Avenella flexuosa</i> |  <i>Calamagrostis villosa</i> |  <i>Carex bigelowii</i> |  <i>Picea abies</i> |
|  <i>Molinia caerulea</i>  |  <i>Deschampsia cespitosa</i> |  <i>Nardus stricta</i>  |  <i>Pinus mugo</i>  |
|  neklasifikovaná plocha   |  |  |  |









0 15 30 m




Vít Ježek  
Praha 2022

# PŘÍLOHA 4: VÝSTUP KLASIFIKACE PLOCHY „U ZAHRÁDKY“ objektově orientovanou metodou z multispektrálních dat



- |  |  |  |  |
|--|--|--|--|
|  <i>Avenella flexuosa</i> |  <i>Calamagrostis villosa</i> |  <i>Carex bigelowii</i> |  <i>Picea abies</i> |
|  <i>Molinia caerulea</i>  |  <i>Deschampsia cespitosa</i> |  <i>Nardus stricta</i>  |  <i>Pinus mugo</i>  |

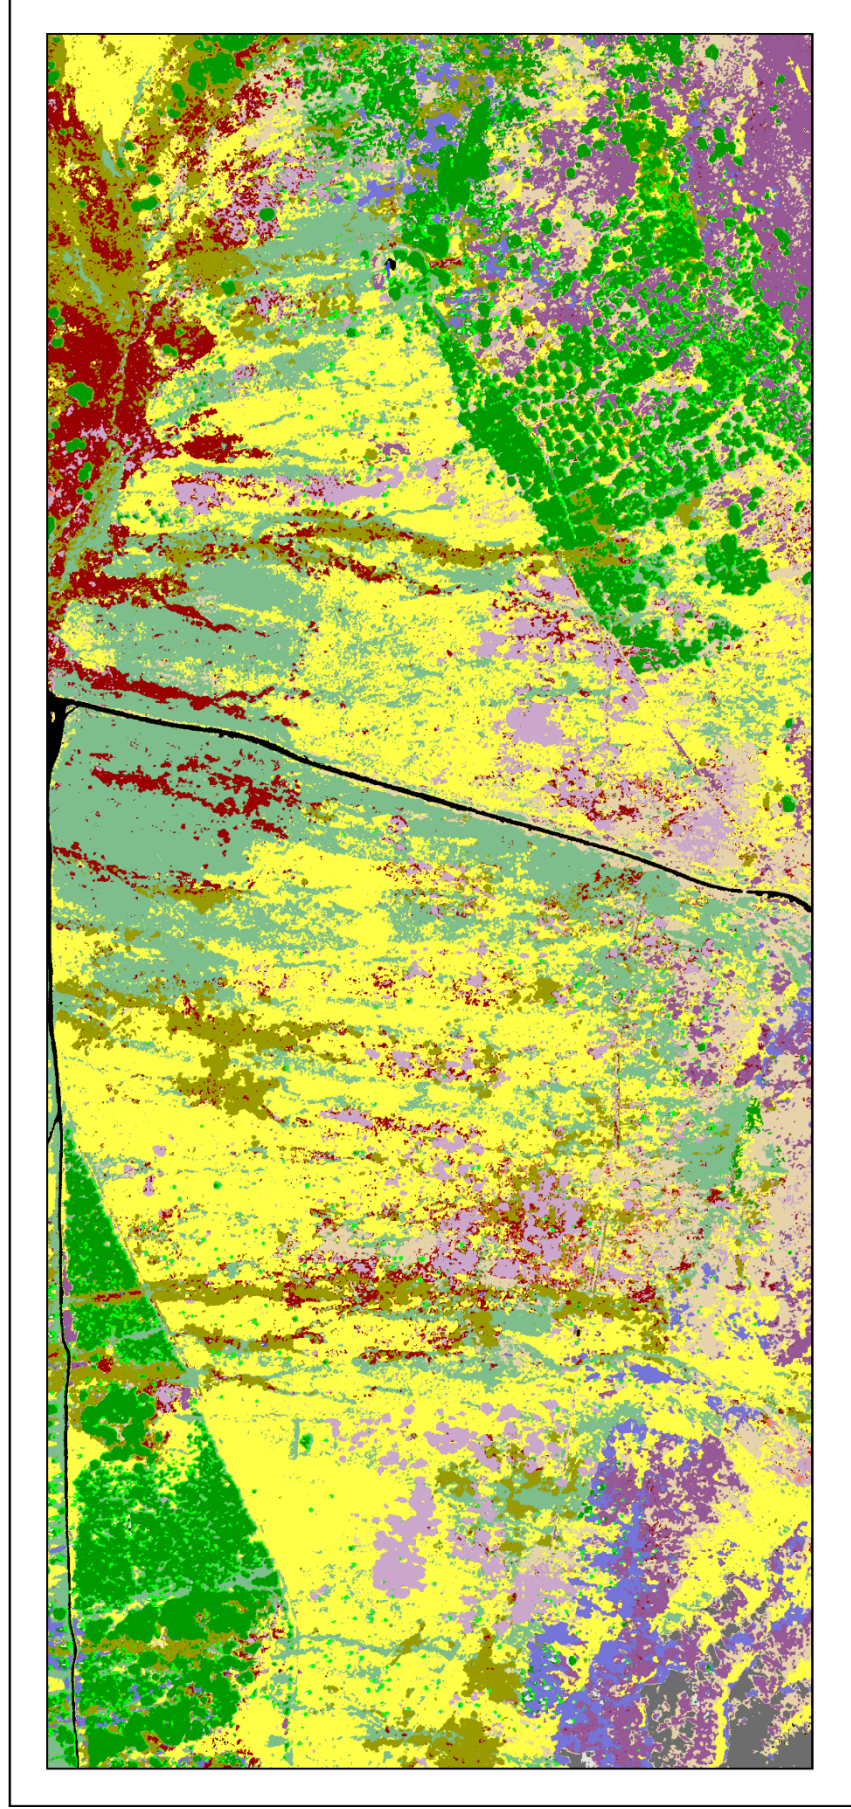

















Vít Ježek  
Praha 2022



# PŘÍLOHA 5: VÝSTUP KLASIFIKACE ŠIRŠÍHO ÚZEMÍ TUNDRY

metodou Random forest z hyperspektrálních leteckých dat



- |  |  |  |  |   |   |
|--|--|--|--|---|---|
|  <i>Molinia caerulea</i>      |  <i>Vaccinium myrtillus</i>   |  cesta                    |  kamenná moře       |  <i>Pinus mugo</i> |  <i>Carex bigelowii</i>  |
|  <i>Deschampsia cespitosa</i> |  mokřady a rašelinště         |  <i>Nardus stricta</i>    |  <i>Picea abies</i> |  stříny            |  <i>Calluna vulgaris</i> |
|  vodní plochy                 |  <i>Calamagrostis villosa</i> |  <i>Avenella flexuosa</i> |  |   |   |



















Vít Ježek  
Praha 2022



# PŘÍLOHA 6: VÝSTUP KLASIFIKACE ŠIRŠÍHO ÚZEMÍ TUNDRY

metodou maximální pravděpodobnosti z multispektrálních dat



- |  |  |  |   |   |   |
|--|--|--|---|---|---|
|  <i>Molinia caerulea</i>      |  <i>Vaccinium myrtillus</i>   |  cesta                    |  kamenná moře       |  <i>Pinus mugo</i> |  <i>Carex bigelowii</i>  |
|  <i>Deschampsia cespitosa</i> |  mokřady a rašeliniště        |  <i>Nardus stricta</i>    |  <i>Picea abies</i> |  stříny            |  <i>Calluna vulgaris</i> |
|  vodní plochy                 |  <i>Calamagrostis villosa</i> |  <i>Avenella flexuosa</i> |   |   |   |



Vít Ježek  
Praha 2022